

Estimando os Impactos Covid-19 na Volatilidade e Spillover de Mercados Financeiros: Uma Análise Contrafactual Temporal.

Abstract

The study's objective is to estimate the counterfactual impacts of the Covid-19 pandemic on the volatility and spillovers (for the Brazilian financial market) of 15 countries, in addition to the counterfactual effects of adopting lockdown policies and characteristics of these countries. Consider in the study two counterfactual inference approaches: the Differential-in-Differences (DiD) panel data models and the high-dimensional artificial counterfactual panels (ArCo) models. DiD models increase volatility (on average) when there is a higher pandemic incidence and reduce this volatility with pandemic cooling, while spillovers for the Brazilian market fall (on average) with increasing pandemic severity and increase with pandemic cooling, to these models the adoption of a lockdown policy only has negative counterfactual effects for the volatility panel. The results of the ArCo models indicate that volatility suffers the greatest impacts from the combination of incidence and pandemic severity, while for spillovers, the greatest impact of the incidence of the Covid pandemic was found. In the ArCo models, there is no evidence of counterfactual effects associated with the adoption of lockdown policies. Both approaches converge on the conclusion that the Covid-19 pandemic's cooled down, counterfactually will reduce volatility and increase spillovers for the Brazilian market.

JEL: G15, C58, C32

Keywords: Covid-19, Volatility, Spillovers, Counterfactual Inference.

Resumo

O objetivo deste estudo é estimar os impactos contrafactuais da pandemia do Covid-19 na volatilidade e spillovers (para mercado financeiro brasileiro) de 15 países, além dos efeitos contrafactuais de adoção de políticas de lockdown e de características desses países. Consideramos no estudo duas abordagens de inferência contrafactual: os modelos de dados em painel de Diferenças-em-Diferenças (DiD) e os modelos de painéis contrafactuais artificiais de alta-dimensão (ArCo). Os modelos DiD, sugerem que a volatilidade aumenta(em média) quando existe maior incidência pandêmica e reduz no arrefecimento da pandemia, enquanto os spillovers para o mercado brasileiro, caem (em média) com aumento da gravidade pandêmica e aumentam com o arrefecimento da pandemia, para esses modelos a adoção de política de lockdown apenas tem efeitos contrafactuais negativos para o painel de volatilidade. Os resultados dos modelos ArCo indicam que a volatilidade sofre maiores impactos da combinação de incidência e gravidade pandêmica, enquanto para os spillovers, verificou-se maior impactos da incidência da pandemia do Covid. Nos modelos ArCo não há nenhuma evidência de efeitos contrafactuais associado a adoção de políticas de lockdown. As duas abordagens convergem na conclusão de que arrefecimentos da pandemia do Covid-19, contrafactualmente reduzem a volatilidade e aumentam os spillovers para o mercado brasileiro.

JEL: G15, C58, C32

Palavras-Chave: Covid-19, Volatilidade, Spillovers, Inferência Contrafactual.

1. Introdução

A pandemia do Covid-19 trouxe ao mundo novos comportamentos, novas políticas, novos temas de pesquisa e alterou de maneira abrupta as escolhas dos agentes diante de um novo cenário com risco sanitário adicional. A velocidade de propagação de casos combinado a aceleração de letalidade na sequência gerou impacto de políticas públicas que foram desde restrições completas de movimentação, a políticas de socorro sócio-econômico. Os desdobramentos dessas políticas geraram efeitos em cadeia nos mercados e na economia como um todo. Os mercados financeiros sofreram diretamente esse choque exógeno, os impactos se traduziram como uma drástica elevação da incerteza e, por conseguinte, uma elevação nos riscos financeiros. O aumento da volatilidade seria reflexo desse comportamento, absorvido quase que em tempo real nas bolsas de valores. Esse comportamento conjunto, em reação a mudança do cenário de risco e de políticas adotadas pelos governos, afeta também os co-movimentos desses mercados de ativos, criando movimento de sincronização ou de-sincronização que podem ser globais, regionais ou localizados e que a literatura de finanças chama de spillover, ou ainda a literatura de econometria financeira chama de correlação condicional, dado sua dinâmica variando no tempo.

Várias importantes questões surgem sobre esses temas financeiros envolvendo volatilidade e spillovers. Estudos podem ser direcionados para análise a trajetória dos fatos como ocorreram e podem chegar a importantes conclusões, contudo, em se tratando de um evento inesperado e repentino, como foi o evento pandêmico do Covid-19, isso o torna um evento quase-experimental, fazendo com que as questões mais relevantes surjam dos questionamentos do que teria ocorrido em um contexto contrafactual, ou seja, o que teria ocorrido com um mesmo mercado, em termos de volatilidade e spillovers, caso não tivesse a intervenção pandêmica, ou se caso não tivesse adotado uma política de lockdown na intervenção pandêmica. A resposta dessas importantes questões nos conduzem a inferência contrafactual (ou causal), e nesse contexto foi utilizado uma amostra de 15 países (incluindo o Brasil) com 143 observações diárias de volatilidade e de transbordamentos de volatilidade para o mercado financeiro brasileiro em um período que antecede a pandemia e chega até o mês de agosto do ano desse estudo.

O primeiro passo foi estimar individualmente para cada país sua variância e correlação condicional por meio de modelos GARCH multivariados. Uma vez obtidas essas medidas de volatilidade e spillovers, foram construídos dois painéis nessas temáticas, incluindo diversas fontes de informações pandêmicas, de diferentes tipos de restrições impostas pelos governos da amostra, além de características desses países, para que somente então fossem estimadas as inferências contrafactuais. Duas abordagens de inferência contrafactual temporal são colocadas a prova para estudar os dois painéis dados com esses países: modelos de painel de Diferenças-em-Diferenças (DiD) e os recentes modelos de painel contrafactuais artificiais de alta-dimensão. Os resultados dessas duas abordagens divergem em relação dos impactos da incidência (medida pelo número de casos em 1 milhão/hab.) e a gravidade (medida pelo número de óbitos por 1 milhão/hab.) sobre a volatilidade e spillovers, também divergem para adoção pelos países da política de lockdown, contudo convergem em relação as medidas de arrefecimento da pandemia (medida pelo número de recuperados e número de medidas de saúde pública), em que arrefecimentos da pandemia, estão relacionados com redução de volatilidade e aumentos de spillovers para o mercado brasileiro.

O artigo apresenta na seção 2 uma breve revisão da literatura sobre spillovers no mercado de ações e os diferentes impactos da pandemia Covid-19. Na seção 3 detalhamos todos os modelos utilizados no estudo, sendo que a descrição dos dados e resultados são apresentados na seção 4, e as conclusões do estudo na seção 5.

2. Literatura

2.1 A literatura de Spillover no Mercado de Ações

O efeito spillover, também chamado de transbordamento, apresenta uma vasta utilização na literatura. Este efeito, procura identificar o quanto as variações de um mercado (ou índice) podem afetar outro mercado e em que direção este impacto pode ocorrer.

Em de Oliveira and Maranhao (2017) os autores apresentam uma importante abordagem do efeito spillover para o mercado acionário brasileiro, combinando as volatilidades cambiais e de mercados internacionais para o mercado de ações brasileiro com a utilização dos modelos GARCH multivariados. Ademais, os autores acrescentaram os testes de causalidade de Granger em segunda ordem com intuito de verificar a direção do efeito spillover na análise. Os resultados apontados pelos autores indicaram a existência de correlações condicionais as quais permitiram chegar a conclusão de transbordamento e, ainda, que o spillover, cambial e de mercados financeiros estrangeiros, ocorre dos choques para o índice Ibovespa.

Milani et al. (2014) analisaram os choques de iliquidez entre os mercados brasileiros, por meio do modelo de Auto-regressão Vetorial (VAR). Os autores utilizaram em sua análise dados mensais dos mercados de Fundos de Investimento, Títulos do Tesouro Nacional, Poupança e Depósitos à Prazo no Brasil. A partir da análise de impulso-resposta realizada, os autores observaram em seus resultados co-movimentos na iliquidez dos mercados estudados, com destaque para os choques na variação de iliquidez de Fundos de Ações que impactam positivamente na variação de iliquidez da Bovespa, de modo que, o aumento da iliquidez de um está ligada ao aumento do outro.

Em de Almeida et al. (2012), os autores avaliam como um distress nos retornos financeiros do Ibovespa, Dow Jones e das ações brasileiras negociadas no mercado brasileiro, se relacionam entre si, com intuito de capturar o efeito spillover entre as séries históricas. Os autores utilizaram a metodologia CoVar nos dados diários, entre janeiro de 1995 e agosto de 2011, das variáveis analisadas. Ademais, construíram uma matriz de contágio para observar como ocorre a transmissão das perdas entre os papéis negociados. Os resultados encontrados indicaram a existência de uma interação entre os retornos dos ativos financeiros das empresas brasileiras e os Índices Ibovespa e Dow Jones, na presença de fortes choques nestes índices. Ainda, ressaltaram que a Petrobrás (PETR4) foi identificado como o ativo líder em contágio e a Usiminas (USIM5) a líder em ser contagiada quando há a presença de um ambiente adverso.

No trabalho de Righi and Ceretta (2013) os autores tratam do efeito spillover para a volatilidade do mercado acionário brasileiro, com relação aos mercados de México, Argentina, China e Estados Unidos. O período analisado foi de janeiro de 2000 até março de 2010, com a amostra diária dos índices dividida em três grupos distintos: pré-crise, durante a crise e pós-crise. O modelo utilizado pelos autores foi o GARCH Multivariado com parametrização BEKK. Os resultados apontados pelos autores indicam que durante a crise de 2008 ocorreu alteração na direção em que volatilidade se transmitiu entre o mercado brasileiro e os demais mercados analisados, de modo que, o Brasil passou a exercer maior influência na volatilidade dos índices, por ter tido um impacto menor da crise comparativamente com os outros países. Os autores acrescentaram, ainda, que no período pós crise de 2008 a assimetria entre o mercado brasileiro e os demais diminuiu em termos de volatilidade, comparativamente ao período pré-crise.

Em outro trabalho elaborado por Gaio et al. (2014), os autores visaram identificar, a partir de alguns índices de ações, a existência de causalidade e interdependência entre as volatilidades. Além do Ibovespa foram selecionados outros 5 índices de bolsa de valores internacionais, sendo eles: Dow Jones, Nasdaq, Nikkei-225, Standard & Poor's 500 e

Financial Times, com a utilização da metodologia de séries temporais com os testes de estacionariedade ADF (DickeyFuller Aumentado), KPSS e Causalidade de Granger. Gaio et al. [2014] indicaram em seus resultados que os índices comportam-se com média constante no tempo e, ainda, que as variações observadas na volatilidade do índice brasileiro não causam interferência nos índices Dow Jones e Standard & Poor's 500. Porém, observam que há uma relação entre os índices Dow Jones e Financial Times sobre o Ibovespa.

Destaca-se que a literatura do efeito spillover é ampla tanto no âmbito nacional, quanto internacional, tratando do tema em diferentes áreas de pesquisa e várias abordagens distintas entre si. Menciona-se, ainda, a vasta revisão de literatura apresentada em de Oliveira and Maranhao (2017) tratando do tema, com foco no mercado acionário. No estudo, os autores exibem literaturas com diferentes aplicabilidades do efeito transbordamento pelo mundo, em diferentes épocas.

2.2 A literatura de Impactos da Pandemia do Covid-19

A pandemia do Covid-19 marcou a história mundial recente não apenas pela alta velocidade de propagação e intensidade de letalidade, mas também pelos impactos nas mais diferentes áreas de conhecimento. Assim que seus impactos tomaram proporções mundiais, pesquisadores de diferentes áreas da ciência aceleraram esforços em identificar os diferentes efeitos desse novo fenômeno em seus respectivos nichos de pesquisa.

Os números de casos, de óbitos por Covid-19 e recuperados passou a ter seus número atualizados e acompanhados diariamente na maior parte dos países¹ e publicações surgiram já estimando seus impactos em mortes futuras, como no estudo Roberton et al. (2020), que apresenta estimativas iniciais dos efeitos indiretos da pandemia COVID-19 na mortalidade materna e infantil em países de baixa e média renda. Sumner et al. (2020) estimaram os efeitos sobre a pobreza mundial e chegaram a preocupante conclusão de que, *ceteris paribus*, assumindo uma contração de 5 por cento na renda per capita, o mundo poderia testemunhar um aumento potencial no número de pessoas pobres, em relação aos números de 2018, de mais de 80 milhões para a linha de pobreza de US \$ 1,9/dia, de mais de 130 milhões para o US \$ 3,2/dia padrão, e de quase 124 milhões para a linha superior de US \$ 5,5/dia.

Os efeitos econômicos estudados não se limitaram a temática futura da pobreza, mas também aos efeitos correntes sobre o desemprego, como no estudo de Fairlie et al.(2020), que mostra como a pandemia impactou o desemprego das minorias usando microdados até abril de 2020. Afro-americanos experimentaram um aumento no desemprego para 16,6 por cento, menos do que o antecipado com base em recessões anteriores. Outros estudos como Coates et al. (2020) e Kurmannet al. (2020), mostram outros diferentes impactos sobre o desemprego. As políticas de lockdown também foram alvo de pesquisas, como o estudo de Ozili e Arun (2020), mostravam que o aumento do número de dias de bloqueio, as decisões de política monetária e as restrições às viagens internacionais afetaram severamente o nível das atividades econômicas e o fechamento, a abertura, o menor e o maior preço das ações dos principais índices do mercado de ações. Os estudos com a resposta dos governos para amenizar os efeitos perversos também começaram a surgir, como por exemplo o estudo de Casado et al. (2020), que fornece uma maneira de avaliar quase em tempo real medidas fiscais para estímulo atividade econômica local. Por outro lado impactos nas finanças públicas também foi tema de estudo de Clemens e Veuger (2020), que estimaram uma queda de arrecadação de US\$ 106 bilhões projetados para o exercício de 2021. Mesmo os impactos

¹ A universidade JHU criou um painel de informações da pandemia para um grande grupo de países disponível no site: <https://coronavirus.jhu.edu>

diários na economia foram estimados utilizando dados de consumo de energia elétrica para Itália, como mostra Fezzi e Fanghella (2020).

Apesar da maioria dos impactos da pandemia do Covid-19 terem caráter negativos, alguns estudos relatam benefícios ecológicos e climáticos que a abrupta desaceleração social causou, como por exemplo Wang e Su (2020), Mandaland Pal (2020), Norouzi et al. (2020) e Le Quéré et al. (2020), apenas para citar alguns exemplos. Os impactos nos mercados financeiros, segundo Baker et al. (2020) e Fernandes (2020), foram sem precedentes. Baker et al. (2020) mostram que nenhum surto de doença infecciosa anterior, incluindo a gripe espanhola, impactou a bolsa de valores norte americana tão vigorosamente quanto a pandemia COVID-19. Na verdade, as pandemias anteriores deixaram apenas leves traços no Mercado de ações dos EUA. As evidências desse estudo sugere que as restrições dos governos à atividade comercial e distanciamento social voluntário, operaram como poderosos efeitos em uma economia mundial orientada para serviços, essas seriam as principais razões pelas quais o mercado de ações dos EUA reagiu com tamanha força para COVID-19 do que para pandemias anteriores.

O estudo de De Vito e Gomez (2020) investigaram como a crise de saúde COVID-19 pode afetar a liquidez de empresas listadas em 26 países. Os resultados indicaram que os empréstimos-ponte são mais econômicos para evitar uma crise de caixa massiva. Os estudos de Garcin et al.(2020) utilizaram uma abordagem não paramétrica para estimar as variações no tempo das densidade de retornos de preços diários de vários índices de ações e, usando várias estatísticas de divergência, puderam descrever a cronologia da crise, bem como as disparidades regionais. Por exemplo, um impacto mais limitado do COVID-19 nos mercados financeiros da China, um forte impacto nos EUA e uma lenta recuperação na Europa. Zhang et al. (2020) mostram que a rápida disseminação do coronavírus (COVID-19) teve impactos dramáticos na volatilidade e nos níveis de risco nos mercados financeiros em todo o mundo, fazendo com que os investidores sofressem perdas significativas em um período muito curto de tempo. Al-Awadhi et al. (2020) mostraram que tanto o crescimento diário no total de casos confirmados quanto no total de casos de morte causados por COVID-19 têm efeitos negativos significativos no retorno das ações em todas as empresas nas bolsas chinesas. O estudo de Topcu and Gulal (2020) estimando os impactos do COVID-19 nos mercados de ações de países emergentes, revelam que o impacto negativo da pandemia nos mercados de ações emergentes caiu gradualmente e começou a diminuir em meados de abril. Em termos de classificação regional, o impacto do surto foi maior nos mercados emergentes asiáticos, enquanto os mercados emergentes na Europa tiveram menor intensidade.

Em termos dos impactos Covid-19 em volatilidade, o estudo de Albulescu [2020a] mostra que os novos casos relatados na China e fora da China têm um efeito misto na volatilidade financeira, a taxa de mortalidade influencia positivamente a índice de volatilidade dos mercados financeiros (VIX), enquanto no estudo Albulescu [2020b], o autor investiga empiricamente o efeito dos anúncios oficiais relativos ao índice de novos casos de infecção e fatalidade do COVID-19 na volatilidade dos mercados financeiros dos Estados Unidos (EUA). Considerando os números globais e americanos do COVID-19 o autor mostra que a crise sanitária aumenta a volatilidade realizada do S&P 500. Ibikunle e Rzayev (2020) mostram uma migração de traders para diferentes mercados orientados pelas mudanças de volatilidade causadas pelo Covid-19. Em termos de spillover, o estudo de Corbet et al. (2020), relata que o COVID-19 teve um efeito substancial sobre os transbordamentos de volatilidade para o mercado de Bitcoin. O objetivo dessa breve revisão não é esgotar todos os inumeros estudos que tratam dos impactos da pandemia do Covid-19, mas trazer exemplos de diferentes áreas de pesquisa, até a temática de volatilidade e spillovers que serão tratados como o tema principal deste estudo.

3. Metodologia

3.1 Modelo GARCH Multivariado - BEKK

Inicialmente, os estudos de volatilidade com comportamento variável no tempo foram discutidos por meio de modelos univariados. Posteriormente, outros autores passaram a tratar do tema considerando uma abordagem multivariada. Nesta primeira subseção são apresentados os modelos de análises multivariadas, ampliando os modelos do tipo ARCH exibidos por Engle (1982). Bollerslev (1986) propôs em seu estudo o modelo descrito como GARCH, uma generalização do modelo ARCH. Dentre uma das principais vantagens da adoção deste modelo destaca-se a utilização de uma quantidade menor de parâmetros quando comparado com o modelo ARCH. Conforme apresentado em Maranhão e de Oliveira (2017), após a adoção dos modelos multivariados, outro importante aspecto foi adicionado às pesquisas para tratar da abordagem das correlações variando ao longo do tempo. À esta nova implementação ao modelo GARCH foi dado o nome de GARCH multivariado (MGARCH) que segue a fórmula: de Oliveira e Maranhão (2017)

$$vech(\Sigma_{t|t-1}) = C_0 + \sum_{j=1}^q A_j vech(u_{t-j} u'_{t-j}) + \sum_{j=1}^m B_j vech(\Sigma_{t-j|t-j-1}) \quad (1)$$

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

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

Com intuito de obter parâmetros adequados de covariâncias condicionais, o espaço de parâmetros do modelo MGARCH precisa ser reduzido, de modo que seja garantida a unicidade na representação. A restrição do MGARCH é abordado em Bollerslev (1986) com a implementação de modelos MGARCH diagonais, sendo que A_j 's e B_j 's são interpretados como matrizes diagonais.

Como opção alternativa ao modelo MGARCH foi exibido o modelo BEKK GARCH representado pela equação a seguir:

$$\Sigma_{t|t-1} = C_0^* C_0^* + \sum_{n=1}^N \sum_{j=1}^q A_{jn}^* u_{t-j} u'_{t-j} A_{jn}^* + \sum_{n=1}^N \sum_{j=1}^m B_{jn}^* \Sigma_{t-j|t-j-1} B_{jn}^* \quad (4)$$

Em que C_0^* é a representação de uma matriz triangular de dimensão $K \times K$, assim como, os coeficientes matriciais A_{jn}^* e B_{jn}^* que possuem a mesma dimensão.

Conforme exposto nos estudos de Maranhão e de Oliveira (2017) e de Oliveira e Maranhão (2017), apesar do modelo BEKK de baixa ordem ser uma representação equilibrada da estrutura de covariância, o número de parâmetros tende a crescer de forma rápida com a dimensão do sistema subjacente. Diante desta situação, em termos práticos, somente pode ser considerado viável sistemas com algumas variáveis e com outras medidas de simplificação para comedir a modelagem de processos com dimensões mais elevadas. Para estes casos podem ser considerados modelos especiais como o Diagonal BEKK, em particular para os casos bivariados como serão estimados nesse estudo. Nessa versão, o caso bivariado considera apenas a diagonal com variâncias condicionais e o elemento de correlação condicional a ser estimado.

3.2 Introdução a Inferência Causal e os Modelos de Dados em Painel de Diferenças-em-Diferenças

O estudo experimental aleatorizado, desde surgimento dos testes estatísticos de hipóteses, se consolidou como um dos principais pilares do desenvolvimento científico. No ambiente clínico, a dosimetria controlada, e a identificação de grupos de controle e de tratamento, permitiu identificar a eficácia de medicamentos ou de tratamentos. No contexto ciências sociais, a reprodução desse ferramental metodológico tem se mostrado um grande desafio. Desde o trabalho pioneiro de John Snow (1855), que buscou identificar as causas da epidemia de cólera em Londres, até a primeira versão do modelo de diferenças-em-diferenças apresentado por Ashenfelter e Card (1985) foram mais de cem anos. Diante da impossibilidade de haver um experimento completamente randomizado, a estatística evoluiu para métodos que permitisse uma pseudo randomização por meio de fenômenos quase-experimentais. A ideia era estimar efeitos contrafactuais a partir da reconstrução de uma pseudo-unidade de tratamento que permitisse obter uma estimativa dos efeitos de uma intervenção.

Dessa forma, considere a notação apresentada por Carvalho et al. (2018);

- 1) Unidades: indexados por $i = 1, \dots, n$, que pode ser indivíduos, estados, países, etc. O tratamento ocorre em uma dessas unidades e não afeta as outras;
- 2) Variáveis: $z_{it} = (z_{it}^1, \dots, z_{it}^{q_i})$ sendo $q_i > 1$ a quantidade total de variáveis relacionadas as unidades de tratamento;
- 3) Intervenção: A intervenção ocorreu apenas na unidade tratada no momento $T_0 = \lambda_0 T$ com $\lambda_0 \in (0,1)$.

Suponha, sem perda de generalidade, que a unidade tratada é a primeira ($i = 1$). Considere ainda que $z_{1t}^{(0)}$ e $z_{1t}^{(1)}$ sejam os resultados da primeira unidade com tratamento e sem tratamento, respectivamente. Normalmente, não observamos os dois resultados simultaneamente. Em vez disso, observamos:

$$z_{1t} = D_t z_{1t}^{(0)} + (1 + D_t) z_{1t}^{(1)} \quad (5)$$

Onde D_t assume valor 1 se a unidade estiver em tratamento no momento t e 0 caso contrário. O objetivo é testar a hipótese de os efeitos da intervenção serem estatisticamente significativos para $t > T_0$. As intervenções são consideradas no seguinte formato:

$$y_t^{(1)} = \begin{cases} y_t^{(0)}, & t = 1, \dots, T_0 \\ y_t^{(0)} + \delta_t, & t = T_0, \dots, T \end{cases} \quad (6)$$

Onde y_t representa a variável resposta de interesse. Considerando um contexto de dados em painel, o efeito δ_t pode ser estimado a partir dos modelos de efeito fixos, conforme Angrist (2008):

$$y_{it} = \alpha_i + \lambda_t + \theta D_{int} + \phi D_{trat} + \delta(D_{int} \times D_{trat}) + z'_{it} \beta + \varepsilon_{it} \quad (7)$$

Onde, D_{int} representa a dummy de intervenção e D_{trat} a dummy de tratamento. Os efeitos contrafactuais de Diferenças-em-Diferenças (DiD) são obtidos pelo parâmetro $\hat{\delta}$. Para Card and Krueger (1994) a principal vantagem do método DiD é a de que ele é capaz de controlar para as influências das variáveis de resultado para características não-observáveis que sejam fixas no tempo, essa é uma vantagem importante, porque caso essas características não-observáveis influenciem sobre a decisão de participar do tratamento, ocorrerá o que chamamos de viés de seleção. Ou seja, a ferramenta DiD é capaz de levar em conta a

associação entre a variável de resultado, a participação no tratamento e as características não observáveis dos indivíduos que sejam invariantes no tempo, contornando o viés de seleção. As principais hipóteses desse modelo são:

- 1) O modelo de regressão foi corretamente especificado, com inclusão de outras variáveis independentes de controle;
- 2) O termo de erro é em média igual a zero: $E(\varepsilon_{it}) = 0$;
- 3) O termo de erro não é correlacionado com outras variáveis na equação. Esse pressuposto, conhecido como pressuposto de tendência paralela;
- 4) As variáveis omitidas são constantes no tempo;
- 5) Não dependência cross-section;
- 6) Não há endogeneidade presente no modelo;

Várias dessas hipóteses foram contestadas por Bertrand et al. (2004), em particular o pressuposto-chave de tendências comuns que é chamado *de parallel trend assumption*. Esse pressuposto não possui teste formal na literatura e dessa forma a validade de suas inferências contrafactuais depende diretamente da crença em sua validade nos modelos estimados.

3.3 Modelos de Dados em Painel de Contrafactuais Artificiais em Alta Dimensão

Uma alternativa recente para enfrentar as hipóteses restritivas dos modelos DiD, foi o surgimento dos modelos contrafactuais sintéticos ou artificiais. O método de controle sintético (SCM) proposto por Abadie et al. (2010), Abadie et al. (2015), Abadie and Gardeazabal (2003) é uma abordagem popular para estimar o impacto de um tratamento em uma única unidade em ambientes com um número grande de unidades de controle e com muitos pré-tratados com resultados para todas as unidades. A ideia é construir uma média ponderada das unidades de controle, conhecido como controle sintético, que corresponda a uma unidade tratada mais estatisticamente próximo de uma unidade pré-tratada. O impacto estimado é então a diferença nos resultados pós-tratamento entre a unidade tratada e o controle sintético. Uma limitação importante desta abordagem é que, enquanto SCM minimiza o desequilíbrio nos resultados de pré-tratamento, geralmente falha em atingir o equilíbrio exato entre tratados e não tratados pós-intervenção devido à maldição da dimensionalidade, o desequilíbrio resultante pode levar a um grave viés.

A primeira solução proposta para eliminação desse viés foi proposto por Hsiao, Ching, and Wan (2012), que considera um método de duas etapas em que, em sua primeira etapa, o contrafactual para uma única variável de interesse tratada é construído como uma combinação linear de um conjunto de baixa dimensão de covariáveis observadas a partir de elementos pré-selecionados de um grupo de pares. O modelo é estimado por mínimos quadrados ordinários usando dados do período pré-intervenção. Seus resultados teóricos foram derivados sob a hipótese de especificação correta de um modelo linear de dados em painel com fatores comuns e sem covariáveis. A seleção dos pares incluídos na combinação linear é feita por critérios de informação.

O método proposto por Carvalho et al. (2018), de painéis contrafactuais artificiais em alta dimensão (ArCo), generaliza o trabalho de Hsiao, Ching, and Wan (2012) em direções importantes. Primeiro, considerando estimativa LASSO na primeira etapa, permitimos que um grande número de covariáveis/pares sejam incluídos, não exigindo qualquer seleção de pré-estimativa que pode enviesar as estimativas. Além disso, estimativa LASSO é bastante atraente quando o tamanho da amostra é pequeno em comparação com o número de parâmetros a serem estimados. Em segundo lugar os resultados teóricos são derivados sem suposições estritas sobre o processo gerador da série, que se assume ser desconhecido. Outra grande vantagem desse método é não precisar estimar a verdadeira expectativa condicional. Este é um bom recurso da metodologia ArCo, já que normalmente os modelos são mal

especificados. Terceiro, não há restrição de balanceamento entre tratados e não tratados, ou seja, não há restrição a análise a uma única variável tratada. Ainda é possível, por exemplo, medir o impacto das intervenções em diversas variáveis da unidade tratada simultaneamente. Os modelos ArCo também permitem testes em vários momentos da variável de interesse. Quarto, a metodologia ArCo pode ser aplicada quando o tempo de intervenção é desconhecido, permitindo que seja estimado endogenamente o tempo de intervenção. Considere as hipóteses até a equação (6).

A metodologia ArCo propõe, $y_t^{(j)} = h(z_{1t}^j) \in \mathbb{R}^q, j \in \{0,1\}, h(\cdot)$ sendo uma função mensurável de z_{1t} e $\{\delta_t\}_{t=T_0}^T$ sendo uma sequência determinística. A função $h(\cdot)$ é uma função geral que permite intervenções na média, na variância, na covariância e etc. O método ArCo concentra-se na hipótese:

$$H_0: \Delta_T = \frac{1}{T-T_0+1} \sum_{t=T_0}^T \delta_t = 0 \quad (8)$$

Onde Δ_T representa o efeito médio do tratamento durante o período de tratamento. Não observamos $y_t^{(0)}$ para $t \geq T_0$, esse será o valor contrafactual, ou seja, qual seria o y_t na ausência da intervenção. Na primeira etapa do método ArCo, seja $z_{0t} = (z'_{2t}, \dots, z'_{nt})'$ e $Z_{0t} = (Z'_{2t}, \dots, Z'_{nt})'$ uma coleta de todas as unidades não tratadas até uma defasagem arbitrária $p \geq 0$. A dimensão de Z_{0t} depende do número de unidades, número de defasagens e número de variáveis por unidade. Considere agora o seguinte modelo para $y_t^{(0)}$:

$$y_t^{(0)} = \mathcal{M}_t + v_t \quad (9)$$

Com as únicas hipóteses de $E(v_t) = 0$ e \mathcal{M}_t sendo um mapeamento mensurável, não necessariamente uma função explícita, ou seja, podendo assumir qualquer forma funcional, como por exemplo, árvore de decisão, florestas randômicas, funções não lineares, modelos de dados em painel, funções temporais com diversas estruturas de dependência, etc. O primeiro passo do modelo ArCo é estimar a equação (9) utilizando as $T_0 - 1$ observações, haja vista que para $t < T_0$ temos $y_t = y_t^{(0)}$. Com o conjunto $T_1 = T_0 - 1$ e $T_2 = T - T_0 + 1$, é possível estimar $\widehat{\mathcal{M}}_{t,T_1} = \widehat{\mathcal{M}}_{t,T_1}(Z_{0t})$ e utilizá-lo para construção do contrafactual:

$$y_t^{(0)} = \begin{cases} y_t^{(0)}, & t = 1, \dots, T_0 \\ \widehat{\mathcal{M}}_{t,T_1}, & t = T_0, \dots, T \end{cases} \quad (10)$$

Finalmente o estimador ArCo é definido como:

$$\widehat{\Delta}_T = \frac{1}{T - T_0 + 1} \sum_{t=T_0}^T \widehat{\delta}_t \quad (11)$$

Onde $\widehat{\Delta}_T = y_t - y_t^{(0)}$.

A metodologia ArCo é uma abordagem em dois estágios de estimação, sendo o primeiro estágio a estimação de \mathcal{M}_t na amostra pré-intervenção e na segunda etapa estimamos $\widehat{\Delta}_T$ que é o impacto médio da intervenção.

Conforme destaca Carvalho et al. (2018), quando comparados aos estimadores DiD, as vantagens da metodologia ArCo são três. Primeiro, não precisamos que o número de unidades tratadas cresça. Na verdade, a situação laboriosa é quando há uma única unidade tratada. A segunda e mais importante diferença é que a metodologia ArCo foi desenvolvida para situações em que as $n - 1$ unidades não tratadas diferem substancialmente do tratado e não pode formar um grupo de controle mesmo após o condicionamento em um conjunto de

observáveis. Por fim, a metodologia ArCo funciona mesmo sem a hipótese de tendências paralelas.

Embora, os métodos ArCo e SCM construam um contrafactual em função de variáveis observadas de um grupo de pares, as duas abordagens têm diferenças importantes. Apenas elencando os pontos principais listados por Carvalho et al. (2018), primeiro, o método SCM depende de uma combinação convexa de pares para construir o contrafactual que, como apontado por Ferman e Pinto (2016), gera viés no estimador. Isso é claramente evidenciado em experimentos de simulação. A solução ArCo é uma função geral, possivelmente não linear. Mesmo no caso de linearidade, o método não impõe nenhuma restrição aos parâmetros. Por exemplo, a restrição de que os pesos nos métodos SCM são todos positivos também é uma forte restrição. Além disso, os pesos no método SCM são geralmente estimados usando médias de tempo das variáveis observadas para cada par. Portanto, toda a dinâmica da série temporal é removida e os pesos são determinados em um cenário de corte transversal puro. Em algumas aplicações do SCM método, o número de observações para estimar os pesos é muito menor do que o número de parâmetros a serem determinados. Por exemplo, Abadie and Gardeazabal (2003), os autores tem 13 observações para estimar 16 parâmetros.

Além disso, como destacado em Carvalho et al. (2018), o método SCM foi projetado para avaliar os efeitos da intervenção em uma única variável. Para avaliar os efeitos em um vetor de variáveis, o método deve ser aplicado várias vezes. A metodologia ArCo pode ser aplicada diretamente a um vetor de variáveis de interesse. Além disso, não há procedimento inferencial formal para teste de hipótese no método SCM, enquanto na metodologia ArCo, um método simples e uniforme teste válido e padrão pode ser aplicado. Uma última desvantagem do SCM, destacado em Ferman, Pinto, e Possebom (2016), o método SCM não oferece nenhum guia sobre a seleção de variáveis utilizadas para construção dos pesos que serão utilizados na criação dos valores contrafactuais.

Para fins de estimação utilizaremos os modelos lineares generalizados com penalização complexa, que combinam diferentes tipos de métodos de regularização ℓ_1 (LASSO), ℓ_2 (Regressão Ridge) e a combinação dessas duas (o elastic net), com algoritmo de estimação cíclico de coordenada descendente, conforme apresentado por Friedman et al (2010). Essa formulação garante estimar diferentes estrutura temporais da dinâmica das variáveis e unidades dos painéis utilizados para o estudo.

4. Resultados

4.1 Descrição, Tratamentos e Estatísticas Descritivas dos Dados

A construção da base de dados utilizada nesse estudo considerou a possibilidade de construção de um painel balanceado para os países selecionados que permitisse a implementação dos modelos de painel Dif-em-Dif, além da estimação dos modelos contrafactuais artificiais para dados em painel, bem como os modelos GARCH multivariados. A construção desse painel considerou, portanto a disponibilidade em diferentes fontes de informações de dados diários relativos aos fechamentos das bolsas, do número de casos, óbitos e recuperações pandemia do Covid-19, características específicas de cada país, etc. O resultado desse levantamento e construção de variáveis é detalhado na Tabela 1 no Apêndice.

O painel final de dados contempla dados diários do dia 22 de janeiro de 2020 ao dia 07 de agosto de 2020 perfazendo um total de 143 observações temporais para os seguintes países: Argentina, Brasil, Chile, Colômbia, Peru, México, EUA, Reino Unido, Alemanha, Suíça, Suécia, Itália, Espanha e Japão. A seleção desses países foi orientada pela disponibilidade completa dos dados de modelagem, tanto pandêmicos quanto financeiros, além dos custos e limites computacionais de estimação dos modelos propostos.

A partir dos dados financeiros de fechamento das bolsas de valores foi obtido o log retorno (retorno) e estimados 14 modelos GARCH DBEKK. Cada um desses modelos

GARCH multivariados combinaram a o retorno da bolsa brasileira ao retorno de cada um dos catorze demais países. Cada modelo DBEKK estimado gerou uma estimativa da volatilidade brasileira e da volatilidade do respectivo país, além do seu transbordamento para a volatilidade brasileira. Desse modo o painel de dados para os demais modelos tiveram como variável resposta: 1) a volatilidade estimada para cada país (Modelo para os estudos de volatilidades) e 2) o spillover de cada país para o Brasil (Modelo para os estudos de transbordamentos)². Os resultados dos modelos DBEKK estimados serão detalhados na próxima seção.

Para cada dia de volatilidade e spillover estimados foram construídas três medidas de evolução pandêmica: a taxa de casos por 1 milhão de habitantes, a taxa de óbitos por 1 milhão de habitantes e a taxa de recuperados por 1 milhão de habitantes. Número de medidas de distanciamento social, número de restrições de movimento, número de medidas de saúde pública e número de medidas socioeconômicas impostas pelos governos dos respectivos países trazem informação de outros diferentes traços da evolução pandêmica em seus diferentes estágios de desenvolvimento. Esses dados diários também compõem o painel final de estudo. Outra variável de estudo está relacionado a pandemia são: 1) Volume de pesquisa do Google (Google Trend) para o termo "coronavírus" e 2) Volume de pesquisa do Google para o termo "coronavírus" para cada país individualmente. Essas variáveis podem capturar potenciais indivíduos com sintomas iniciais em busca de informação e pode contribuir para o entendimento da dinâmica epidêmica.

Por fim foram construídas as variáveis dicotômicas para captura de efeitos contrafactuais nos modelos Dif-em-Dif. Diferentes efeitos foram testados, a Tabela 1 descreve cada um dos efeitos testados nessa classe de modelos:

Tabela 1 - Construção de Variáveis de Estimação dos Efeitos Dif-em-Dif.

Variável	Efeito Contrafactual
I_PAN_LOCK	Efeito médio contrafactual sobre a variável resposta, dos países que fizeram lockdown em relação aos países que não fizeram lockdown, durante a pandemia.
I_PAN_LATAM	Efeito médio contrafactual sobre a variável resposta, dos países latino americanos em relação aos demais países, durante a pandemia.
I_PAN_EUROPA	Efeito médio contrafactual sobre a variável resposta, dos países europeus em relação aos demais países, durante a pandemia.
I_PAN_AMNOR	Efeito médio contrafactual sobre a variável resposta, dos países norte americanos em relação aos demais países, durante a pandemia.
I_PAN_RENDA	Efeito médio contrafactual sobre a variável resposta, dos países de alta renda (classificação do Banco Mundial) em relação aos demais países, durante a pandemia.

² Cada um dos 14 modelos GARCH DBEKK gerou estimativas de volatilidade para bolsa de valores brasileira e seus respectivo transbordamento. Para composição do painel de estudos dos impactos Covid-19, a volatilidade brasileira foi construída da média dos 14 modelos estimados e o spillover a mediana dos 14 modelos estimados. A opção pela mediana para o spillover brasileiro evita correlações condicionais extremas.

I_PAN_DENS

Efeito médio contrafactual sobre a variável resposta, dos países de mais alta densidade demográfica (classificação do Banco Mundial) em relação aos demais países, durante a pandemia.

Nota: Todos esses efeitos são referentes aos países contidos na amostra. Muito embora os efeitos de todos os demais países sobre os países da amostra possam ser capturados na heterogeneidade estimada nos modelos de painel, os resultados devem ser considerados para amostra de países em questão.

Fonte: Elaboração própria.

Esses efeitos são construídos considerando o início da pandemia em cada país (I_PAN), definido como o dia a partir da primeira morte registrada por Covid-19. A descrição detalhada dessas características para cada país é detalhada na Tabela 2:

Tabela 2 - Descrição da presença de características estudadas por países

Variáveis utilizadas para construção dos Efeitos Dif-em-Dif						
Países	I_lockdown	I_DENS	I_RENDA	I_LATAM	I_EUROPA	I_AMNOR
Alemanha	1	0	1	0	1	0
Argentina	1	0	0	1	0	0
Brasil	1	0	0	1	0	0
Chile	1	1	1	1	0	0
Colômbia	1	1	0	1	0	0
Espanha	1	1	1	0	1	0
EUA	0	1	1	0	0	1
França	1	0	1	0	1	0
Itália	1	0	1	0	1	0
Japão	0	1	1	0	0	0
México	1	1	0	0	0	1
Peru	1	0	0	1	0	0
Reino Unido	1	1	1	0	1	0
Suécia	0	0	1	0	1	0
Suíça	0	0	1	0	1	0
Total (1):	11	7	10	5	7	2
Total (0):	4	8	5	10	8	13

Nota: A presença da característica é indicada pelo valor "1".

Fonte: Elaboração própria.

Com o estudo centrado na variância condicional e na correlação condicional, a serem estimadas via modelos GARCH multivariados, apresentamos nas próximas três tabelas a análise descritiva dos retornos (log retornos) das bolsas de valores dos países selecionados em três configurações temporais:

- 1) Estatísticas descritivas de todo período temporal;
- 2) Estatísticas descritivas de todo período pandêmico;
- 3) Estatísticas descritivas de todo período pré-pandêmico.

Tabela 3 - Estatísticas Descritivas para todo período Amostral

Países	T	Média	Mediana	Máximo	Mínimo	Variância	Desvio-Padrão	Assimetria	Curtose	Coef. Variação
Alemanha	143	-0,00045	0,00000	0,10414	-0,13055	0,00064	0,02539	-0,79613	6,38801	-56,52767
Argentina	143	0,00154	0,00000	0,09773	-0,15629	0,00149	0,03863	-0,77395	3,26260	25,13327
Brasil	143	-0,00099	0,00000	0,13023	-0,15994	0,00128	0,03573	-1,18197	6,48948	-36,12632
Chile	143	-0,00110	0,00000	0,07594	-0,15216	0,00072	0,02677	-1,85622	10,10552	-24,28275
França	143	-0,00144	0,00000	0,08056	-0,13098	0,00063	0,02501	-1,16511	5,73835	-17,32170
Reino Unido	143	-0,00159	0,00052	0,08667	-0,11512	0,00051	0,02260	-0,93316	5,69195	-14,21674
México	143	-0,00127	-0,00125	0,04744	-0,06638	0,00033	0,01807	-0,43778	1,51342	-14,17709
EUA	143	-0,00043	0,00040	0,10764	-0,13842	0,00088	0,02969	-0,64095	5,32164	-68,55326
Peru	143	-0,00098	0,00000	0,04064	-0,11009	0,00035	0,01881	-1,70785	8,24335	-19,16966
Japão	143	-0,00051	-0,00039	0,07731	-0,06274	0,00039	0,01964	0,30178	2,88584	-38,24764
Colômbia	143	0,00009	0,00000	0,38134	-0,13281	0,00183	0,04277	4,76294	45,84734	460,29769
Espanha	143	-0,00224	0,00029	0,07528	-0,15151	0,00067	0,02582	-1,48253	8,21564	-11,53261
Suíça	143	-0,00055	0,00028	0,06780	-0,10134	0,00036	0,01891	-1,12772	6,72461	-34,25299
Suécia	143	-0,00028	0,00138	0,06849	-0,11173	0,00049	0,02208	-0,98407	4,46071	-78,65381
Itália	143	-0,00136	0,00278	0,08549	-0,18541	0,00078	0,02792	-2,43008	14,83904	-20,52819

Fonte: Elaboração própria.

Tabela 4 - Estatísticas Descritivas para todo período Pandêmico

Países	T	Média	Mediana	Máximo	Mínimo	Variância	Desvio-Padrão	Assimetria	Curtose	Coef. Variação
Alemanha	110	0,00085	0,00038	0,10414	-0,13055	0,00076	0,02753	-0,86604	5,95330	32,34124
Argentina	106	0,00578	0,00384	0,09773	-0,15629	0,00145	0,03805	-0,65668	3,08112	6,58196
Brasil	103	0,00311	0,00086	0,09249	-0,10925	0,00069	0,02626	-0,35755	3,86694	8,44738
Chile	100	0,00260	0,00292	0,07594	-0,06005	0,00044	0,02096	0,08277	1,30200	8,07567
França	118	-0,00127	0,00043	0,08056	-0,13098	0,00072	0,02692	-1,12567	4,92864	-21,20892
Reino Unido	110	-0,00063	0,00067	0,08667	-0,11512	0,00060	0,02443	-0,99100	5,38605	-38,98872
México	101	0,00077	0,00000	0,04744	-0,05489	0,00028	0,01686	-0,16769	1,18660	21,75776
EUA	115	0,00067	0,00170	0,10764	-0,13842	0,00104	0,03229	-0,68062	4,48875	48,45476
Peru	101	0,00202	0,00137	0,03893	-0,04252	0,00021	0,01452	-0,21647	1,79046	7,17564
Japão	124	-0,00042	-0,00019	0,07731	-0,06274	0,00043	0,02073	0,28144	2,46691	-49,36556
Colômbia	100	0,00598	0,00054	0,38134	-0,05564	0,00198	0,04453	6,41479	52,06105	7,44532
Espanha	113	-0,00210	-0,00055	0,07528	-0,15151	0,00079	0,02807	-1,43532	7,22486	-13,37143
Suíça	110	0,00030	0,00028	0,06780	-0,10134	0,00039	0,01982	-1,19278	7,34007	65,19062
Suécia	105	0,00223	0,00270	0,06849	-0,05045	0,00043	0,02079	-0,10624	0,83665	9,30386
Itália	120	-0,00199	0,00248	0,08549	-0,18541	0,00090	0,02997	-2,29130	12,93360	-15,07747

Fonte: Elaboração própria.

Tabela 5 - Estatísticas Descritivas para todo período Pré-Pandêmico

Países	T	Média	Mediana	Máximo	Mínimo	Variância	Desvio-Padrão	Assimetria	Curtose	Coef.Variação
Alemanha	33	-0,00478	-0,00122	0,01797	-0,04089	0,00025	0,01593	-0,86271	0,00741	-3,33071
Argentina	37	-0,01062	-0,00703	0,07763	-0,14790	0,00146	0,03817	-1,31065	4,67165	-3,59312
Brasil	40	-0,01154	-0,00507	0,13023	-0,15994	0,00269	0,05184	-0,85451	3,17024	-4,49208
Chile	43	-0,00970	-0,00173	0,06898	-0,15216	0,00128	0,03577	-2,25540	8,02838	-3,68716
França	25	-0,00227	-0,00140	0,01743	-0,04025	0,00017	0,01291	-1,26675	2,05023	-5,69443
Reino Unido	33	-0,00480	-0,00266	0,01537	-0,03689	0,00022	0,01485	-0,82980	-0,16210	-3,09383
México	42	-0,00620	-0,00282	0,03877	-0,06638	0,00040	0,02006	-0,66518	1,51999	-3,23354
EUA	28	-0,00495	-0,00088	0,01663	-0,04518	0,00021	0,01437	-1,28089	1,69224	-2,90295
Peru	42	-0,00821	-0,00327	0,04064	-0,11009	0,00064	0,02521	-1,81913	5,90184	-3,07247
Japão	19	-0,00112	-0,00140	0,02348	-0,02051	0,00011	0,01036	0,31278	0,69470	-9,20929
Colômbia	43	-0,01360	-0,00016	0,02181	-0,13281	0,00123	0,03514	-2,32630	4,82218	-2,58383
Espanha	30	-0,00277	0,00130	0,01668	-0,04159	0,00022	0,01486	-1,20636	0,85917	-5,37606
Suíça	33	-0,00341	0,00028	0,01776	-0,04093	0,00024	0,01540	-1,07008	0,57994	-4,52202
Suécia	38	-0,00723	-0,00046	0,02116	-0,11173	0,00059	0,02427	-2,51514	8,60190	-3,35607
Itália	23	0,00191	0,00409	0,02578	-0,02334	0,00016	0,01266	-0,57005	-0,02024	6,61461

Fonte: Elaboração própria.

Os resultados da Tabela 3 mostram uma típica configuração de distribuição de retornos para cada país, apresentando os clássicos fatos estilizados, descritos nos trabalhos de Caldeira et. al.(2010), Maranhão e Oliveira (2017a) e Oliveira e Maranhão (2017): presença de assimetria e curtose, média próxima de zero e grande dispersão em torno dessa média. Considerando o período pandêmico, observamos a média dos retornos logarítmicos superiores, tanto do período pré-pandêmico quanto de todo período amostral, com exceção da Itália, que apresentou uma média maior para o período pré-pandêmico. A variância por outro lado, apresentou 6 países (Argentina, Brasil, Chile, México, Peru e Suécia) com valores pré-pandêmicos menores do que no período pandêmico. Quando consideramos os valores de curtose, observamos que os eventos extremos ocorreram com mais frequência no período pandêmico, com exceção da Itália, Espanha, Japão, França e Reino Unido.

Os resultados descritivos mostram os primeiros indícios de heterogeneidade dos efeitos pandêmicos na distribuição dos retornos, e por consequência na distribuição de variância condicional a ser estimada pelos modelos GARCH multivariados. Uma vez estimadas as variâncias e correlações condicionais, os estudos contrafactuais contribuíram para o entendimento dessa heterogeneidade dado as características pandêmicas e idiossincráticas de cada país no estudo.

4.2 Resultados dos Modelos GARCH Multivariados

Apresentamos nessa seção os resultados dos modelos GARCH multivariados estimados com a finalidade de obtenção das volatilidades dos países e seus spillovers para a volatilidade do mercado brasileiro. Para estimação desses componentes por país foram construídos os seguintes modelos:

Tabela 6 - Modelos para Estimação da Volatilidades e Spillovers por País.

Modelo	Países	Modelo Estimado
1	Brasil, Alemanha	DBEKK(1,1)
2	Brasil, Argentina	DBEKK(1,1)
3	Brasil, Chile	DBEKK(1,1)
4	Brasil, França	DBEKK(1,1)
5	Brasil, Reino Unido	DBEKK(1,1)
6	Brasil, México	DBEKK(1,1)
7	Brasil, EUA	DBEKK(2,1)
8	Brasil, Peru	DBEKK(1,1)
9	Brasil, Japão	DBEKK(1,1)
10	Brasil, Colômbia	DBEKK(1,1)
11	Brasil, Espanha	DBEKK(1,1)
12	Brasil, Suíça	DBEKK(1,1)
13	Brasil, Suécia	DBEKK(1,1)
14	Brasil, Itália	DBEKK(1,1)
15	Brasil	GARCH(2,1), Combinações

Fonte: Elaboração própria.

Considerando que a proposta de estimação de cada modelo consiste em um modelo bivariado, a opção inicial do modelo Diagonal BEKK é natural, pois sua formulação é mais parcimoniosa que outras versões BEKK, que são mais adequados para um conjunto de ativos maior que três e estruturas auto-regressivas e de médias-móveis mais elaboradas, todavia a escolha inicial do DBEKK, seria alterada na ausência de ajuste desse modelo, verificada pelos testes formais implementados. A escolha da ordem dos modelos DBEKK seguiu o procedimento apresentado em Oliveira e Maranhão (2017) com posterior verificação de ajuste do modelo mediante a eliminação de estrutura de autocorrelação dos resíduos e do quadrado dos resíduos por meio do teste LM³. A volatilidade dos primeiros 14 países é obtida diretamente de cada modelo estimado e validado. A volatilidade do Brasil por outro lado foi obtida pela comparação de dois métodos: a) estimação de um modelo GARCH univariado com a ordem do modelo obtida pela análise da ACF e PACF da série de log retorno do bovespa; b) média das volatilidades do Brasil dos 14 modelos DEKK estimados. O teste t não rejeitou a hipóteses de diferença estatisticamente significativa entre a volatilidade estimada por esses dois métodos, de modo que optamos pela utilização do método “b”. O spillover de volatilidade para o mercado brasileiro dos 14 primeiros países foi obtido diretamente dos modelos DBEKK, enquanto que o spillover geral para o Brasil foi obtido pela combinação da mediana da correlação condicional dos 14 modelos estimados em cada dia da amostra. O spillover geral do mercado brasileiro utilizando a mediana considerada nessa abordagem com vista à eliminação de eventuais valores extremos de correlação diária.

Para exemplificação de cada um dos modelos estimados apresentamos os resultados para o Modelo 7 (Modelo Brasil e EUA):

³ Teste do Multiplicador de Lagrange para autocorrelação com H₀: Ausência de autocorrelação na k-ésima defasagem.

Tabela 7 - Resultados do Modelo GARCH Multivariado

Modelo 7 - DBEKK(1,1)				
Parâmetros	Estimativas	DP	Estatísticas	P-valor
c11	0,010	0,002	6,320	0,000
c12	0,004	0,001	4,068	0,000
c22	0,007	0,002	3,435	0,000
a11	0,049	0,068	0,716	0,237
a12	0,152	0,087	1,735	0,041
a22	0,576	0,123	4,684	0,000
b11	0,594	0,134	4,442	0,000
b12	0,808	0,043	18,702	0,000
b22	0,827	0,041	20,203	0,000
AIC	-1.426,38			
BIC	-1.399,72			
LOG	722,19			

Teste LM para Autocorrelação dos Resíduos e Quadrado dos Resíduos -
Modelo 7

Defasagem	P-valor Resíduos		P-valor Quadrado dos Resíduos	
	Volatilidade 1	Volatilidade 2	Volatilidade 1	Volatilidade 2
1	0,294	0,702	0,322	0,271
2	0,371	0,714	0,215	0,521
3	0,579	0,828	0,352	0,553
4	0,477	0,919	0,517	0,689
5	0,561	0,915	0,669	0,310
6	0,691	0,947	0,630	0,299
7	0,351	0,758	0,683	0,299
8	0,434	0,370	0,730	0,357
9	0,380	0,113	0,396	0,389
10	0,413	0,187	0,428	0,452


Nota: H_0 : Ausência de Autocorrelação na k-ésima defasagem.

Fonte: Elaboração própria.

Os resultados⁴ apresentados na Tabela 7 mostram todos os parâmetros do modelo DBEKK estatisticamente significantes, exceto o parâmetro de média-móvel “a11”, referente a parcela da primeira defasagem do resíduo da volatilidade do mercado brasileiro. Todos os parâmetros auto-regressivos (b11,b12 e b22) foram estatisticamente significantes, assim como os parâmetros de assimetria. Os testes LM para os resíduos e quadrado dos resíduos confirma o ajuste adequado do modelo DBEKK(1,1) na estimação das variâncias condicionais de Brasil e EUA e correlação condicional entre esses países. Apresentamos na Figura 1 a correlação condicional (spillover) e volatilidades estimada nesse modelo:

⁴ Os resultados dos modelos estimados estão contidos no Apêndice.

Figura 1 – Volatilidades e Spillover de Brasil e EUA.



Fonte: Elaboração própria.

Os resultados da Figura 1 indicam que um aumento expressivo de volatilidade tanto no Brasil quanto nos EUA entre metade do mês de março e início do mês de abril, um período coincidente com a aceleração pandêmica. A correlação condicional também sofre uma brusca elevação nesse período, e decai acentuadamente após o dia 8 de abril. Dessa forma todos os modelos foram estimados formando dois painéis de estudo: painel de volatilidades e painel de spillovers. A combinação dessas estimativas as variáveis pandêmicas, de movimentação e de efeitos Dif-em-Dif, permitem implementar modelos de inferência contrafactual. Para todas covariáveis assumimos, de maneira contundente, a hipótese de exogeneidade estrita, haja vista que não há razões objetivas para acreditar que qualquer volatilidade ou spillover possa apresentar endogeneidade com a pandemia e sua dinâmica. Dessa forma, tanto os modelos de dados em painel Dif-em-Dif, quanto os modelos de painéis temporais de contrafactuais artificiais podem ser estimado.

4.3 Resultados dos Modelos de Dados em Painel de Diferenças-em-Diferenças

Apresentamos nessa seção os resultados dos modelos de dados em painel Dif-em-Dif considerando dois escopos de estudos:

- a) Estudo contrafactual das volatilidades estimadas;
- b) Estudo contrafactual dos spillovers estimados para o mercado brasileiro.

Uma importante propriedade para utilização de modelos lineares que combinam séries de tempo diz respeito à estacionaridade. Negligenciar tal propriedade faz com que quaisquer resultados inferenciais possam ser espúrios e, portanto não representando a realidade do fenômeno. Essa preocupação evoluiu na literatura econometrica para a extensão dos tradicionais testes de raiz unitária para o contexto de dados em painel. Nesse sentido uma das

principais motivações em adequar os testes de raiz unitária para painéis foi a possibilidade de aumento do poder do teste, ponto no qual, os testes para uma única série temporal, sofreram por muito tempo. Dentre algumas possibilidades de testes de raiz unitária para dados de painel, utilizamos nesse estudo o teste do tipo Fisher que combina os p-valores dos testes de raiz unitária unidade-específicos usando os quatro métodos propostos por Choi (2001). A hipótese nula sendo testada por estes métodos é que todas as unidades do painel contêm uma raiz unitária. Para um número finito de unidades, a alternativa é que pelo menos uma unidade seja estacionária. Com a finalidade de inferência contrafactual por meio de modelos de painéis de diferenças-em-diferenças, apresentamos na Tabela 8 os resultados dos testes de raiz unitária para todas as variáveis que serão utilizadas no estudo.

Tabela 8 - Teste do tipo Fisher para estacionariedade de Dados em Painel

Teste	Estatística	P-valor
Volatilidade	Pm = -9.1853	0.01
Spillover	Pm = -8.2041	0.01
NR_CASOSMIL	Pm = -5.7538	0.01
NR_OBITOSMIL	Pm = -5.0936	0.01
NR_RECML	Pm = -5.6177	0.01
soc_dist	Pm = -4.6168	0.01
mov_rest	Pm = -5.6628	0.01
pub_health	Pm = -3.9031	0.01383
gov_soc_econ	Pm = -3.8065	0.01866
gtrends_score	Pm = -6.9457	0.01

Nota: Para todas as variáveis foram testadas diferentes defasagens: 2, 5 e 10. As conclusões não se alteram e reportamos os resultados para a 10ª defasagem.

Fonte: Elaboração própria.

As conclusões dos testes, mesmo considerando diferentes defasagens, indicam séries estacionárias em nível, sempre rejeitando a hipótese de presença de raiz unitária. Dessa forma, temos a evidência de estacionariedade que nos permite utilizar os métodos tradicionais de estimação de dados em painel.

4.3.1 Resultados dos Modelos de Dados em Painel de Diferenças-em-Diferenças para Volatilidade

Partindo de uma abordagem de hipóteses mais restritas para modelos mais gerais, estimamos em um primeiro momento um painel Pooling para a volatilidade dos países da amostra, com a forte hipótese de não haver heterogeneidade individual, e os parâmetros são constantes no tempo. Os resultados desse primeiro modelo estão detalhados na Tabela 9 a seguir.

Os resultados desse modelo tem significância global validada pelo teste F com uma parcela de 33% da variabilidade da volatilidade dos países, no período amostral, explicada. Considerando os parâmetros estimados, observamos que, sendo validas as hipóteses desse modelo, o número de casos por 1 milhão/hab, gerou aumentos médios estatisticamente significantes de volatilidade, enquanto o número de recuperados e de óbitos, redução media.

Medidas de distanciamento social e restrições e de saúde pública também reduzem em média a volatilidade dos países, enquanto medidas de restrições de movimento e sócio-econômicas e pesquisas no Google, apresentam aumento médio, estatisticamente significantes de volatilidade. Considerando as variáveis de efeitos contrafactuais, apenas três efeitos Dif.-em-Dif, dentre os seis, foram estatisticamente significantes. Países que não adotaram alguma

Tabela 9 - Modelo de Dados em Painel Dif-em-Dif para Volatilidade dos Países e efeitos Covid-19

Modelo Pooling - Parâmetros Estimados				
	Estimativa	Desv.Pad	t valor	Pr(> t)
(Intercepto)	-4.1798e-04	2.8611e-04	-1.4609	0.1441812
NR_CASOSMIL	5.4004e-08	2.4408e-08	2.2126	0.0270325 *
NR_OBITOSMIL	-4.8157e-07	2.6836e-07	-1.7945	0.0728729 .
NR_RECMIIL	-7.9094e-08	2.6337e-08	-3.0031	0.0027037 **
soc_dist	-2.3711e-05	5.0435e-06	-4.7013	2.751e-06 ***
mov_rest	3.1001e-05	8.1593e-06	3.7995	0.0001491 ***
pub_health	-7.0969e-06	2.2935e-06	-3.0944	0.0019980 **
gov_soc_econ	1.0914e-05	2.9832e-06	3.6586	0.0002598 ***
gtrends_score	3.4372e-05	1.5392e-06	22.3305	< 2.2e-16 ***
gtrends_country_score	-7.5906e-07	1.5171e-06	-0.5003	0.6168809
I_lockdown	6.5783e-04	1.6298e-04	4.0363	5.622e-05 ***
I_LATAM	3.3570e-04	3.1344e-04	1.0710	0.2842707
I_EUROPA	-5.6226e-04	2.8454e-04	-1.9761	0.0482760 *
I_AMNOR	4.2607e-04	3.0651e-04	1.3900	0.1646606
I_RENDA	5.3053e-04	1.7842e-04	2.9735	0.0029772 **
I_DENS	-4.5870e-04	1.0791e-04	-4.2508	2.222e-05 ***
I_PAN	-8.1854e-05	3.4042e-04	-0.2405	0.8100043
I_PAN_LOCK	-3.0853e-04	1.7802e-04	-1.7331	0.0832228 .
I_PAN_LATAM	-2.2519e-04	3.6479e-04	-0.6173	0.5370975
I_PAN_EUROPA	6.8046e-04	3.1759e-04	2.1426	0.0322586 *
I_PAN_AMNOR	1.0365e-04	3.6905e-04	0.2809	0.7788404
I_PAN_RENDA	-5.9811e-04	2.2766e-04	-2.6272	0.0086701 **
I_PAN_DENS	6.5017e-04	1.2726e-04	5.1090	3.528e-07 ***
OBS		2,145		
R2		0.343		
R2 ajustado		0.336		
Estatística F		50.2815 com 22 e 2122 GL, p-valor: < 2,22e-16		

Nota: 0 '***' 0,001 '**' 0,01 '*' 0,05 '.' 0,1 ' ' 1

Fonte: Elaboração própria.

medida de lockdown, teriam tido uma menor volatilidade, caso tivessem adotado uma medida de lockdown, dessa forma nesse modelo, existe de fato uma efeito redutor de volatilidade na adoção de políticas de lockdown. Países de menor renda, também teriam uma menor volatilidade, caso tivessem uma maior renda, conforme a significância estatística de I_PAN_RENDA. Países de baixa densidade demográfica, também teria maiores volatilidades,

caso tivessem maior densidade demográfica, da mesma forma que países não europeus, teriam maior volatilidade, caso estivessem na Europa. As hipóteses desse modelo são extremamente fortes e sugerem cautela com essas evidências. Uma maneira de flexibilizar tais restrições é a utilização dos modelos de efeitos fixos, que assume que características individuais dos países (heterogeneidade individual) pode ser estimada para cada país da amostra. Essa abordagem permite modelar diferenças no comportamento individual dos países, os parâmetros ainda constantes no tempo, mas variando de país para país. O primeiro de efeito fixo estimado, também conhecido como LSDV (*Least Square Dummy Variable*), tem seus resultados estimados apresentados na Tabela 10.

Tabela 10 - Modelo de Dados em Painel Dif-em-Dif para Volatilidade dos Países e efeitos Covid-19

Modelo de Efeitos Fixos (LSDV) - Parâmetros Estimados					
	Estimativa	Desv.Pad	t valor	Pr(> t)	
NR_CASOSMIL	7.956e-08	2.675e-08	2.974	0.002968	**
NR_OBITOSMIL	-3.335e-07	2.863e-07	-1.165	0.244141	
NR_RECMIIL	-7.387e-08	2.864e-08	-2.579	0.009984	**
soc_dist	-1.256e-05	5.926e-06	-2.119	0.034183	*
mov_rest	1.372e-05	8.646e-06	1.587	0.112769	
pub_health	-1.294e-05	2.608e-06	-4.962	7.54e-07	***
gov_soc_econ	1.388e-05	3.719e-06	3.731	0.000196	***
gtrends_score	3.318e-05	1.490e-06	22.269	< 2e-16	***
gtrends_country_score	-9.950e-06	3.528e-06	-2.820	0.004840	**
I_lockdown	4.745e-04	3.049e-04	1.556	0.119813	
I_LATAM	-3.090e-05	1.940e-04	-0.159	0.873424	
I_EUROPA	-1.127e-04	2.903e-04	-0.388	0.698023	
I_AMNOR	9.269e-04	3.385e-04	2.739	0.006222	**
I_RENDA	2.661e-05	2.765e-04	0.096	0.923341	
I_DENS	-3.206e-04	1.695e-04	-1.891	0.058750	.
I_PAN	2.972e-04	3.275e-04	0.907	0.364291	
I_PAN_LOCK	-3.551e-04	1.703e-04	-2.085	0.037170	*
I_PAN_LATAM	-5.097e-04	3.496e-04	-1.458	0.145013	
I_PAN_EUROPA	5.759e-04	3.072e-04	1.875	0.060959	.
I_PAN_AMNOR	4.767e-04	3.548e-04	1.344	0.179176	
I_PAN_RENDA	-8.610e-04	2.183e-04	-3.944	8.26e-05	***
I_PAN_DENS	7.230e-04	1.253e-04	5.771	9.06e-09	***
factor(Pais)Alemanha	1.450e-04	2.950e-04	0.491	0.623125	
factor(Pais)Argentina	9.923e-04	1.251e-04	7.929	3.55e-15	***
factor(Pais)Brasil	6.530e-04	1.610e-04	4.055	5.20e-05	***
factor(Pais)Chile	9.223e-04	2.907e-04	3.172	0.001533	**
factor(Pais)Colombia	1.105e-03	1.283e-04	8.611	< 2e-16	***
factor(Pais>Espanha	6.520e-04	1.489e-04	4.378	1.26e-05	***
factor(Pais)EUA	1.689e-04	2.951e-04	0.512	0.726321	
factor(Pais)França	5.255e-04	2.033e-04	2.585	0.009818	**
factor(Pais)Itália	1.198e-03	2.041e-04	5.866	5.16e-09	***

factor(Pais)Japão	1.534e-04	2.053e-04	0,481	0.543289	
factor(Pais)México	5.430e-04	1.509e-04	4.066	4.11e-05	***
factor(Pais)Peru	1.176e-03	2.078e-04	5.761	5.01e-09	***
factor(Pais)Reino Unido	1.799e-04	2.761e-04	0.972	0.823357	
factor(Pais)Suécia	8.125e-04	2.989e-04	3.512	0.001477	**
factor(Pais)Suíça	8.022e-04	2.811e-04	3.311	0.001651	**
OBS		2,145			
R2		0.5689			
R2 ajustado		0.5628			
Estatística F		93.05	com 30 e 2115 GL,	p-valor: <	
		2,22e-16			

Nota: 0 '***' 0,001 '**' 0,01 '*' 0,05 '.' 0,1 ' ' 1

Fonte: Elaboração própria.

Os resultados do modelo LSDV, assim como o modelo Pooling, tem significância global confirmada pelo teste F, contudo com um percentual maior de variância explicada no conceito de R^2 , de 57%. Os resultados dos parâmetros estimados no modelo Pooling, continuaram validos no modelo LSDV, com exceção da covariável `gtrends_country_score`, com efeitos negativos na volatilidade dos países, o que indica que aumentos médios nas buscas no Google pela palavra “coronavirus” no respectivo país, estão associadas a menores volatilidades. Outro novo resultados desse modelo, mostra que o número de óbitos por 1 milhão/hab não tem mais significância estatística para volatilidade dos países. Os efeitos causais estimados por Dif.-em-Dif, também se mantiveram em relação ao modelo sem heterogeneidade individual, tendo mesmo sinais e interpretações. A heterogeneidade individual nesse modelo tem por hipótese ser uma característica intrínseca do país, não sendo dada por um choque aleatório (Modelos de Efeitos Aleatórios), sendo estimado pelo parâmetros interceptos individuais. Os resultados da Tabela 10 apresentam evidências de que a heterogeneidade individual está presente, de maneira estatisticamente significativa, para 11 países. Para quatro nações (EUA, Alemanha, Japão e Reino Unido), a volatilidade não apresentou comportamento individual estatisticamente significativa, o fato de serem grandes economias com mercados financeiros, pode ser a explicação desse resultado, fazendo que esses países, causem, no sentido de Granger, as volatilidades dos demais países.

Outra abordagem de estimação de efeitos fixos, conhecida como Within, extrai a média temporal das variáveis de seus respectivos países e então re-estima o painel. Os resultados desse método está detalhado na Tabela 11.

Tabela 11 - Modelo de Dados em Painel Dif-em-Dif para Volatilidade dos Países e efeitos Covid-19

Modelo de Efeitos Fixos (Within) - Parâmetros Estimados					
	Estimativa	Desv.Pad	t valor	Pr(> t)	
NR_CASOSMIL	7.9561e-08	2.6748e-08	2.9744	0.0029685	**
NR_OBITOSMIL	-3.3351e-07	2.8627e-07	-1.1650	0.2441412	
NR_RECMIIL	-7.3866e-08	2.8645e-08	-2.5787	0.0099838	**
soc_dist	-1.2559e-05	5.9261e-06	-2.1193	0.0341833	*
mov_rest	1.3717e-05	8.6459e-06	1.5865	0.1127688	
pub_health	-1.2943e-05	2.6084e-06	-4.9620	7.536e-07	***
gov_soc_econ	1.3876e-05	3.7187e-06	3.7313	0.0001955	***
gtrends_score	3.3178e-05	1.4899e-06	22.2693	< 2.2e-16	***

I_PAN	2.9718e-04	3.2750e-04	0.9074	0.3642913
I_PAN_LOCK	-3.5512e-04	1.7031e-04	-2.0852	0.0371700 *
I_PAN_LATAM	-5.0971e-04	3.4962e-04	-1.4579	0.1450126
I_PAN_EUROPA	5.7590e-04	3.0718e-04	1.8748	0.0609589 .
I_PAN_AMNOR	4.7672e-04	3.5477e-04	1.3437	0.1791759
I_PAN_RENDA	-8.6101e-04	2.1829e-04	-3.9444	8.261e-05 ***
I_PAN_DENS	7.2305e-04	1.2530e-04	5.7706	9.060e-09 ***
OBS	2,145			
R2	0.32567			
R2 ajustado	0.31643			
Estadística F	68.0978 com 15 e 2115 GL, p-valor: < 2,22e-16			

Nota: 0 '***' 0,001 '**' 0,01 '*' 0,05 '.' 0,1 ' ' 1

Fonte: Elaboração própria.

Observe que para esse modelo variáveis constantes no tempo, tem parâmetros nulos, haja vista o primeiro passo de extração da média temporal. Os resultados gerais se mantêm em relação a versão LSDV, com significância global, os mesmos efeitos contrafactuais estatisticamente significantes, permanecem sem efeito sobre a volatilidade: o número de óbitos por 1 milhão/hab, medidas de restrição de movimentação e efeitos contrafactuais associados a países latino e norte americanos. Todos os resultados apresentados são válidos apenas na condição de que as hipóteses dos modelos estejam ativas. Falhas nas hipóteses geram inferências e/ou estimativas incorretas, desse modo submetemos os modelos estimados a uma bateria de vários testes que tornem suas conclusões mais confiáveis, e dessa forma apresentamos os resultados de todos esses testes na Tabela 12.

Tabela 12 - Testes em Modelos de Dados em Painel

Teste	Estadística	Graus de Liberdade	P-valor
Teste F para efeitos individuais	F = 32.304	gl1 = 7, gl2 = 2115	< 2.2e-16
Breusch-Pagan studentizado	BP = 203.94	gl = 22	< 2.2e-16
Teste Breusch-Godfrey/Wooldridge para correlação serial em modelos de painel	chisq = 1426.3	gl = 143	< 2.2e-16
Teste Pesaran para dependencia Cross-Sectional em Painéis	z = 39.966	-	< 2.2e-16
Teste do tipo Fisher para estacionaridade do resíduo do Painel	Pm = -11.973	-	0.01
Teste de Wooldridge para efeitos individuais não-observáveis	z = 2.0426	-	0.04109

Fonte: Elaboração própria.

O primeiro teste coloca a hipótese do modelo Pooling a prova, ou seja, a existência ou não de heterogeneidade individual. O p-valor aponta para a existência de efeitos individuais estatisticamente significantes, rejeitando a hipótese nula do teste. Dessa forma as evidências dos modelos de efeitos fixos devem ser visto com maior segurança e, portanto serão aplicados os demais testes para o modelo Within, dado sua parcimônia em termos de parâmetros estimados, resultado em um maior grau de liberdade, importante característica em modelos lineares. O teste Breusch-Pagan na sequência, não rejeita a hipótese de heterocedasticidade, ou seja, a variância não é constante e, portanto as inferências utilizando o teste t sobre parâmetros estimados estão comprometidos. O teste Breusch-Godfrey/Wooldridge apresenta evidência estatística de presença de autocorrelação serial, que tem efeitos similares a da heterocedasticidade sobre a inferência de parâmetros, novamente comprometendo a inferência dos testes t. A dependência *cross-sectional* se apresenta em painéis com longas séries de tempo. O teste de Pesaran é utilizado para esse tipo de dependência, sendo que a hipótese nula é de que os resíduos através dos indivíduos não estão correlacionados, dessa forma temos evidência de existe uma estrutura de dependência entre os resíduos dos países da amostra. O teste do tipo Fisher para estacionaridade dos resíduos garante que bom ajuste do modelo linear de dados em painel. Por fim o teste de Wooldridge para efeitos individuais não observáveis está no limiar (p-valor de 0,041) de rejeição da hipótese nula de ausência desses efeitos individuais não observáveis.

Heteroscedasticidade e autocorrelação serial são problemas bastante recorrentes em modelos de Dif-em-Dif. Uma prática comum nestas circunstâncias é empregar um estimador consistente da matriz de covariâncias a fim de formular teste de hipóteses assintoticamente válidos. Diante das evidências de heterocedasticidade e autocorrelação serial no modelo Within reestimamos esse modelo considerando a correção proposta por Cribari-Neto (2004) ao estimador HC4 amplamente empregado e apresentado por Arellano (2003,1987). Esse estimador é consistente tanto na presença de heteroscedasticidade quando de autocorrelação serial dos erros além de considerar o contexto de pequenas amostras cross-section e possíveis pontos de alavancagem. Os resultados do modelo Within robusto a quebra das hipóteses de heterocedasticidade e autocorrelação serial é apresentado na Tabela 13.

Tabela 13 - Modelo de Dados em Painel Dif-em-Dif para Volatilidade dos Países e efeitos Covid-19

Modelo de Efeitos Fixos (Within+Corr. Het.Auto-Corr.) - Parâmetros Estimados				
	Estimativa	Desv.Pad	t valor	Pr(> t)
NR_CASOSMIL	7.9561e-08	2.5631e-08	2.9987	0.002155 **
NR_OBITOSMIL	-3.3351e-07	1.0021e-06	-0.3328	0.739315
NR_RECMIL	-7.3866e-08	2.6121e-08	-2.6712	0.009031 **
soc_dist	-1.2559e-05	1.1345e-05	-1.1070	0.268420
mov_rest	1.3717e-05	3.1946e-05	0.4294	0.667694
pub_health	-1.2943e-05	6.6856e-06	-1.9359	0.053012 .
gov_soc_econ	1.3876e-05	1.3814e-05	1.0044	0.315282
gtrends_score	3.3178e-05	1.0463e-05	3.1709	0.001541 **
I_PAN	2.9718e-04	4.4201e-04	0.6723	0.501435
I_PAN_LOCK	-3.5512e-04	1.6120e-04	-2.0922	0.039210 *
I_PAN_LATAM	-5.0971e-04	4.4967e-04	-1.1335	0.257122
I_PAN_EUROPA	5.7590e-04	5.7942e-04	0.9939	0.320373
I_PAN_AMNOR	4.7672e-04	6.4504e-04	0.7390	0.459962

I_PAN_RENDA	-8.6101e-04	5.6123e-04	-1.5341	0.125145
I_PAN_DENS	7.2305e-04	5.3414e-04		
1.3537	0.175986			

Nota: 0 ‘****’ 0,001 ‘***’ 0,01 ‘**’ 0,05 ‘.’ 0,1 ‘.’ 1

Fonte: Elaboração própria.

A correção da heterocedasticidade e autocorrelação serial altera significativamente o desvio-padrão dos parâmetros estimados e, portanto também toda inferência dos testes t. Os novos resultados apenas quatro variáveis são estatisticamente significantes: o número de casos por 1 milhão/hab, com efeito médio positivo na volatilidade dos países, o número de recuperados por 1 milhão/hab com sinal negativo, o número de medidas de saúde pública com efeito negativo na volatilidade e o número de busca mundiais no Google da palavra “coronavirus”. Dentre os efeitos contrafactuais apenas o lockdown apresenta significância estatística, com sinal negativo, o que se traduz em dizer que os países não adotaram medidas de lockdown, teriam tido menor volatilidade.

4.3.2 Resultados dos Modelos de Dados em Painel de Diferenças-em-Diferenças para Spillovers

Seguindo as mesmas etapas de modelagem da seção 4.3.1, apresentamos nessa seção os resultados de inferência causal para os transbordamentos (spillovers) de volatilidade o mercado financeiro brasileiro. Conforme os resultados da Tabela 8 o spillover também é estacionário no contexto de dados em painel e portanto estimamos inicialmente o modelo Pooling de hipóteses mais restritas sobre a heterogeneidade individual, sendo seus resultados apresentados na Tabela 14.

Tabela 14 - Modelo de Dados em Painel Dif-em-Dif para Spillovers dos Países e efeitos Covid-19

Modelo Pooling - Parâmetros Estimados				
	Estimativa	Desv.Pad	t valor	Pr(> t)
(Intercept)	2.9760e-01	3.4531e-02	8.6184	< 2.2e-16 ***
NR_CASOSMIL	-7.8312e-06	2.9458e-06	-2.6584	0.0079104 **
NR_OBITOSMIL	-1.1023e-04	3.2389e-05	-3.4034	0.0006778 ***
NR_RECMIIL	1.9527e-05	3.1788e-06	6.1428	9.652e-10 ***
soc_dist	1.2068e-04	6.0872e-04	0.1983	0.8428654
mov_rest	-4.0643e-03	9.8477e-04	-4.1272	3.814e-05 ***
pub_health	1.4859e-03	2.7681e-04	5.3681	8.825e-08 ***
gov_soc_econ	-4.3063e-03	3.6006e-04	-11.9602	< 2.2e-16 ***
gtrends_score	1.7502e-03	1.8578e-04	9.4210	< 2.2e-16 ***
gtrends_country_score	-8.1433e-04	1.8310e-04	-4.4475	9.137e-06 ***
I_lockdown	8.1849e-02	1.9670e-02	4.1611	3.294e-05 ***
I_LATAM	1.8866e-01	3.7830e-02	4.9872	6.625e-07 ***
I_EUROPA	2.1844e-01	3.4341e-02	6.3608	2.451e-10 ***
I_AMNOR	3.1316e-01	3.6994e-02	8.4651	< 2.2e-16 ***
I_RENDA	-6.3516e-02	2.1534e-02	-2.9496	0.0032169 **
I_DENS	3.6593e-02	1.3024e-02	2.8097	0.0050037 **

I_PAN	8.7692e-02	4.1086e-02	2.1343	0.0329295	*
I_PAN_LOCK	-4.2959e-02	2.1486e-02	-1.9994	0.0456962	*
I_PAN_LATAM	-4.5264e-02	4.4027e-02	-1.0281	0.3040238	
I_PAN_EUROPA	1.3186e-01	3.8330e-02	3.4401	0.0005928	***
I_PAN_AMNOR	1.4905e-01	4.4542e-02	3.3462	0.0008335	***
I_PAN_RENDA	-5.7720e-02	2.7477e-02	-2.1007	0.0357864	*
I_PAN_DENS	-7.6051e-02	1.5359e-02	-4.9514	7.948e-07	***
OBS		2,145			
R2		0.44589			
R2 ajustado		0.44015			
Estatística F		77.6167	com 22 e 2122 GL,	p-	
		valor:	< 2,22e-16		

Nota: 0 '***' 0,001 '**' 0,01 '*' 0,05 '.' 0,1 ' ' 1

Fonte: Elaboração própria.

Os resultados do modelo Pooling para spillovers apresenta significância global pelo teste F com 45% da variabilidade dos transbordamentos explicada no conceito R^2 . Dentre todos os parâmetros estimados apenas dois não se mostraram estatisticamente significantes: o número de medidas de distanciamento social e o efeito Dif-em-Dif para países latinos americanos. Comparativamente aos resultados dos modelos para o painel de volatilidade, os resultados dos modelos para spillovers sofrem impactos negativos do aumento do número de casos e óbitos, do número de restrições de movimentação, das medidas sócio econômicas, e das buscas globais no Google da palavra “coronavirus”. Por outro lado, a correlação condicional para o mercado brasileiro aumenta com o número de recuperados, número de medidas saúde pública e de buscas regionais no Google pela palavra “coronavirus”. Dentre os efeitos causais, apenas o efeito de ter sido um país do norte da America tem valor positivo o que indica que o transbordamento para o mercado brasileiro, teria aumentado caso os demais países fossem da America do norte. Todos os demais efeitos contrafactuais são negativos e seguem a mesma interpretação, contudo destacamos o efeito lockdown, onde o transbordamento de volatilidade teria sido menor, caso os países que não tiveram lockdown tivessem adotado tal política. Esses resultados novamente, carecem de flexibilização de suas hipóteses e validações de testes para dados em painel para assegurar essas inferências. Considerando modelos de efeitos fixos, a abordagem LSDV foi estimada e seus resultados apresentados na Tabela 15.

Tabela 15 - Modelo de Dados em Painel Dif-em-Dif para Spillovers dos Países e efeitos Covid-19

Modelo de Efeitos Fixos (LSDV) - Parâmetros Estimados				
	Estimativa	Desv.Pad	t valor	Pr(> t)
NR_CASOSMIL	-1.302e-06	3.317e-06	-0.393	0.694666
NR_OBITOSMIL	-1.542e-04	3.550e-05	-4.344	1.47e-05 ***
NR_RECMIL	1.216e-05	3.553e-06	3.422	0.000633 ***
soc_dist	-2.008e-03	7.350e-04	-2.732	0.006340 **
mov_rest	-1.623e-03	1.072e-03	-1.513	0.130349
pub_health	9.485e-04	3.235e-04	2.932	0.003405 **
gov_soc_econ	-3.811e-03	4.612e-04	-8.264	2.46e-16 ***
gtrends_score	1.973e-03	1.848e-04	10.677	< 2e-16 ***

gtrends_country_score	-1.424e-03	4.375e-04	-3.254	0.001155	**
I_lockdown	4.363e-02	3.782e-02	1.154	0.248752	
I_LATAM	5.749e-01	2.406e-02	23.899	< 2e-16	***
I_EUROPA	2.824e-01	3.601e-02	7.843	6.90e-15	***
I_AMNOR	3.468e-01	4.198e-02	8.262	2.50e-16	***
I_RENDA	1.859e-01	3.429e-02	5.422	6.57e-08	***
I_DENS	8.133e-02	2.102e-02	3.869	0.000113	***
I_PAN	6.458e-02	4.062e-02	1.590	0.111992	
I_PAN_LOCK	-3.396e-02	2.112e-02	-1.608	0.108040	
I_PAN_LATAM	-5.549e-02	4.336e-02	-1.280	0.200789	
I_PAN_EUROPA	1.300e-01	3.810e-02	3.413	0.000655	***
I_PAN_AMNOR	1.607e-01	4.400e-02	3.651	0.000267	***
I_PAN_RENDA	-4.783e-02	2.707e-02	-1.767	0.077451	.
I_PAN_DENS	-6.568e-02	1.554e-02	-4.227	2.47e-05	***
factor(Pais)Alemanha	4.697e-02	3.659e-02	1.284	0.199387	
factor(Pais)Argentina	-1.314e-02	1.552e-02	-0.847	0.397221	
factor(Pais)Brasil	-7.211e-02	1.997e-02	-3.610	0.000313	***
factor(Pais)Chile	-3.233e-01	3.605e-02	-8.966	< 2e-16	***
factor(Pais)Colombia	-1.280e-01	1.591e-02	-8.045	1.43e-15	***
factor(Pais)Espanha	3.816e-02	1.847e-02	2.066	0.038960	*
factor(Pais)EUA	4.519e-02	3.547e-02	1.024	0.219387	
factor(Pais)França	7.556e-02	2.522e-02	2.996	0.002764	**
factor(Pais)Itália	8.307e-02	2.532e-02	3.281	0.001051	**
factor(Pais)Japão	3.921e-02	1.751e-02	2.045	0.037212	*
factor(Pais)México	-1.412e-02	1.982e-02	-0.637	0.457231	
factor(Pais)Peru	-1.313e-02	1.991e-02	-0.611	0.477255	
factor(Pais)Reino Unido	3.921e-02	1.751e-02	2.045	0.037212	*
factor(Pais)Suécia	-1.415e-02	1.651e-02	-0.831	0.399219	
factor(Pais)Suíça	-1.415e-02	1.651e-02	-0.831	0.399219	
OBS		2,145			
R2		0.9457			
R2 ajustado		0.9449			
Estatística F		1227 com 15 e 2115 GL, p-valor: <			
		2,22e-16			

Nota: 0 '***' 0,001 '**' 0,01 '*' 0,05 '.' 0,1 ' ' 1

Fonte: Elaboração própria.

Os resultados do modelo LSDV apresenta significância global pelo teste F com uma elevação substancial do R2, chegando a 95%, o que pode está ocorrendo pela redução de graus de liberdade, característico desse modelo. Os parâmetros das variáveis pandêmicas permaneceram com mesmos sinais e também significativos exceto o número de casos em 1 milhão/hab. Número de medidas de distanciamento social passou ser estatisticamente significativo nesse modelo, enquanto o número de restrições de movimentação, perdeu significância estatística. As demais covariáveis permaneceram com mesma interpretação de impacto sobre o spillover e estatisticamente significantes. Nesse modelo os efeitos causais de lockdown e países latino americanos deixaram de ser estatisticamente significantes, sendo que os remanescentes permaneceram com mesmas interpretações e inferências

(I_PAN_EUROPA, I_PAN_AMNOR, I_PAN_RENDA e I_PAN_DENS). Quando analisamos a heterogeneidade individual estimadas pelos parâmetros intercepto do modelo LSDV observamos que oito países tem parâmetros significativos, o que diferente do painel de volatilidade, tem um maior número de países sem características individuais intrínsecas de transbordamento de volatilidade para o mercado brasileiro. Esse número de parâmetros de heterogeneidade individual sem significância estatística, associadas a questão de graus de liberdades já destacadas anteriormente, sugerem a estimação do modelo de efeito fixo Within. Os resultados desse modelo estão detalhados na Tabela 16.

Tabela 16 - Modelo de Dados em Painel Dif-em-Dif para Spillovers dos Países e efeitos Covid-19

Modelo de Efeitos Fixos (Within) - Parâmetros Estimados					
	Estimativa	Desv.Pad	t valor	Pr(> t)	
NR_CASOSMIL	-1.3024e-06	3.3175e-06	-0.3926	0.6946656	
NR_OBITOSMIL	-1.5422e-04	3.5505e-05	-4.3436	1.468e-05	***
NR_RECMIIL	1.2158e-05	3.5527e-06	3.4222	0.0006329	***
soc_dist	-2.0083e-03	7.3499e-04	-2.7324	0.0063398	**
mov_rest	-1.6227e-03	1.0723e-03	-1.5133	0.1303490	
pub_health	9.4849e-04	3.2351e-04	2.9319	0.0034048	**
gov_soc_econ	-3.8115e-03	4.6121e-04	-8.2640	2.456e-16	***
gtrends_score	1.9728e-03	1.8478e-04	10.6767	< 2.2e-16	***
I_PAN	6.4582e-02	4.0619e-02	1.5900	0.1119924	
I_PAN_LOCK	-3.3959e-02	2.1122e-02	-1.6077	0.1080403	
I_PAN_LATAM	-5.5490e-02	4.3361e-02	-1.2797	0.2007892	
I_PAN_EUROPA	1.3003e-01	3.8098e-02	3.4130	0.0006546	***
I_PAN_AMNOR	1.6065e-01	4.4000e-02	3.6512	0.0002674	***
I_PAN_RENDA	-4.7826e-02	2.7073e-02	-1.7665	0.0774509	.
I_PAN_DENS	-6.5681e-02	1.5540e-02	-4.2265	2.474e-05	***
OBS		2,145			
R2		0.30555			
R2 ajustado		0.31643			
Estatística F		62.0393	com 15 e 2115 GL,	p-valor: <	
		2,22e-16			

Nota: 0 '***' 0,001 '**' 0,01 '*' 0,05 '.' 0,1 ' ' 1

Fonte: Elaboração própria.

O modelo Within apresentou significância global pelo teste F e com R2, de 32%. O número de óbitos e número de recuperados em 1 milhão/hab permanecem estatisticamente significativos e com mesmo sinais. O número de restrições de movimentações permaneceu estatisticamente insignificante, sendo todos demais variáveis (pub_health, gov_soc_econ e gtrends_score) permaneceram estatisticamente significativos e de mesmo sinal. Cabe ressaltar que a variável gtrends_country_score, por não apresentar variabilidade temporal para alguns países, no processo de estimação, não permaneceu no modelo. Dentre os efeitos contrafactuais, os parâmetros do efeito lockdown e para países latinos americanos também não são estatisticamente significantes. Esses resultados inferenciais precisam serem testadas em relação as hipótese sobre variância, efeitos individuais não observados, etc. O resultado desses testes são apresentados na Tabela 17.

Tabela 17 - Testes em Modelos de Dados em Painel

Teste	Estatística	Graus de Liberdade	P-valor
Teste F para efeitos individuais	F = 14.574	gl1 = 7, gl2 = 2115	< 2.2e-16
Breusch-Pagan studentizado	BP = 275.67	gl = 22	< 2.2e-16
Teste Breusch-Godfrey/Wooldridge para correlação serial em modelos de painel	chisq = 1527	gl = 143	< 2.2e-16
Teste Pesaran para dependência Cross-Sectional em Painéis	z = 60.153	-	< 2.2e-16
Teste do tipo Fisher para estacionariedade do resíduo do Painel	Pm = -14.324	-	0.01
Teste de Wooldridge para efeitos individuais não-observáveis	z = 1.6178	-	0.1057

Fonte: Elaboração própria.

O teste F para efeitos individuais conclui pela presença de heterogeneidade individual, sugerindo o uso dos modelos de efeitos fixos. Assim como nos modelos de volatilidade, os testes Breusch-Pagan e Breusch-Godfrey/Wooldridge, apresentam evidências de heterocedasticidade e autocorrelação serial, comprometendo as inferências de teste t apresentadas nos modelos estimados. Muitos embora os resíduos sejam estacionários pelo teste tipo Fisher, temos a indicação de presença de dependência cross-section pelo teste Pesaran. O teste de Wooldridge, rejeita a hipótese de efeitos individuais não observáveis. Diante dessas evidências o modelo Within foi estimado com a mesma correção do estimador HC4 comentado na seção anterior. Os resultados estão contidos na Tabela 18.

Tabela 18 - Modelo de Dados em Painel Dif-em-Dif para Spillovers dos Países e efeitos Covid-19

Modelo de Efeitos Fixos (Within+Corr. Het.Auto-Corr.) - Parâmetros Estimados				
	Estimativa	Desv.Pad	t valor	Pr(> t)
NR_CASOSMIL	-1.3024e-06	8.5472e-06	-0.1524	0.8789061
NR_OBITOSMIL	-1.5422e-04	6.8444e-05	-2.2532	0.0117370 *
NR_RECMIIL	1.2158e-05	6.7293e-06	1.8068	0.0454521 *
soc_dist	-2.0083e-03	1.8811e-03	-1.0676	0.2858100
mov_rest	-1.6227e-03	2.4954e-03	-0.6503	0.5155700
pub_health	9.4849e-04	4.9514e-04	1.9156	0.0555515 .
gov_soc_econ	-3.8115e-03	1.1337e-03	-3.3619	0.0007878 ***
gtrends_score	1.9728e-03	6.5685e-04	3.0035	0.0027001 **
I_PAN	6.4582e-02	4.0586e-02	1.5912	0.1117030

I_PAN_LOCK	-3.3959e-02	4.3474e-02	-0.7811	0.4348133
I_PAN_LATAM	-5.5490e-02	4.7564e-02	-1.1666	0.2434918
I_PAN_EUROPA	1.3003e-01	5.3977e-02	2.4090	0.0160820 *
I_PAN_AMNOR	1.6065e-01	3.4000e-02	4.7251	2.451e-06 ***
I_PAN_RENDA	-4.7826e-02	5.3569e-02	-0.8928	0.3720731
I_PAN_DENS	-6.5681e-02	5.2052e-02	-1.2618	0.2071442

Nota: 0 ‘***’ 0,001 ‘**’ 0,01 ‘*’ 0,05 ‘.’ 0,1 ‘ ’ 1

Fonte: Elaboração própria.

Os resultados da correção para heterocedasticidade e autocorrelação reduz o número de parâmetros estatisticamente significantes. Dentre as variáveis pandêmicas o número de óbitos por 1 milhão/hab tem efeito negativos no transbordamento de volatilidade para o mercado brasileiro, ou seja, agravamentos na pandemia, reduzem a correlação condicional do mercado brasileiro com os demais países. Por outro lado, aumento no número de recuperados, tem efeito positivo sobre os transbordamentos de volatilidade. O número de medidas de saúde pública aumentam, em média, os transbordamentos de volatilidade, ao passo que o número de medidas sócio econômicas reduzem esse transbordamento. A busca por informação medida na variável *gtrends_score* causa aumentos médios na correlação condicional do mercado financeiro brasileiro com os demais países. Dentre os efeitos contrafactuais, apenas os efeitos associados aos países europeus e da América do Norte, foram estatisticamente significantes, ambos positivos, ou seja, países não europeus (ou não norte americanos), teriam maior transbordamento de volatilidade para o mercado brasileiro, caso fossem dessas regiões.

4.3.3 Conclusões Contrafactuais dos Modelos Dif-em-Dif

Os resultados apresentados nas duas últimas seções apresentam evidências, tanto da dinâmica dos choques pandêmicos exógenos, quanto dos efeitos contrafactuais identificados na volatilidade e no *spillover* para o mercado financeiro brasileiro. Com relação as variáveis pandêmicas, a volatilidade dos países apresentam uma aumento (em média), quando ocorrem aumento no número de casos por 1 milhão/hab e quando existe uma aumento nas buscas globais do Google pela palavra “coronavirus”, ao passo que existe uma redução na volatilidades dos países quando ocorrem aumentos no número de recuperados do Covid-19 e quando o número de medidas de saúde pública aumentam. Esses efeitos sugerem que a oscilação dos mercados aumente com os indícios de propagação da pandemia, mas não com sua gravidade, pois a gravidade está relacionada à dinâmica do número de óbitos. Mesmo as buscas globais pela palavra “coronavirus”, pode ser vista como um proxy para indivíduos com sintomas iniciais, e novamente relacionado com a propagação da pandemia. Por outro lado, o número de recuperados seria o contraponto dos mecanismos de propagação, o que juntamente a aumentos no número de medidas de saúde pública, são indícios de arrefecimento da pandemia, o que impacta positivamente as expectativas dos agentes e uma crença na retomada da atividade econômica. Nesse mesmo sentido o efeito contrafactual do lockdown, indica que países não lançaram mão dessa medida extrema, teriam tido menores volatilidades em seus mercados adotando tal política, da mesma forma que os países que a utilizaram como política poderiam ter tido maiores volatilidades sem sua adoção.

Com relação aos transbordamentos de volatilidade dos países da amostra para o mercado financeiro brasileiro, temos diferentes efeitos observados. A correlação condicional apresenta uma queda na medida em que o número de óbitos (normalizado pela população) aumenta e quando o número de medidas sócio econômico aumenta. Essas duas variáveis

podem ser vistas como indicadores de gravidade da pandemia, quanto mais grave a pandemia, maior a taxa de mortalidade e maior número de socorro governamental são desprendidos. Por outro lado, aumentos na taxa de recuperação, número de medidas de saúde pública, que podem ser vistas como medidas de arrefecimento da pandemia causam aumento da correlação condicional dos mercados financeiros da amostra em relação ao mercado brasileiro. Os efeitos causais dos países europeus e do norte da América, indicam que países de outras regiões, teriam tido maior correlação condicional com o mercado brasileiro, caso fossem dessas regiões. Esse resultado destaca a importância dos mercados europeus e em especial o mercado dos EUA em termos de co-movimentos com o mercado brasileiro, não havendo efeitos contrafactuais associados as políticas de lockdown. Por fim, as buscas globais no Google pela palavra “coronavirus”, tem impacto positivo nos spillovers.

Em resumo, as evidências apresentadas, sugerem que a volatilidade reage mais diretamente aos mecanismos de propagação da pandemia do que com a gravidade pandêmica, enquanto o spillover reage mais diretamente a essa gravidade da pandemia Covid-19. Os movimentos de arrefecimento da pandemia agem reduzindo a volatilidade e aumentando o spillover. Todos esses resultados inferências contrafactuais, dependem diretamente das hipóteses dos modelos de dados painel de Diferenças-em-Diferenças. Nesse sentido, uma hipótese central é a de que os países diferentes entre si, mas de maneira constante, isso se traduz em não haver tendências presente na componente de heterogeneidade individual, ou seja as tendências são necessariamente paralelas, o que em muitas situações é uma hipótese extremamente restritiva. Os testes Pesaran para dependência cross-section e de Wooldridge para efeitos individuais não observáveis, além da persistente presença de heterocedasticidade e autocorrelação serial, são indícios de que as hipóteses dos modelos Dif-em-Dif, e suas inferências podem está falhando conforme Bertrand et al (2004). Outra sensível questão diz respeito aos efeitos defasados de intervenções, como por exemplo políticas de lockdown, em seus efeitos podem ocorrer de maneira lenta, criando uma estrutura de autocorrelação e demandando técnicas GMM, como a de Arellano e Bond (1991), para sua estimação. Caso a distribuição da variável resposta esteja mudando no tempo, e mesmo introduzindo dinâmica temporal nos modelos de dados em painel, permanece presente a necessidade de tendências paralelas e com ela todas suas dificuldades inferências.

Uma alternativa a todas essas questões de inferência causal em modelos de dados em painel são os modelos de painel contrafactuais artificiais (ArCo). A abordagem ArCo engloba o método PF proposto por Hsiao et al.(2012) e pode ser visto como um generalização da abordagem de Controle Sintético nas mesmas linhas discutidas por Doudchenko e Imbens (2016) e Ferman e Pinto (2016). O método ArCo é mais adequado do que os estimadores de Diferenças-em-Diferenças (DiD), mesmo para estudos de caso comparativos quando há uma única unidade tratada e nenhum grupo de controle semelhante está disponível, mesmo após a inclusão de muitas variáveis de controle. Além disso, a abordagem ArCo relaxa a restrição estrita de tendência paralela dos métodos DiD. Recentemente, Gobillon e Magnac (2016) generalizam estimadores DiD considerando uma especificação correta modelo de painel linear encontrado com regressores estritamente exógenos e efeitos fixos interativos representados como uma série de fatores comuns com cargas heterogêneas. Seus resultados teóricos dependem de duplo assintóticos quando T e n vão ao infinito. Os autores permitem que os fatores de confusão comuns têm tendências determinísticas não lineares. O método ArCo difere de Gobillon e Magnac (2016) em várias direções:

- 1) O modelo não é considerado como especificado corretamente e não há necessidade de estimar os fatores comuns. A estimativa consistente de fatores precisa que tanto o a série temporal e as dimensões da seção transversal divergem ao infinito e podem ser severamente enviesadas em pequenas amostras;

2) A metodologia ArCo requer apenas a divergência da dimensão da série temporal. Além disso, o regressores não precisam ser estritamente exógenos, o que é uma suposição irreal na maioria das aplicações com dados agregados. Tendências não lineares heterogêneas também são permitidas, mas não há necessidade de estimar (explicitamente ou por meio de fatores comuns);

3) Finalmente, como no caso DiD, o ArCo também não exigem que o número de unidades tratadas cresça ou tenha um grupo de controle confiável (após o condicionamento covariáveis).


Diante de todas essas questões apresentamos na próxima seção os resultados ArCo para estimar comportamentos contrafactuais da volatilidade e do spillovers dos países da amostra desse estudo.

4.4 Resultados dos Modelos de Dados em Painel Contrafactuais Artificiais

Apresentamos nessa seção os resultados⁵ dos modelos de dados em painel contrafactual artificial (ArCo) para os painéis de volatilidade e spillovers. O ponto de intervenção, tanto para a volatilidade quanto para o spillover, foi estimado endogeneamente em um primeiro momento. As estimativas para os 15 países indicaram uma intervenção no dia 13/03/2020 para 10 países, para EUA, Alemanha e Itália uma intervenção no dia 11/03/2020 e Brasil, França no dia 12/03/2020. Dessa forma, para manter o mesmo parâmetro de comparabilidade das métricas de avaliação contrafactual utilizamos o dia 13/03/2020 como a data de intervenção para todos os países, a partir desse ponto da amostra temporal, podemos verificar um aumento abrupto na volatilidade para todos os países da amostra, sugerindo que tenha sido um choque comum a todos os mercados.

Inicialmente apresentamos estudos de casos para elucidar os resultados obtidos e como serão tratados. Na Figura 2 apresentamos os resultados⁶ do modelo ArCo para o Chile.

Figura 2 – Estudo de Caso: Chile



Fonte: Elaboração própria


⁵ Os demais estudos de casos estão disponibilizados no Apêndice

⁶ Quando consideramos o número de parâmetros estimados para todos os modelos: modelo de estimação, modelo de ajuste contrafactual, tornou-se impraticável o reporte desses modelos dado a limitação de páginas. Tais resultados podem ser requeridos a qualquer tempo ao autor.

O caso chileno reflete o comportamento contrafactual a partir da intervenção do dia 13/03 abaixo da volatilidade observada, ou seja, em um contexto contrafactual sem pandemia, utilizando a melhor estimativa de um Chile-contrafactual, a volatilidade chilena teria sido menor. Dessa forma para o Chile, a pandemia trouxe considerável impacto em volatilidade. O comportamento do transbordamento de volatilidade para o mercado brasileiro também esteve na maior parte do período amostral acima do que seria em um contexto contrafactual, e portanto, o movimento desses dois mercados, em razão da pandemia, tiveram maior correlação condicional.

Na sequência apresentamos na Figura 3 os resultados para o caso do Japão, que é o contra-ponto do caso chileno. Podemos observar graficamente que a volatilidade observada foi abaixo da volatilidade do Japão-Contrafactual a partir da intervenção, e nesse caso, o Japão teria a princípio tido menores impactos da pandemia na volatilidade de seu mercado. Seu spillover para o mercado brasileiro por outro lado permaneceu quase sem diferença entre o contrafactual e o observado, contudo um descolamento da correlação condicional começa a ser observado a partir do dia 27/04, em um contexto contrafactual, teríamos um transbordamento maior do que o verificado, e, portanto a partir dessa data, o co-movimento desses dois mercados cai.


Figura 3 – Estudo de Caso: Japão



Fonte: Elaboração própria

Apresentamos na Figura 4 outro caso possível da dinâmica contrafactual, e nesse estudo de caso temos a Alemanha. Em termos de volatilidade podemos verificar que praticamente não há diferença entre diferença entre a volatilidade observada e a volatilidade da Alemanha-Contrafactual, e nesse caso a evidência de que o comportamento da volatilidade foi pouco impactada pela pandemia a partir da data de intervenção. Em termos de transbordamento verificamos que o mesmo comportamento, exceto para um pequeno período entre 13/03 a 03/04, onde o spillover observado esteve acima do contrafactual. Esse resultado mostra que a estrutura de correlação condicional entre o mercado alemão e brasileiro, pouco foi afetado pela pandemia, mantendo-se na maior parte do período amostral acima de 0,4, o que revela um grande co-movimento desses dois mercado. Dois outros importantes estudos de caso serão apresentados na sequência: o caso brasileiro e o caso norte-americano.


Figura 4 – Estudo de Caso: Alemanha



Fonte: Elaboração própria

Apresentamos na Figura 5 os resultados para o caso brasileiro. Observamos que a dinâmica contrafactual a partir da data da intervenção, inicialmente não tem grandes divergência da volatilidade observada, contudo a partir do dia 30/03, a volatilidade do Brasil-Contrafactual tem valores acima do observado, o que indica que o mercado brasileiro sofreu impactos menores advindos da pandemia. Quando consideramos o transbordamento de volatilidade dos demais países da amostra para o mercado financeiro brasileiro, podemos observar que da intervenção até o dia 07/04, a correlação condicional observada permanece acima do seu contrafactual, e partir dessa data o spillover internacional cai para um nível, que na maior parte do período restante, está abaixo do spillover do Brasil-Contrafactual. Esse resultado mostra que no início da pandemia, o movimento do mercado brasileiro esteve mais intensamente correlacionado com o movimento dos demais mercado e acima do que seria num contexto contrafactual, a partir do arrefecimento pandêmico, os co-movimentos com os demais mercado caiu para baixo do que seria esperado.


Figura 5 – Estudo de Caso: Brasil



Fonte: Elaboração própria

Um último e importante estudo de caso, o caso dos EUA, é apresentado na Figura 6. Podemos observar que a volatilidade dos EUA-Contrafactual, a partir da intervenção esteve muito abaixo da volatilidade observada até o dia 07/04, indicando que os EUA sofreram grandes impactos advindos da pandemia nesse período, a partir desse ponto praticamente não há diferença entre a volatilidade observada e seu contrafactual, ou seja, para os EUA, passado o primeiro choque de volatilidade, o mercado rapidamente voltou à normalidade. Em termos de transbordamento dessa volatilidade, novamente o início da pandemia, observamos uma correlação condicional muito acima do contrafactual até o dia 21/04, e mesmo posteriormente a essa data, os valores do spillover contrafactual permanece abaixo do observado. Esse resultado ressalta a influência do mercado norte-americano e seus impactos no mercado brasileiro.

Figura 6 – Estudo de Caso: EUA



Fonte: Elaboração própria

Os resultados apresentados nesses estudos de caso mostram a heterogeneidade dos impactos pandêmico nas volatilidades dos países e dos spillovers para o mercado brasileiro. Para termos ideia desse impacto em termos contrafactuais utilizaremos duas medidas: Diferença Contrafactual (DCF) e a Diferença Contrafactual Percentual (DCFP). A primeira medida é a diferença entre a variável contrafactual e seu valor observado, enquanto que a segunda considera essa diferença em modulo, dividida pelo valor observado, permitindo termos uma ideia percentual da diferença contrafactual. Enquanto a média da DCFP permite termos uma medida de impacto total, sem discriminar se o contrafactual esteve acima ou abaixo do observado, essa informação é obtida pela média do DCF. Apresentamos na Tabela 19 os resultados dessas medidas para os 15 países da amostra, ranqueadas da maior média de DCFP para menor, tanto para o painel de volatilidade quanto para o painel de spillovers.

Os resultados mostram os impactos absolutos contrafactuais (média de DCFP) foram maiores para os países onde a pandemia foi mais graves, um conclusão diferente dos resultados dos modelos Dif.-em-Dif, onde a gravidade da pandemia não efeito estatisticamente relevante sobre a volatilidade dos países. O número absoluto de recuperados também apresentou correlação estatisticamente positiva com os impactos absolutos na volatilidade, ou seja, países com número maior de recuperados (em termos absolutos), tem maior impacto absoluto da pandemia na volatilidade (também em termos absolutos, ou seja, esse impacto pode ser volatilidade contrafactual acima ou abaixo da volatilidade observada).

Tabela 19 - Impacto Pandêmicos Contrafactuais Estimados

País	I_Lockdown	Média DCFP Volatilidade	Média DCF Volatilidade	Nr. Casos por 1 Milhão/hab.	Nr. Óbitos por 1 Milhão/hab.	Nr Recuperados por 1 Milhão/hab.	Nr. Casos	Nr. Óbitos	Nr Recuperados
Suíça	0	3,7521	0,000733	4.230	232	3.685	36.269	1.986	31.600
Brasil	1	1,2823	0,000512	14.037	472	10.767	2.962.442	99.572	2.272.299
Argentina	1	0,5800	-0,000731	5.244	98	2.299	235.677	4.411	103.297
Itália	1	0,5581	0,000173	4.142	584	3.344	249.756	35.190	201.642
França	1	0,5482	0,000268	3.507	452	1.237	235.207	30.327	82.968
EUA	0	0,5247	-0,000026	15.055	492	4.947	4.941.755	161.347	1.623.870
Japão	0	0,4581	0,000028	362	8	240	45.764	1.042	30.241
Chile	1	0,4443	-0,000007	19.461	525	18.054	368.825	9.958	342.168
México	1	0,3464	-0,000035	3.679	402	2.901	469.407	51.311	370.098
Peru	1	0,3280	0,000024	14.268	635	9.669	463.875	20.649	314.332
Espanha	1	0,2518	-0,000043	6.678	605	3.194	314.362	28.503	150.376
Reino Unido	1	0,2353	0,000065	4.649	697	22	310.696	46.596	1.447
Suécia	0	0,1395	-0,000053	8.004	560	2.401	82.323	5.763	24.697
Colômbia	1	0,0907	-0,000049	7.295	243	3.943	367.204	12.250	198.495
Alemanha	1	0,0721	-0,000022	2.601	111	2.357	216.196	9.195	195.935
Correlação com a Média DCFP		-	0,66*	-0,06	-0,20*	0,06	0,02	-0,04	0,09*
País	I_Lockdown	Média DCFP Spillover	Média DCF Spillover	Nr. Casos por 1 Milhão/hab.	Nr. Óbitos por 1 Milhão/hab.	Nr Recuperados por 1 Milhão/hab.	Nr. Casos	Nr. Óbitos	Nr Recuperados
Japão	0	1,331977	0,049781	362	8	240	45.764	1.042	30.241
Colômbia	1	1,209933	0,366666	7.295	243	3.943	367.204	12.250	198.495
Chile	1	0,933049	0,051631	19.461	525	18.054	368.825	9.958	342.168
Suíça	0	0,293056	0,091026	4.230	232	3.685	36.269	1.986	31.600
EUA	0	0,241854	-0,101887	15.055	492	4.947	4.941.755	161.347	1.623.870
Espanha	1	0,215994	-0,103271	6.678	605	3.194	314.362	28.503	150.376
Argentina	1	0,195895	0,056564	5.244	98	2.299	235.677	4.411	103.297
Brasil	1	0,161670	0,038426	14.037	472	10.767	2.962.442	99.572	2.272.299
México	1	0,124512	0,035915	3.679	402	2.901	469.407	51.311	370.098
Reino Unido	1	0,110011	0,029440	4.649	697	22	310.696	46.596	1.447
França	1	0,103903	0,016584	3.507	452	1.237	235.207	30.327	82.968
Peru	1	0,098136	0,019934	14.268	635	9.669	463.875	20.649	314.332
Itália	1	0,098085	0,003368	4.142	584	3.344	249.756	35.190	201.642
Suécia	0	0,068551	-0,027302	8.004	560	2.401	82.323	5.763	24.697
Alemanha	1	0,057262	-0,007526	2.601	111	2.357	216.196	9.195	195.935
Correlação com a Média DCFP		-	0,60*	-0,10*	0,47*	0,29*	0,24*	0,95*	0,83*

Nota: 1) *Estatisticamente significantes ao nível de 5%; 2) Os números pandêmicos dessa tabela se referem ao dia de informação coletado, 07/08/2020. **Fonte:** Elaboração própria.


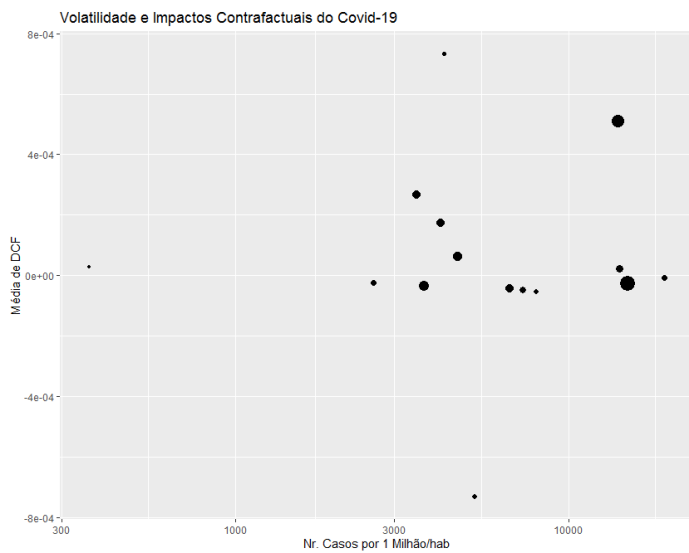
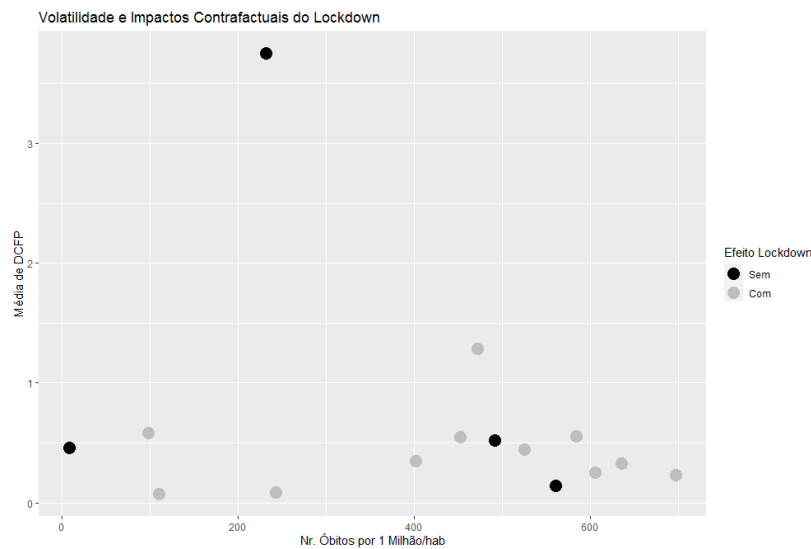
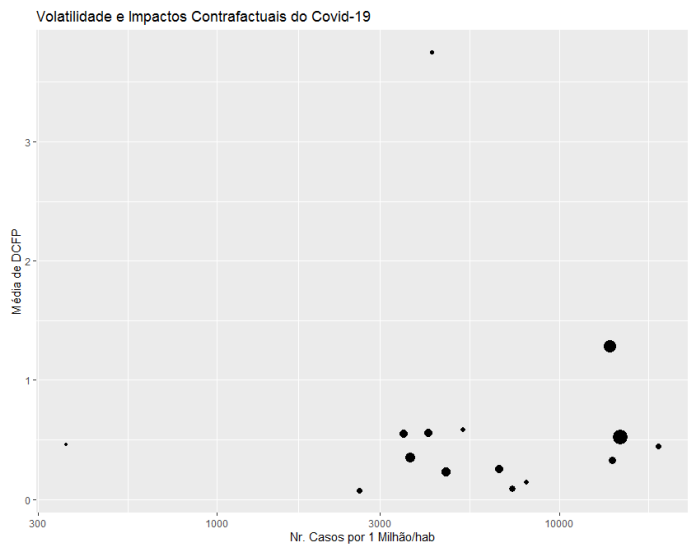
Outro importante aspecto mostra que lockdown nos resultados ArCo não apresenta um padrão em destaque, dos quatros países sem adoção dessa política, a Suíça, com maior impacto DCFP e com DCF positivo e por outro lado a Suécia, com um dos menores DCFP e DCF negativa. Esse resultado sobre lockdown se repete para EUA e Japão, países que não adotaram lockdown durante o período amostral e com impacto DCFP próximos, com sinais alternados de DCF. Considerando spillover as intensidades dos impactos contrafactuais são maiores e mais estatisticamente significantes. Os impactos medidos pelo DCFP são maiores tanto para taxa de mortalidade quanto para o número absoluto de óbitos, sendo que o número de absoluto, que mede a gravidade pandêmica interna de cada país, tem maior impacto absoluto na diferença entre a correlação condicional contrafactual e seu valor observado, O mesmo resultados vale para a taxa de recuperação, quanto para o número absoluto de recuperados. Quando consideramos os cinco maiores DCFP, observamos são oriundos de países em que o número de óbitos somados não superava o número de óbitos brasileiros, todos com DCF positiva, o que indica a correlação condicional observada foi menor que seu valor contrafactual, ou seja, os co-movimentos desses mercados com o mercado brasileiro, foi intensamente menor do que seria no contexto contrafactual sem pandemia. Apenas quatros outros países (EUA, Espanha, Suécia e Alemanha) apresentaram DCF negativa, ou seja, para esses países, a correlação condicional observada foi maior do que seu valor contrafactual, e nessas condições, os co-movimentos desses países, foram no período amostral, intensamente maiores, do que seriam no contexto sem pandemia. Assim como na volatilidade, não há padrão identificado nos impactos contrafactuais da adoção ou não de política de lockdown.

Para finalizar a análise ArCo apresentamos na Figura 7 os impactos DCFP e DCF na volatilidade dos países considerando a incidência pandêmica (número de casos por 1 milhão/hab.) e o número absoluto de óbitos por Covid-19. Os resultados para volatilidade reinteram as observações da Tabela 19. Os países com maior incidência e maior gravidade pandêmica apresenta maior impactos absolutos DCFP e não apresentando nenhum padrão em relação a adoção ou não de políticas de lockdown, um resultado que contraria os resultados dos modelos de Dif-em-Dif. Considerando DCF, menor incidência está associado DCF positivos (com algumas exceções), de menores valores e de menor gravidade pandêmica, ou seja, para países onde os valores de volatilidade observada foram menores que seu valores contrafactuais, também são os países de baixa incidência e com menor número absoluto de óbitos. Os resultados de lockdown para DCFP também são validos para o DCF.

Na figura 8 apresentamos a mesma análise para spillover. Os resultados de DCFP e DCF para adoção de políticas de lockdown continuam sem apresentar um padrão que indique qualquer relação relevante. Para transbordamentos de volatilidade, maiores impactos absolutos (DCFP), estão associados a maior a incidência pandêmica, contudo não necessariamente com um maior número absoluto de óbitos. Quando analisamos o DCF, observamos que tanto valores positivos e negativos aumentam com aumentos da incidência pandêmica, mas não necessariamente aumentam com países de maior número absoluto de mortes. Esse resultado indica que a medida que a incidência da pandemia aumenta, a diferença entre correlações condicionais contrafactuais e seus valores observados, também aumenta, esse resultado também contraria os resultados dos modelos Dif.-em-Dif, em que o número de casos por 1 milhão/hab. não apresentou resultados estatisticamente significantes.

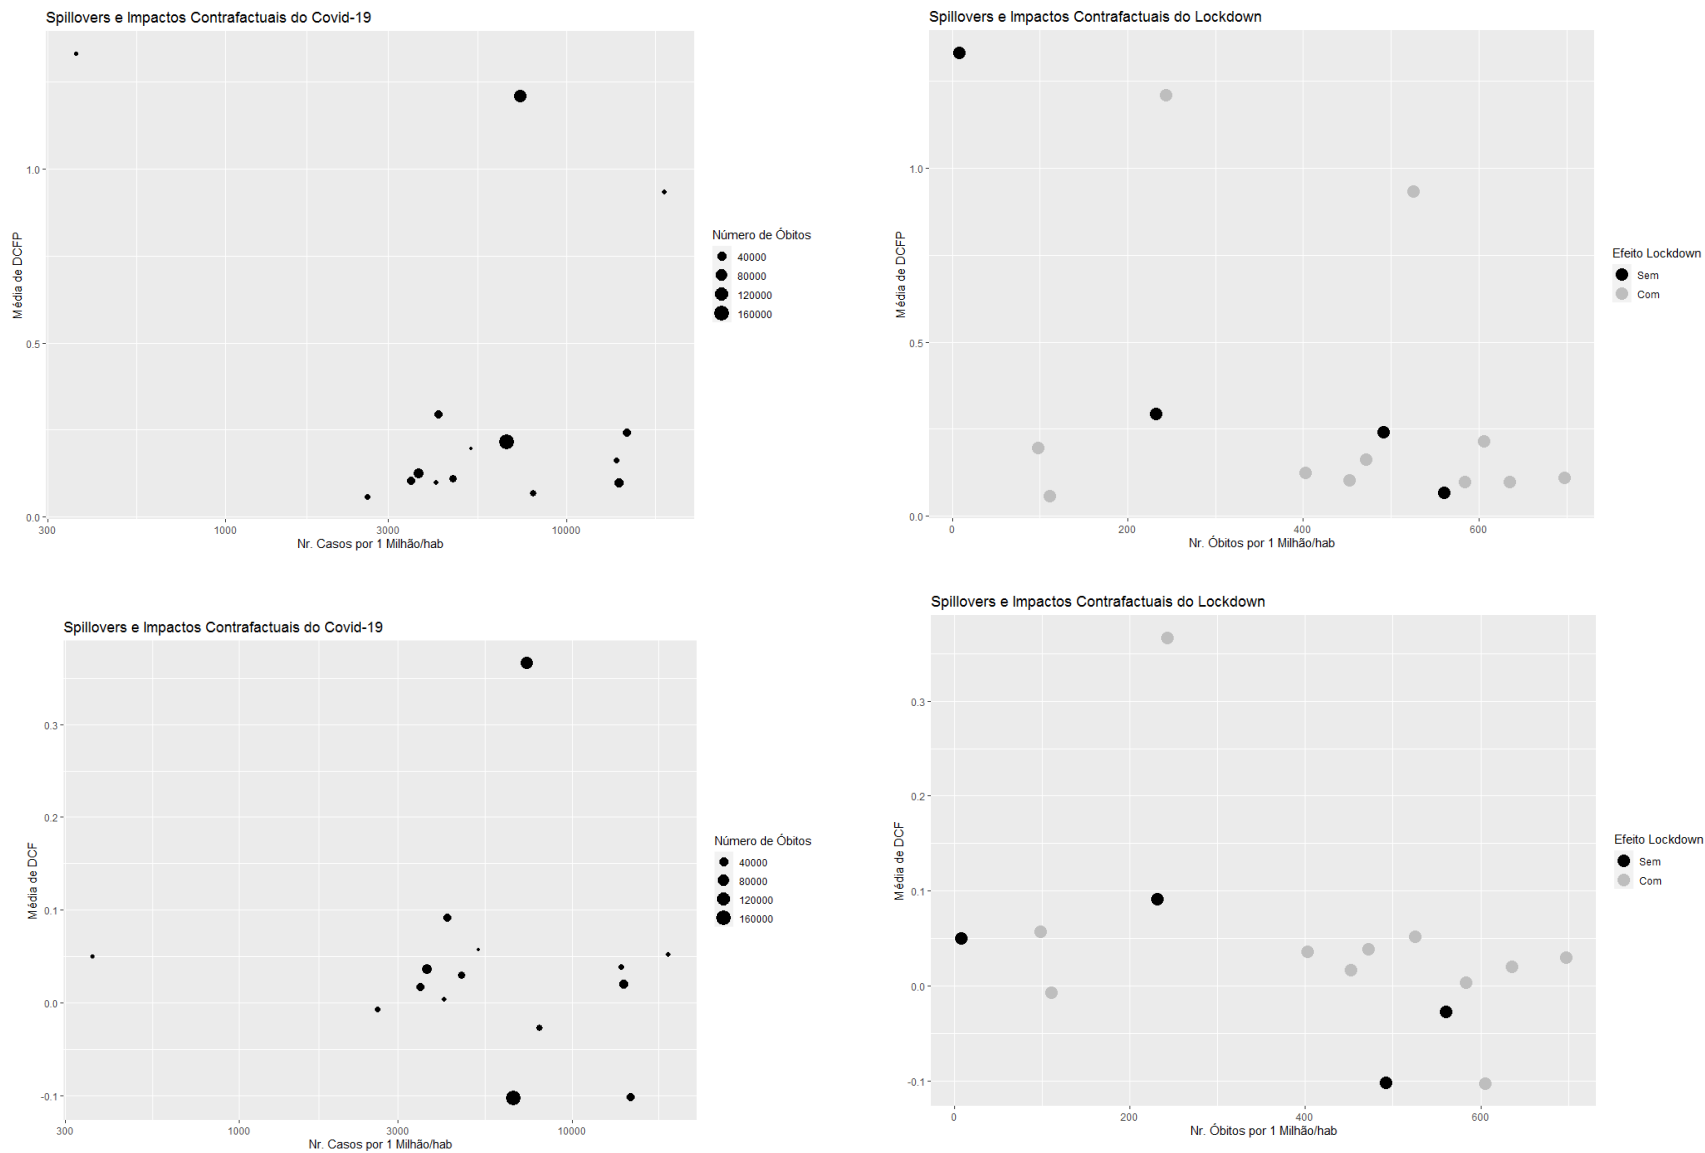
A metodologia ArCo permite dessa forma entender os impactos da pandemia do Covid-19 de uma forma detalhada e individual para cada país, sem impor fortes restrições para a inferência causal. Algumas conclusões tem resultado contrario aos modelos de painel Dif.-em-Dif o que não necessariamente invalida tais evidências, mas ressaltam o caráter investigativo necessário para o entendimento dos impactos pandêmicos do Covid-19 na volatilidade e spillovers dos países selecionados no período amostral considerado.

Figura 7 – Impactos Contrafactuais Pandêmicos na Volatilidade dos Países



Fonte: Elaboração própria.

Figura 8 - Impactos Contrafactuais Pandêmicos nos Transbordamentos de Volatilidade dos Países para o Mercado Brasileiro.



Fonte: Elaboração própria.

5. Conclusão

Nesse artigo investigamos como a pandemia do Covid-19 afetou a volatilidade do mercado financeiro de quinze países e seus transbordamentos de volatilidade (spillovers) para o mercado brasileiro. A proposta desse estudo teve como linha principal de investigação a inferência contrafactual dessas volatilidades e spillovers no período pandêmico. Para essa finalidade utilizamos uma base de dados diários de dados financeiros de fechamento das bolsas de valores, de dados pandêmicos do número de casos, número de óbitos e número de recuperados, além de informações de medidas de restrições de movimentação, de distanciamento social, de saúde pública e sócio-econômicas além de buscas no Google Trend da palavra “coronavirus” em todo mundo e nos países da amostra. Também foi considerada no estudo uma marcação caso o país tenha adotado política de lockdown em algum momento do período amostral, além de, outras informações adicionais de cada país para cálculo de taxas pandêmicas, geográficas e de densidade demográfica. O período amostral compreendeu o período de 22/01/2020 a 07/08/2020 perfazendo uma amostra de 143 observações temporais.

O primeiro passo foi à estimação das volatilidades e spillovers para construção de dois painéis de dados com essas temáticas. Para cada país foi estimado um modelo GARCH multivariado Diagonal BEKK considerando o log retorno do Brasil e o de cada um dos demais 14 países. Esses modelos bivariados apresentaram ajuste adequado de baixa ordem validados pelos testes nos resíduos e quadrado dos resíduos. A partir das volatilidades e spillovers estimados foram construídos dois painéis considerando as variáveis supracitadas como covariáveis exógenas. O estudo utilizou duas abordagens de inferência causal: modelos de dados em painel de Diferenças-em-Diferenças (DiD) e os modelos de painel contrafactuals artificiais (ArCo).

As conclusões gerais dos modelos DiD estimados depreende que a volatilidade aumenta quando que as medidas de propagação da pandemia, dadas pela taxa de incidência e as buscas globais no Google como proxy para primeiros sintomas, também aumentam. Por outro lado, a volatilidade reduz na medida em que os números de arrefecimento da pandemia aumentam, como por exemplo, a taxa de recuperados e o número de medidas de saúde pública. Para o painel de spillover, os resultados indicam que a correlação condicional entre a volatilidade do Brasil e dos demais países, aumenta quando as medidas de arrefecimento da pandemia também aumentam: taxa de recuperados, número de medidas de saúde pública, e caem quando as medidas de gravidade da pandemia, taxa de mortalidade e número de medidas sócio-econômicas, aumentam. Por esses modelos estimados a volatilidade reage mais diretamente à propagação pandêmica do que pela gravidade pandêmica, enquanto que os transbordamentos de volatilidade reagiriam mais diretamente à gravidade pandêmica do que sua propagação. A política de lockdown teria efeitos contrafactuals apenas para a volatilidade. Todas essas inferências são sensíveis a um conjunto de hipóteses, dentre essas, destaca-se a hipótese de que os países diferentes entre si, mas de maneira constante, isso se traduz em não haver tendências presente na componente de heterogeneidade individual, ou seja, as tendências são necessariamente paralelas, o que em muitas situações é uma hipótese extremamente restritiva, como alternativa a essas (e outras) fragilidades dos modelos DiD foram estimados os modelos para painéis contrafactuals artificiais (ArCo).

Os resultados dos modelos ArCo permitiram, individualmente por país, construir sua respectiva volatilidade contrafactual, bem como seu spillover contrafactual. Com esses resultados foi possível observar o comportamento dos painéis a partir de uma data de intervenção (inicialmente estimada endogenamente, mas pela similaridade fixada exogenamente como o dia 13/03). Os resultados revelaram que os impactos foram

heterogêneos nos países, volatilidades como a do Chile e dos EUA, se mostraram acima de seus valores contrafactuais, ou seja, para esses países, volatilidade teria menor em um contexto contrafactual. Outros países, como o Japão, apresentaram volatilidade contrafactual acima de seus valores observados, ou seja, a volatilidade japonesa teria sido maior no contexto contrafactual. Houve ainda países em que quase não há distinção entre os valores observados de volatilidade e seus contrafactuais, como foi o caso da Alemanha. O Brasil inicialmente não tem grandes divergências da volatilidade observada, contudo a partir do dia 30/03, a volatilidade do Brasil-Contrafactual tem valores acima do observado, o que indica que o mercado brasileiro sofreu impactos menores advindos da pandemia. Os resultados para spillovers também se mostram heterogêneos. Para dimensionar os impactos a partir da data de intervenção, foram construídas duas medidas de diferença entre valores contrafactuais e valores observados de volatilidades e spillovers: Diferença Contrafactual (DCF), como a diferença simples, e a Diferença Contrafactual Percentual (DCFP), que considera o valor absoluto dessa diferença dividido pelo valor observado, medindo impactos absolutos.

Os resultados ArCo indicam que países com maior incidência e maior gravidade pandêmica interna (medida pelo número absoluto de óbitos no país) apresenta maior impactos absolutos DCFP para volatilidade e não apresentando nenhum padrão em relação a adoção ou não de políticas de lockdown, um resultado que contraria os resultados dos modelos de Dif-em-Dif. Para transbordamentos de volatilidade, maiores impactos absolutos (DCFP), estão associados a maior a incidência pandêmica, contudo não necessariamente com um maior número absoluto de óbitos, também sem resultados para efeitos de países que adotaram política de lockdown. Os resultados ArCo, diferentemente dos modelos DiD, sinalizam que a volatilidade reagem mais diretamente a uma combinação de propagação e gravidade pandêmica, enquanto o spillover reagem mais diretamente a propagação pandêmica. As divergências inferenciais entre os modelos ArCo e DiD, não inviabilizam as evidências encontradas em nenhum desses modelos, mas sua interpretação deve sempre considerar suas hipótese fundamentais. Ambas as classes de modelos também apresentam convergência em alguns pontos: as medidas de arrefecimento da pandemia, contrafactualmente reduzem a volatilidade e aumentam o spillover para o mercado financeiro brasileiro. Dessa forma o estudo contribui com a literatura como um pioneiro estudo dos impactos contrafactuais da pandemia do Covid-19 para volatilidade e spillovers de mercados financeiros.

Referências Bibliográficas

- Abadie, A., Diamond, A. and Hainmueller, J.: 2010, Synthetic control methods for comparative case studies: Estimating the effect of california's tobacco control program, *Journal of the American statistical Association* 105(490), 493–505.
- Abadie, A., Diamond, A. and Hainmueller, J.: 2015, Comparative politics and the synthetic control method, *American Journal of Political Science* 59(2), 495–510.
- Abadie, A. and Gardeazabal, J.: 2003, The economic costs of conflict: A case study of the basque country, *American economic review* 93(1), 113–132.
- Al-Awadhi, A. M., Al-Saifi, K., Al-Awadhi, A. and Alhamadi, S.:2020, Death and contagious infectious diseases: Impact of the covid-19 virus on stock market returns, *Journal of Behavioral and Experimental Finance* p. 100326.
- Albulescu, C.: 2020a, Coronavirus and financial volatility: 40 days of fasting and fear, arXiv preprint arXiv:2003.04005 .
- Albulescu, C. T.: 2020b, Covid-19 and the united states financial markets' volatility, *Finance Research Letters* p. 101699.
- Angrist, J. D. and Pischke, J.-S.: 2008, *Mostly harmless econometrics: An empiricist's companion*, Princeton university press.
- Arellano, M.: 2003, *Panel data econometrics*, Oxford university press.
- Arellano, M. and Bond, S.: 1991, Some tests of specification for panel data: Monte carlo evidence and an application to employment equations, *The review of economic studies* 58(2), 277–297.
- Arellano, M. et al.: 1987, Computing robust standard errors for within-groups estimators, *Oxford bulletin of Economics and Statistics* 49(4), 431–434.
- Ashenfelter, O. and Card, D.: 1985, susing the longitudinal structure of earnings to estimate the effect of training programs, *The review of economics and statistics*; 67 (4).
- Baker, S. R., Bloom, N., Davis, S. J., Kost, K., Sammon, M. and Viratyosin, T.: 2020, The unprecedented stock market reaction to covid-19, *The Review of Asset Pricing Studies*
- Bertrand, M., Duflo, E. and Mullainathan, S.: 2004, How much should we trust differences-in-differences estimates?, *The Quarterly journal of economics* 119(1), 249–275.
- Bollerslev, T.: 1986, Generalized autoregressive conditional heteroskedasticity, *Journal of econometrics* 31(3), 307–327.
- Card, D. and Krueger, A. B.: 2000, Minimum wages and employment: a case study of the fast-food industry in new jersey and pennsylvania: reply, *American Economic Review* 90(5), 1397–1420.
- Carvalho, C., Masini, R. and Medeiros, M. C.: 2018, Arco: na artificial counterfactual approach for high-dimensional panel time-series data, *Journal of econometrics* 207(2), 352–380.
- Casado, M. G., Glennon, B., Lane, J., McQuown, D., Rich, D. and Weinberg, B. A.: 2020, The effect of fiscal stimulus: Evidence from covid-19. Working Paper.
- Choi, I.: 2001, Unit root tests for panel data, *Journal of international money and Finance* 20(2), 249–272.

- Clemens, J. and Veuger, S.: 2020, Implications of the covid-19 pandemic for state government tax revenues. Working Paper.
- Coates, B., Cowgill, M., Chen, T. and Mackey, W.: 2020, Shutdown: estimating the covid-19 employment shock, Grattan Institute, Melbourne, Victoria .
- Corbet, S., Hou, G., Hu, Y., Oxley, L. and Xu, D.: 2020, Pandemic-related financial market volatility spillovers: Evidence from the chinese covid-19 epicentre, Available at SSRN 3618736 .
- Cribari-Neto, F.: 2004, Asymptotic inference under heteroskedasticity of unknown form, *Computational Statistics & Data Analysis* 45(2), 215–233.
- de Almeida, A. T. C., Frascaroli, B. F. and da Cunha, D. R.: 2012, Medidas de risco e matriz de contágio: uma aplicação do covar para o mercado financeiro brasileiro, *Revista Brasileira de Finanças* 10(4), 551–584.
- de Oliveira, W. S. M. and Maranhao, A. N.: 2017, Spillovers de volatilidades cambiais e de mercados financeiros internacionais no mercado acionario brasileiro, *Revista Brasileira de Finanças* 15(4), 569–603.
- De Vito, A. and Gomez, J.-P.: 2020, Estimating the covid-19 cash crunch: Global evidence and policy, *Journal of Accounting and Public Policy* p. 106741.
- Doudchenko, N. and Imbens, G. W.: 2016, Balancing, regression, difference-in-differences and synthetic control methods: A synthesis, Technical report, National Bureau of Economic Research.
- Engle, R. F.: 1982, Autoregressive conditional heteroscedasticity with estimates of the variance of united kingdom inflation, *Econometrica: Journal of the Econometric Society* pp. 987–1007.
- Fairlie, R. W., Couch, K. and Xu, H.: 2020, The impacts of covid-19 on minority unemployment: First evidence from april 2020 cps microdata. Working Paper.
- Ferman, B. and Pinto, C.: 2016, Revisiting the synthetic control estimator, Working Paper FGV .
- Ferman, B. and Pinto, C.: 2019, Inference in differences-in-differences with few treated groups and heteroskedasticity, *Review of Economics and Statistics* 101(3), 452–467.
- Ferman, B., Pinto, C. and Possebom, V.: 2020, Cherry picking with synthetic controls, *Journal of Policy Analysis and Management* 39(2), 510–532.
- Fernandes, N.: 2020, Economic effects of coronavirus outbreak (covid-19) on the world economy, Available at SSRN 3557504 .
- Fezzi, C. and Fanghella, V.: 2020, Real-time estimation of the short-run impact of covid-19 on economic activity using electricity market data, *Environmental and Resource Economics* 76(4), 885–900.
- Friedman, J., Hastie, T. and Tibshirani, R.: 2010, Regularization paths for generalized linear models via coordinate descent, *Journal of statistical software* 33(1), 1.
- GAIO, L. E., AMBROZINI, M. A., BONACIM, C. A. G. and JUNIOR, T. P.: 2014, Interdependência entre os mercados mundiais de ações: uma análise de volatilidades, *Revista Base (Administração e Contabilidade) da UNISINOS* 11(3), 259–274.

- Garcin, M., Klein, J. and Laaribi, S.: 2020, Estimation of time-varying kernel densities and chronology of the impact of covid-19 on financial markets, arXiv preprint arXiv:2007.09043 .
- Gobillon, L. and Magnac, T.: 2016, Regional policy evaluation: Interactive fixed effects and synthetic controls, *Review of Economics and Statistics* 98(3), 535–551.
- Hsiao, C., Steve Ching, H. and Ki Wan, S.: 2012, A panel data approach for program evaluation: measuring the benefits of political and economic integration of hong kong with mainland china, *Journal of Applied Econometrics* 27(5), 705–740.
- Ibikunle, G. and Rzaev, K.: 2020, Volatility, dark trading and market quality: evidence from the 2020 covid-19 pandemic-driven market volatility, Available at SSRN 3586410 .
- Kurmann, A., Lale, E. and Ta, L.: 2020, The impact of covid-19 on us employment and hours: Real-time estimates with homebase data, (May). [http://www. andrekurmann. com/hb_covid](http://www.andrekurmann.com/hb_covid) .
- Le Quéré, C., Jackson, R. B., Jones, M. W., Smith, A. J., Abernethy, S., Andrew, R. M., De-Gol, A. J., Willis, D. R., Shan, Y., Canadell, J. G. et al.: 2020, Temporary reduction in daily global co 2 emissions during the covid-19 forced confinement, *Nature Climate Change* pp. 1–7.
- Mandal, I. and Pal, S.: 2020, Covid-19 pandemic persuaded lockdown effects on environment over stone quarrying and crushing areas, *Science of The Total Environment* 732, 139281.
- Milani, B., Bender Filho, R., Ceretta, P. S., Vieira, K. M. and Coronel, D. A.: 2014, Spillover de liquidez no mercado brasileiro, *Revista Pensamento Contemporâneo em Administração* 8(2), 55–74.
- Norouzi, N., de Rubens, G. Z., Choubanpishehzafar, S. and Enevoldsen, P.: 2020, When pandemics impact economies and climate change: Exploring the impacts of covid-19 on oil and electricity demand in china, *Energy Research & Social Science* 68, 101654.
- Nunes Maranhão, A. and de Oliveira, W. S. M.: 2017, Spillovers de volatilidades cambiais e efeito lead-lag no mercado acionário brasileiro., *Revista Brasileira de Economia de Empresas/Brazilian Journal of Business Economics* 17(2).
- Ozili, P. K. and Arun, T.: 2020, Spillover of covid-19: impact on the global economy, available at SSRN 3562570 .
- Righi, M. B. and Ceretta, P. S.: 2013, Efeito da crise de 2007/2008 na transmissão internacional de volatilidade no mercado de capitais brasileiro, REAd. *Revista Eletrônica de Administração* (Porto Alegre) 19(2), 384–400.
- Roberton, T., Carter, E. D., Chou, V. B., Stegmuller, A. R., Jackson, B. D., Tam, Y., Sawadogo-Lewis, T. and Walker, N.: 2020, Early estimates of the indirect effects of the covid-19 pandemic on maternal and child mortality in low-income and middle-income countries: a modelling study, *The Lancet Global Health* .
- Snow, J.: 1855, *On the mode of communication of cholera*, John Churchill.
- Sumner, A., Hoy, C., Ortiz-Juarez, E. et al.: 2020, Estimates of the impact of covid-19 on global poverty, UNU-WIDER, April pp. 800–9.
- Topcu, M. and Gulal, O. S.: 2020, The impact of covid-19 on emerging stock markets, *Finance Research Letters* p. 101691

Wang, Q. and Su, M.: 2020, A preliminary assessment of the impact of covid-19 on environment—a case study of china, *Science of the Total Environment* p. 138915.

Zhang, D., Hu, M. and Ji, Q.: 2020, Financial markets under the global pandemic of covid-19, *Finance Research Letters* p. 101528.

6. Apêndice

Tabela 1 - Composição e construção de dados financeiros e pandêmicos do estudo.

Variáveis do Painel	
Variável	Descrição
country	Código ISO3c do país, conforme definido pela ISO 3166-1 alfa-3
date	Data
confirmed	Casos confirmados de Covid-19, conforme relatado por JHU CSSE (acumulado)
deaths	Mortes relacionadas a Covid-19, conforme relatado por JHU CSSE (acumulado)
recovered	Recuperações do Covid-19, conforme relatado por JHU CSSE (acumulado)
soc_dist	Número de medidas de distanciamento social relatadas pela ACAPS, líquidas de restrições levantadas
mov_rest	Número de restrições de movimento relatadas até o momento pelo ACAPS, líquido de restrições levantadas
pub_health	Número de medidas de saúde pública relatadas até o momento pelo ACAPS, líquido de restrições levantadas
gov_soc_econ	Número de medidas socioeconômicas relatadas até o momento pelo ACAPS, líquido de restrições levantadas
lockdown	Número de medidas de bloqueio informadas pela ACAPS, líquidas de restrições levantadas
gtrends_score	Volume de pesquisa do Google para o termo "coronavírus", relativo ao longo do tempo com o país no máximo na escala de 100
gtrends_country_score	Volume de pesquisa no Google em nível de país para o termo "coronavírus" em um período a partir de 1º de janeiro de 2020, relativo entre países com o país com o maior volume de pesquisa na escala de 100 (tempo estável)
region	Região do país classificada pelo Banco Mundial (estável no tempo)
income	Grupo de renda do país classificado pelo Banco Mundial (estável no tempo)
population	População do país, conforme informado pelo Banco Mundial (identificador original 'SP.POP.TOTL', com estabilidade de tempo)
land_area_skm	Massa terrestre do país em quilômetros quadrados, conforme informado pelo Banco Mundial (identificador original 'AG.LND.TOTL.K2', com estabilidade de tempo)

pop_density	Densidade populacional do país, conforme relatado pelo Banco Mundial (identificador original "EN.POP.DNST", com estabilidade de tempo)
NR_CASOSMIL	Número de casos por um milhão de habitantes (variáveis confirmed, population)
NR_OBITOSMIL	Número de mortes por um milhão de habitantes (variáveis deaths e population)
NR_RECML	Número de recuperados por um milhão de habitantes (variáveis recovered e population)
I_lockdown	Indicadora de país que tenha tido pelo menos uma ação pública de Lockout (variável lockdown)
I_LATAM	Indicadora de país latino americano
I_EUROPA	Indicadora de país europeu
I_AMNOR	Indicadora de país norte americano
I_RENDA	Indicadora de país de alta renda classificada pelo Banco Mundial (variável income)
I_DENS	Indicadora de país de alta densidade populacional (variável pop_density)
I_PAN	Indicadora de início da pandemia (primeiro registro de óbito - variável deaths)
I_PAN_LOCK	Variável de Diferença em Diferença para o Efeito Lockdown na Pandemia
I_PAN_LATAM	Variável de Diferença em Diferença para o Efeito America Latina na Pandemia
I_PAN_EUROPA	Variável de Diferença em Diferença para o Efeito Europa na Pandemia
I_PAN_AMNOR	Variável de Diferença em Diferença para o Efeito America do Norte na Pandemia
I_PAN_RENDA	Variável de Diferença em Diferença para o Efeito Alta Renda na Pandemia
I_PAN_DENS	Variável de Diferença em Diferença para o Efeito Densidade Populacional na Pandemia
Volatilidade	Volatilidade estimada nos Modelos GARCH multivariados
Spillover	Transbordamento (Correlação condicional) estimada nos Modelos GARCH multivariados

Variáveis dos Modelos GARCH Multivariados BEKK

Bolsas	Descrição
Brasil	log retorno do bovespa
Alemanha	log retorno do DAX
Argentina	log retorno do Merval
Chile	log retorno do Chile Stock Mkt
Colômbia	log retorno do IGBC General
França	log retorno do CAC 40
Reino Unido	log retorno do FTSE 100
México	log retorno do BMV
EUA	log retorno do Dow Jones
Peru	log retorno do Lima General Index

Japão	log retorno do Nikkei 225
Suíça	log retorno do SIX Swiss Exchange
Suécia	log retorno do OMX Stockholm
Espanha	log retorno do IBEX 35
Itália	log retorno do FTSE MIB

Nota: ACAPS é um provedor de informações independente criada em 2009 como um projeto não governamental e sem fins lucrativos com dados disponibilizados para livre acesso.

As fontes de dados das bolsas de valores são de livre acesso no site:

<https://br.investing.com/indices/world-indices>

As fontes de dados JHU são de livre acesso no site: <https://coronavirus.jhu.edu>

As fontes de dados do Banco Mundial são de livre acesso no site: <https://data.worldbank.org>

Fonte: Elaboração própria.

Modelo 1 - DBEKK(1,1)				
Parâmetros	Estimativas	DP	Estatísticas	P-valor
c11	0,009	0,002	5,722	0,000
c12	0,004	0,001	3,167	0,001
c22	0,005	0,002	3,100	0,001
a11	0,064	0,074	2,866	0,019
a12	-0,115	0,081	-1,422	0,922
a22	0,587	0,113	5,174	0,000
b11	0,398	0,143	2,776	0,003
b12	0,824	0,043	19,096	0,000
b22	0,913	0,039	23,465	0,000
AIC	-1.383,54			
BIC	-1.356,87			
LOG	700,77			

Teste LM para Autocorrelação dos Resíduos e Quadrado dos Resíduos - Modelo 1

Defasagem	P-valor Resíduos		P-valor Quadrado dos Resíduos	
	Volatilidade 1	Volatilidade 2	Volatilidade 1	Volatilidade 2
1	0,290	0,499	0,277	0,067
2	0,376	0,377	0,206	0,045
3	0,586	0,553	0,348	0,088
4	0,475	0,627	0,515	0,173
5	0,563	0,574	0,676	0,052
6	0,694	0,493	0,647	0,078
7	0,331	0,291	0,717	0,109
8	0,397	0,144	0,758	0,152
9	0,340	0,033	0,339	0,112
10	0,370	0,061	0,365	0,150

Nota: H_0 : Ausência de Autocorrelação na k-ésima defasagem.

Fonte: Elaboração própria.

Modelo 2 - DBEKK(1,1)				
Parâmetros	Estimativas	DP	Estatísticas	P-valor
c11	0,009	0,002	4,534	0,000
c12	0,006	0,004	1,482	0,069
c22	0,010	0,009	1,126	0,130
a11	-0,001	0,001	-0,927	0,823
a12	-0,199	0,107	-1,854	0,968
a22	0,590	0,149	3,965	0,000
b11	0,420	0,264	1,592	0,056
b12	0,832	0,061	13,546	0,000
b22	0,887	0,149	5,932	0,000
AIC	-1.243,48			
BIC	-1.216,81			
LOG	630,74			

Teste LM para Autocorrelação dos Resíduos e Quadrado dos Resíduos - Modelo 2

Defasagem	P-valor Resíduos		P-valor Quadrado dos Resíduos	
	Volatilidade 1	Volatilidade 2	Volatilidade 1	Volatilidade 2
1	0,288	0,396	0,232	0,387
2	0,380	0,392	0,192	0,250
3	0,591	0,573	0,335	0,404
4	0,474	0,653	0,502	0,553
5	0,563	0,530	0,668	0,416
6	0,693	0,496	0,644	0,286
7	0,326	0,386	0,723	0,295
8	0,378	0,264	0,759	0,381
9	0,317	0,092	0,301	0,314
10	0,346	0,148	0,321	0,374

Nota: H_0 : Ausência de Autocorrelação na k-ésima defasagem.

Fonte: Elaboração própria.

Modelo 3 - DBEKK(1,1)				
Parâmetros	Estimativas	DP	Estatísticas	P-valor
c11	0,016	0,002	6,600	0,000
c12	0,004	0,001	2,752	0,003
c22	0,004	0,002	2,447	0,007
a11	0,376	0,082	4,575	0,000
a12	0,265	0,134	1,972	0,024
a22	0,880	0,164	5,365	0,000
b11	0,567	0,142	4,006	0,000
b12	0,425	0,076	5,598	0,000
b22	0,851	0,025	34,359	0,000
AIC	-1.390,92			
BIC	-1.364,25			

LOG

704,46

 Teste LM para Autocorrelação dos Resíduos e Quadrado dos Resíduos - Modelo 3

Defasagem	P-valor Resíduos		P-valor Quadrado dos Resíduos	
	Volatilidade 1	Volatilidade 2	Volatilidade 1	Volatilidade 2
1	0,206	0,668	0,085	0,205
2	0,297	0,325	0,086	0,266
3	0,436	0,492	0,135	0,447
4	0,322	0,555	0,225	0,586
5	0,375	0,506	0,250	0,256
6	0,489	0,509	0,165	0,279
7	0,319	0,335	0,189	0,356
8	0,441	0,192	0,236	0,399
9	0,416	0,020	0,254	0,482
10	0,437	0,035	0,275	0,589

Nota: H_0 : Ausência de Autocorrelação na k-ésima defasagem.

Fonte: Elaboração própria.

 Modelo 4 - DBEKK(1,1)

Parâmetros	Estimativas	DP	Estatísticas	P-valor
c11	0,010	0,002	5,752	0,000
c12	0,003	0,001	2,969	0,002
c22	0,005	0,002	3,262	0,001
a11	-0,008	0,017	-0,484	0,686
a12	-0,171	0,090	-1,904	0,971
a22	0,601	0,122	4,912	0,000
b11	0,397	0,122	3,260	0,001
b12	0,814	0,047	17,238	0,000
b22	0,892	0,044	20,471	0,000

AIC -1.402,03

BIC -1.375,36

LOG 710,01

 Teste LM para Autocorrelação dos Resíduos e Quadrado dos Resíduos - Modelo 4

Defasagem	P-valor Resíduos		P-valor Quadrado dos Resíduos	
	Volatilidade 1	Volatilidade 2	Volatilidade 1	Volatilidade 2
1	0,290	0,575	0,254	0,054
2	0,374	0,451	0,195	0,044
3	0,583	0,625	0,335	0,093
4	0,473	0,695	0,499	0,178
5	0,558	0,629	0,657	0,047
6	0,688	0,555	0,622	0,067
7	0,342	0,332	0,689	0,095
8	0,415	0,147	0,731	0,135

9	0,354	0,029	0,352	0,096
10	0,386	0,056	0,378	0,130

Nota: H_0 : Ausência de Autocorrelação na k-ésima defasagem.

Fonte: Elaboração própria.

Modelo 5 - DBEKK(1,1)				
Parâmetros	Estimativas	DP	Estatísticas	P-valor
c11	0,010	0,002	6,388	0,000
c12	0,002	0,001	3,078	0,001
c22	0,004	0,001	2,873	0,002
a11	0,059	0,124	0,473	0,318
a12	-0,067	0,102	-0,662	0,746
a22	0,629	0,119	5,278	0,000
b11	0,398	0,132	3,013	0,001
b12	0,800	0,041	19,421	0,000
b22	0,919	0,037	25,135	0,000
AIC	-1.424,88			
BIC	-1.398,21			
LOG	721,44			

Teste LM para Autocorrelação dos Resíduos e Quadrado dos Resíduos - Modelo 5

Defasagem	P-valor Resíduos		P-valor Quadrado dos Resíduos	
	Volatilidade 1	Volatilidade 2	Volatilidade 1	Volatilidade 2
1	0,287	0,511	0,205	0,055
2	0,375	0,428	0,180	0,056
3	0,580	0,598	0,318	0,117
4	0,466	0,673	0,477	0,216
5	0,548	0,621	0,632	0,080
6	0,679	0,568	0,591	0,107
7	0,347	0,319	0,656	0,139
8	0,424	0,141	0,697	0,193
9	0,358	0,031	0,357	0,141
10	0,391	0,055	0,383	0,187

Nota: H_0 : Ausência de Autocorrelação na k-ésima defasagem.

Fonte: Elaboração própria.

Modelo 6 ⁷ - DBEKK(1,1)				
Parâmetros	Estimativas	DP	Estatísticas	P-valor
c11	0,011	0,002	6,723	0,000

⁷ O modelo 7 está apresentado no corpo do artigo.

c12	0,004	0,001	3,698	0,000
c22	0,005	0,001	4,620	0,000
a11	0,003	0,007	0,435	0,332
a12	0,254	0,082	3,114	0,001
a22	0,760	0,143	5,316	0,000
b11	0,589	0,152	3,866	0,000
b12	0,730	0,049	14,834	0,000
b22	0,767	0,084	9,181	0,000

AIC -1.490,72

BIC -1.464,05

LOG 754,36

Teste LM para Autocorrelação dos Resíduos e Quadrado dos Resíduos - Modelo 6

Defasagem	P-valor Resíduos		P-valor Quadrado dos Resíduos	
	Volatilidade 1	Volatilidade 2	Volatilidade 1	Volatilidade 2
1	0,278	0,791	0,118	0,051
2	0,375	0,465	0,141	0,057
3	0,553	0,645	0,256	0,081
4	0,433	0,774	0,393	0,137
5	0,495	0,783	0,521	0,035
6	0,623	0,682	0,466	0,022
7	0,386	0,413	0,504	0,031
8	0,491	0,198	0,550	0,047
9	0,403	0,066	0,392	0,028
10	0,444	0,111	0,425	0,040

Nota: H_0 : Ausência de Autocorrelação na k-ésima defasagem.

Fonte: Elaboração própria.

Modelo 8 - DBEKK(1,1)

Parâmetros	Estimativas	DP	Estatísticas	P-valor
c11	0,009	0,005	1,933	0,027
c12	0,003	0,002	1,503	0,067
c22	0,004	0,005	0,937	0,174
a11	0,001	0,002	0,618	0,268
a12	0,292	0,084	3,459	0,000
a22	0,534	0,300	1,780	0,038
b11	0,407	0,298	1,368	0,086
b12	0,844	0,165	5,117	0,000
b22	0,854	0,194	4,404	0,000

AIC -1.482,48

BIC -1.455,82

LOG 750,24

Teste LM para Autocorrelação dos Resíduos e Quadrado dos Resíduos - Modelo 8

Defasagem	P-valor Resíduos		P-valor Quadrado dos Resíduos	
	Volatilidade 1	Volatilidade 2	Volatilidade 1	Volatilidade 2
1	0,297	0,535	0,484	0,274
2	0,372	0,618	0,254	0,157
3	0,584	0,782	0,388	0,283
4	0,484	0,778	0,554	0,437
5	0,577	0,704	0,712	0,089
6	0,708	0,742	0,700	0,094
7	0,325	0,445	0,768	0,133
8	0,389	0,244	0,811	0,181
9	0,346	0,051	0,349	0,126
10	0,375	0,084	0,382	0,170

Nota: H_0 : Ausência de Autocorrelação na k-ésima defasagem.

Fonte: Elaboração própria.

Modelo 9 - DBEKK(1,1)				
Parâmetros	Estimativas	DP	Estatísticas	P-valor
c11	0,010	0,002	5,381	0,000
c12	0,001	0,001	1,808	0,035
c22	0,004	0,001	3,370	0,000
a11	-0,212	0,114	-1,865	0,969
a12	0,207	0,102	2,022	0,022
a22	0,644	0,150	4,303	0,000
b11	0,399	0,089	4,471	0,000
b12	0,771	0,060	12,943	0,000
b22	0,911	0,030	29,933	0,000
AIC	-1.415,86			
BIC	-1.389,20			
LOG	716,93			

Teste LM para Autocorrelação dos Resíduos e Quadrado dos Resíduos - Modelo 9

Defasagem	P-valor Resíduos		P-valor Quadrado dos Resíduos	
	Volatilidade 1	Volatilidade 2	Volatilidade 1	Volatilidade 2
1	0,271	0,335	0,147	0,136
2	0,372	0,238	0,170	0,220
3	0,573	0,379	0,304	0,364
4	0,448	0,494	0,449	0,531
5	0,531	0,483	0,600	0,327
6	0,660	0,496	0,555	0,380
7	0,322	0,280	0,618	0,461
8	0,399	0,174	0,650	0,542
9	0,336	0,046	0,366	0,320
10	0,367	0,068	0,390	0,368

Nota: H_0 : Ausência de Autocorrelação na k-ésima defasagem.

Fonte: Elaboração própria.

Modelo 10 - DBEKK(1,1)				
Parâmetros	Estimativas	DP	Estatísticas	P-valor
c11	0,011	0,005	1,933	0,017
c12	0,005	0,002	1,503	0,057
c22	0,000	0,005	0,937	0,164
a11	-0,000	0,002	0,618	0,268
a12	0,000	0,084	3,459	0,000
a22	0,473	0,300	1,780	0,032
b11	0,086	0,298	1,368	0,066
b12	0,824	0,165	5,117	0,000
b22	0,898	0,194	4,404	0,000
AIC	-1.213,87			
BIC	-1.187,20			
LOG	615,93			
Teste LM para Autocorrelação dos Resíduos e Quadrado dos Resíduos - Modelo 10				
Defasagem	P-valor Resíduos		P-valor Quadrado dos Resíduos	
	Volatilidade 1	Volatilidade 2	Volatilidade 1	Volatilidade 2
1	0,328	0,672	0,376	0,498
2	0,368	0,152	0,279	0,602
3	0,573	0,257	0,381	0,311
4	0,531	0,381	0,468	0,278
5	0,632	0,410	0,618	0,377
6	0,734	0,101	0,618	0,070
7	0,394	0,062	0,632	0,087
8	0,502	0,088	0,724	0,041
9	0,505	0,054	0,640	0,033
10	0,545	0,107	0,707	0,021

Nota: H_0 : Ausência de Autocorrelação na k-ésima defasagem.

Fonte: Elaboração própria.

Modelo 11 - DBEKK(1,1)				
Parâmetros	Estimativas	DP	Estatísticas	P-valor
c11	0,010	0,002	5,636	0,000
c12	0,004	0,001	3,114	0,001
c22	0,006	0,002	3,423	0,000

a11	0,013	0,110	0,118	0,453
a12	0,248	0,117	2,118	0,017
a22	0,614	0,133	4,611	0,000
b11	0,439	0,162	2,706	0,003
b12	0,806	0,052	15,402	0,000
b22	0,855	0,043	19,985	0,000
AIC	-1.390,34			
BIC	-1.363,68			
LOG	704,17			

Teste LM para Autocorrelação dos Resíduos e Quadrado dos Resíduos - Modelo 11

Defasagem	P-valor Resíduos		P-valor Quadrado dos Resíduos	
	Volatilidade 1	Volatilidade 2	Volatilidade 1	Volatilidade 2
1	0,289	0,631	0,227	0,093
2	0,374	0,537	0,186	0,095
3	0,581	0,702	0,324	0,053
4	0,470	0,772	0,486	0,069
5	0,553	0,706	0,642	0,025
6	0,683	0,649	0,604	0,040
7	0,347	0,485	0,669	0,060
8	0,422	0,237	0,712	0,088
9	0,358	0,062	0,355	0,092
10	0,391	0,116	0,381	0,123

Nota: H_0 : Ausência de Autocorrelação na k-ésima defasagem.

Fonte: Elaboração própria.

Modelo 12 - DBEKK(1,1)

Parâmetros	Estimativas	DP	Estatísticas	P-valor
c11	0,011	0,002	4,954	0,000
c12	0,002	0,001	2,993	0,001
c22	0,005	0,001	4,815	0,000
a11	0,220	0,117	1,871	0,031
a12	-0,064	0,090	-0,705	0,760
a22	0,629	0,167	3,756	0,000
b11	0,509	0,136	3,731	0,000
b12	0,762	0,084	9,047	0,000
b22	0,860	0,039	21,910	0,000
AIC	-1.468,96			
BIC	-1.442,29			
LOG	743,48			

Teste LM para Autocorrelação dos Resíduos e Quadrado dos Resíduos - Modelo 12

Defasagem	P-valor Resíduos		P-valor Quadrado dos Resíduos	
	Volatilidade 1	Volatilidade 2	Volatilidade 1	Volatilidade 2

1	0,274	0,750	0,176	0,093
2	0,367	0,665	0,184	0,098
3	0,567	0,794	0,324	0,102
4	0,449	0,874	0,473	0,190
5	0,532	0,863	0,616	0,056
6	0,662	0,785	0,566	0,080
7	0,328	0,568	0,614	0,110
8	0,415	0,191	0,647	0,150
9	0,359	0,038	0,397	0,107
10	0,390	0,073	0,425	0,139

Nota: H_0 : Ausência de Autocorrelação na k-ésima defasagem.

Fonte: Elaboração própria.

Modelo 13 - DBEKK(1,1)				
Parâmetros	Estimativas	DP	Estatísticas	P-valor
c11	0,009	0,002	5,237	0,000
c12	0,003	0,001	2,733	0,003
c22	0,004	0,002	2,238	0,013
a11	0,032	0,189	0,169	0,433
a12	-0,017	0,259	-0,065	0,526
a22	0,607	0,150	4,053	0,000
b11	0,346	0,140	2,469	0,007
b12	0,817	0,056	14,568	0,000
b22	0,937	0,037	25,368	0,000
AIC	-1.418,42			
BIC	-1.391,76			
LOG	718,21			

Teste LM para Autocorrelação dos Resíduos e Quadrado dos Resíduos - Modelo 13

Defasagem	P-valor Resíduos		P-valor Quadrado dos Resíduos	
	Volatilidade 1	Volatilidade 2	Volatilidade 1	Volatilidade 2
1	0,289	0,561	0,235	0,091
2	0,376	0,267	0,191	0,096
3	0,585	0,428	0,331	0,149
4	0,472	0,501	0,495	0,247
5	0,558	0,513	0,656	0,086
6	0,688	0,325	0,623	0,118
7	0,337	0,166	0,695	0,169
8	0,404	0,087	0,735	0,224
9	0,342	0,020	0,336	0,194
10	0,373	0,040	0,360	0,250

Nota: H_0 : Ausência de Autocorrelação na k-ésima defasagem.

Fonte: Elaboração própria.

Modelo 14 - DBEKK(1,1)				
Parâmetros	Estimativas	DP	Estatísticas	P-valor
c11	0,010	0,002	4,777	0,000
c12	0,005	0,002	3,296	0,001
c22	0,008	0,002	4,501	0,000
a11	0,250	0,169	1,481	0,069
a12	-0,037	0,185	-0,203	0,580
a22	0,534	0,116	4,619	0,000
b11	0,637	0,226	2,824	0,002
b12	0,780	0,079	9,869	0,000
b22	0,794	0,076	10,453	0,000
AIC	-1.390,34			
BIC	-1.363,68			
LOG	704,17			



Teste LM para Autocorrelação dos Resíduos e Quadrado dos Resíduos - Modelo 14

Defasagem	P-valor Resíduos		P-valor Quadrado dos Resíduos	
	Volatilidade 1	Volatilidade 2	Volatilidade 1	Volatilidade 2
1	0,283	0,765	0,376	0,101
2	0,362	0,614	0,271	0,078
3	0,569	0,696	0,418	0,080
4	0,470	0,839	0,585	0,114
5	0,563	0,801	0,720	0,088
6	0,694	0,639	0,671	0,089
7	0,320	0,379	0,701	0,078
8	0,409	0,148	0,734	0,059
9	0,374	0,059	0,480	0,069
10	0,402	0,101	0,516	0,092

Nota: H_0 : Ausência de Autocorrelação na k-ésima defasagem.


Fonte: Elaboração própria.

Estudo de Caso: Argentina




Fonte: Elaboração própria.


Estudo de Caso: Itália




Fonte: Elaboração própria.




Estudo de Caso: Espanha




Fonte: Elaboração própria.





Estudo de Caso: França



Fonte: Elaboração própria.





Estudo de Caso: México





Fonte: Elaboração própria.

Estudo de Caso: Peru




Fonte: Elaboração própria.

Estudo de Caso: Colômbia




Fonte: Elaboração própria.

Estudo de Caso: Reino Unido




Fonte: Elaboração própria.

Estudo de Caso: Suécia



Fonte: Elaboração própria.

Estudo de Caso: Suíça



Fonte: Elaboração própria.