



UNIVERSIDADE FEDERAL DO CEARÁ
PROGRAMA DE PÓS-GRADUAÇÃO EM ECONOMIA
MESTRADO ACADÊMICO EM ECONOMIA

BRUNA KETHEY DA SILVA PEIXOTO

EFEITOS DA PANDEMIA DE COVID-19 NAS BOLSAS DE VALORES
MUNDIAIS

FORTALEZA

2021

BRUNA KETHEY DA SILVA PEIXOTO

EFEITOS DA PANDEMIA DE COVID-19 NAS BOLSAS DE VALORES MUNDIAIS

Dissertação apresentada ao Programa de Pós-Graduação em Economia da Universidade Federal do Ceará, como requisito parcial à obtenção do título de Mestre em Economia. Área de concentração: Economia.

Orientador: Prof. Dr. Roberto Tatiwa Ferreira

FORTALEZA

2021

Dados Internacionais de Catalogação na Publicação
Universidade Federal do Ceará
Biblioteca Universitária

Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

- P43e Peixoto, Bruna Kethey da Silva.
EFEITOS DA PANDEMIA DE COVID-19 NAS BOLSAS DE VALORES MUNDIAIS / Bruna
Kethey da Silva Peixoto. – 2021.
75 f. : il. color.
- Dissertação (mestrado) – Universidade Federal do Ceará, Faculdade de Economia, Administração,
Atuária e Contabilidade, Programa de Pós-Graduação em Economia, Fortaleza, 2021.
Orientação: Prof. Dr. Roberto Tatiwa Ferreira.
1. Bolsas de Valores. 2. Crise Financeira. 3. Pontos de Quebra. I. Título.

CDD 330

BRUNA KETHEY DA SILVA PEIXOTO

EFEITOS DA PANDEMIA DE COVID-19 NAS BOLSAS DE VALORES MUNDIAIS

Dissertação apresentada ao Programa de Pós-Graduação em Economia da Universidade Federal do Ceará, como requisito parcial à obtenção do título de Mestre em Economia. Área de concentração: Economia.

Orientador: Prof. Dr. Roberto Tatiwa Ferreira

Aprovada em: ___/___/_____.

BANCA EXAMINADORA

Prof. Dr. Roberto Tatiwa Ferreira (Orientador)
Universidade Federal do Ceará (UFC)

Prof. Dr. Leandro de Almeida Rocco
Universidade Federal do Ceará (UFC)

Prof. Dr. - Christiano Modesto Penna
Universidade Federal do Ceará (UFC)

A Deus.
A minha família e amigos.

AGRADECIMENTOS

À CAPES, pelo apoio financeiro com a manutenção da bolsa de auxílio.

Ao Prof. Dr. Roberto Tatiwa Ferreira, pela disponibilidade, confiança e excelente orientação.

Aos professores participantes da banca examinadora Prof. Dr. Leandro de Almeida Rocco e Prof. Dr. Christiano Modesto Penna pelo tempo, pelas valiosas colaborações e sugestões.

A todos os colegas da turma de mestrado, pelos momentos de aprendizado e colaboração durante o curso.

Aos professores da turma de Mestrado, que sempre disponibilizaram seu tempo e conhecimento para nosso crescimento pessoal e intelectual.

Aos meus pais, Raimundo Peixoto e Francisca Peixoto, grandes incentivadores e motivadores das minhas realizações.

Aos meus irmãos, Rafael Peixoto e Dr. Filipe Peixoto, que mesmo na distância se fazem presentes em todos os momentos.

Aos meus sobrinhos, André Victor e Isabella Maria, que são alegria e leveza em nosso dia-a-dia.

Aos amigos que sempre acreditaram no meu potencial, em especial minhas vizinhas, Bárbara Lobo e Allana Lobo, minha madrinha, Fernanda Lins e minha prima Jaine Paiva.

A todos que, de alguma forma, contribuíram para que eu realizasse esse sonho.

RESUMO

Em um mundo altamente globalizado e complexo, crises financeiras mundiais são inevitáveis. A crise financeira mundial de 2020 iniciou-se como uma grave crise sanitária em decorrência da COVID-19 com impactos graves na economia. A pandemia global levou à paralisação econômica devido às medidas urgentes de isolamento, distanciamento social e *lockdown* (bloqueio total de movimentação) necessárias para conter a disseminação do vírus. O efeito imediato no mercado financeiro foi uma queda brusca nas bolsas de valores pelo mundo. Nesse trabalho, busca-se estimar os pontos exatos dessas quebras, de modo a estabelecer uma comparação entre essas datas e acontecimentos relacionados à pandemia. Para isso, foram selecionados dados diários de índices bursáteis de doze países dentre os mais atingidos pela pandemia e cujas bolsas figuram entre as mais importantes do mundo. Utilizando as ferramentas propostas por Zeileis (2005) para testagem, monitoramento e datação de mudanças estruturais nas séries selecionadas, foram encontradas quebras que indicam início de período de decadência em dez dos doze índices entre os dias 24 e 26 de fevereiro de 2020. Também foram estimados segmentos que mostram indícios de recuperação já no final de março de 2020, mesmo com a expansão da pandemia. Utilizando a mesma técnica de datação e com uma base de dados estendida que se inicia em maio de 2005 e vai até janeiro de 2021, busca-se uma análise em relação à resposta dos índices a outros acontecimentos do período. De maneira geral, foram estimados segmentos de queda no período correspondente à crise de 2007-2009 em todos os índices. As datas estimadas referentes ao início desses segmentos foram, no entanto, bem mais espaçadas do que as estimadas para a crise atual. Os segmentos de queda nos índices também tiveram maior duração média, a menor correspondendo a um período de 3 meses, e chegando a cerca de 21 meses nos Estados Unidos. Para analisar mais profundamente as mudanças nas relações dos índices entre si, foram calculadas as correlações locais e correlações locais parciais a partir de uma análise *wavelet* multivariada. Os resultados mostraram uma forte relação linear entre as bolsas europeias durante toda a amostra. Há também um aumento na correlação local no início de 2020 entre bolsas não comumente relacionadas, especialmente da bolsa brasileira (BVSP) com as bolsas de Espanha (IBEX), França (CAC40), Itália (FTSEMIB) e Reino Unido (FTSE).

Palavras-chave: COVID-19. Bolsas de Valores. Pontos de Quebra. Crise Financeira.

ABSTRACT

In a very globalized and complex world, global financial crises are inevitable. The global financial crisis of 2020 has started as a serious health crisis resulted of COVID-19 with serious impacts on the economy. The global pandemic led to an economic paralysis due to the urgent quarantine rules, social distance and lockdown needed to contain the spread of the virus. The immediate effect on the financial market was a sharp drop in stock exchanges around the world. In this study, we seek to estimate the precise points of these breaks, in order to establish a comparison between these dates and events related to the pandemic. For this purpose, daily data from stock market indexes from twelve countries were selected among those most affected by the pandemic and whose stock exchanges are between the most important in the world. Using the tools proposed by Zeileis (2005) for testing, monitoring and dating structural changes in the selected series, the breaks detected indicate the beginning of a fall period in ten of the twelve indexes between February 24 and February 26, 2020. They were also estimated segments that show signs of recovery at the end of March 2020, even with the expansion of the pandemic. Using the same dating tool applied in an extended database that starts in May 2005 and ends in January 2021, we look for an analysis related to the response of the indexes to other events in this period. In general, falling segments were estimated in the period corresponding to the 2007-2009 crisis in all indexes. The estimated dates for the beginning of these segments were, however, much more spaced than those estimated for the 2020 crisis. The falling segments in the indices also had a longer average duration, the shortest one corresponding to a period of 3 months, and reaching until 21 months in the United States. To further analyze the changes in the relations of the indices to each other, local coherence and partial local coherence were calculated from a multivariate wavelet analysis. The results showed a strong linear relationship between European exchanges in all the sample. There is also an increase in the local correlation in early 2020 between non-commonly related exchanges, especially the Brazilian stock exchange (BVSP) with the stock exchanges of Spain (IBEX), France (CAC40), Italy (FTSEMIB) and the United Kingdom (FTSE).

Keywords: COVID-19. Stock Exchanges. Break Points. Financial crisis.

LISTA DE GRÁFICOS

| | |
|--|----|
| Gráfico 1 – Média Móvel de 7 dias (casos) | 37 |
| Gráfico 2 – Média Móvel de 7 dias (óbitos) | 37 |
| Gráfico 3 – Evolução Índice COVID-19 de Rigor da Resposta do Governo | 39 |
| Gráfico 4 – Retornos Acumulados (Mar/2005 – Jan/2021) | 47 |

LISTA DE TABELAS

| | |
|--|----|
| Tabela 1 – Estatísticas Descritivas dos Retornos 02/01/2019 – 22/01/2021 | 36 |
| Tabela 2 – Datas referentes à Pandemia | 38 |
| Tabela 3 – Testes de Flutuação | 41 |
| Tabela 4 – Monitoramento | 42 |
| Tabela 5 – Regressões Segmentadas considerando Modelos AR (1) | 44 |

LISTA DE QUADROS

| | |
|---|----|
| Quadro 1 – Principais contribuições da Literatura de Quebras Estruturais..... | 18 |
|---|----|

LISTA DE ABREVIATURAS E SIGLAS

| | |
|--------|--|
| ADF | <i>Augmented-Dickey-Fuller</i> |
| AR | <i>Autoregressive model</i> |
| AST | Análise de Séries Temporais |
| COVID | <i>CO</i> rona <i>VI</i> rus <i>D</i> isease |
| CUSUM | <i>Cumulative Sum</i> |
| CUSUMQ | <i>Cumulative Sum of Square</i> |
| DCCM | <i>Detrended Cross-Correlation Analysis</i> |
| DMCA | <i>Detrended Moving Cross-Correlation Analysis</i> |
| EWS | <i>Evolutionary Wavelet Spectrum</i> |
| FCLT | Teorema do Limite Central Funcional |
| GMM | Métodos Generalizados de Momentos |
| LM | <i>Maximum Likelihood</i> |
| LR | <i>Likelihood-ratio test</i> |
| LSW | <i>Multivariate Locally Stationary Wavelet Process</i> |
| LWZ | <i>Liu, Wu and Zidek Information Criterion</i> |
| MQO | Mínimos Quadrados Ordinários |
| MOSUM | <i>Moving Sums</i> |
| NLL | <i>Negative log-likelihood</i> |
| OMS | Organização Mundial da Saúde |
| OPEP | Organização dos Países Exportadores de Petróleo |
| RDD | <i>Regression Discontinuity Design</i> |
| VaR | <i>Value at Risk</i> |
| SQR | Soma dos Quadrados dos Resíduos |

LISTA DE SÍMBOLOS

| | |
|------------------|---|
| % | Porcentagem |
| F | Distribuição de Probabilidade |
| H_0 | Hipótese Nula |
| log | Logaritmo natural |
| δ | Derivada parcial |
| E | Valor Esperado |
| argmin | Argumento mínimo |
| \sum | Somatório |
| $efp(.)$ | <i>Empirical Flutuation Process</i> |
| \hat{J} | Estimativa da Matriz de Covariância |
| $W(.)$ | Movimento Browniano Padrão K-dimensional |
| λ_{comp} | Funcional que agrega sobre os k componentes |
| λ_{time} | Funcional que agrega ao longo do tempo |
| $d(t)$ | Função de ponderação |
| sup | Supremo |
| PSI | Função objetivo segmentada |
| min | Mínimo |
| m | Número de pontos de quebra |

SUMÁRIO

| | | |
|-------|---|----|
| 1 | INTRODUÇÃO | 14 |
| 2 | REVISÃO DE LITERATURA | 16 |
| 2.1 | Séries Temporais e Séries Financeiras | 16 |
| 2.2 | Quebras Estruturais | 17 |
| 2.3 | Eventos Mundiais e o Mercado Acionário | 20 |
| 3 | METODOLOGIA | 24 |
| 3.1 | Testagem e Datação de Mudanças Estruturais | 24 |
| 3.1.1 | <i>Teste de Flutuação M generalizado</i> | 24 |
| 3.1.2 | <i>Teste de Monitoramento</i> | 27 |
| 3.2.3 | <i>Datação das Quebras</i> | 28 |
| 3.2 | Correlação Local e Correlação Local Parcial | 30 |
| 4 | BASE DE DADOS | 33 |
| 4.1 | Índices Mundiais | 34 |
| 4.2 | Dados da Pandemia | 37 |
| 4.3 | Base de Dados Extendida | 39 |
| 5 | RESULTADOS | 40 |
| 5.1 | Teste de Flutuação | 40 |
| 5.2 | Monitoramento | 41 |
| 5.3 | Datação e Regressões Segmentadas | 43 |
| 5.4 | Análise Comparativa de Crises | 46 |
| 5.5 | Análise da Correlação Local e Correlação Local Parcial | 49 |
| 6 | CONCLUSÃO | 51 |
| | REFERÊNCIAS | 55 |
| | APÊNDICE A – GRÁFICOS TESTE DE FLUTUAÇÃO M | 58 |
| | APÊNDICE B – GRÁFICOS DE MONITONAMENTO | 60 |
| | APÊNDICE C – LOG-VEROSSIMILHANÇA NEGATIVA | 62 |
| | APÊNDICE D – REGRESSÕES SEGMENTADAS 2005 - 2021 | 64 |
| | APÊNDICE E – GRÁFICOS DA ANÁLISE WAVELET | 69 |

1 INTRODUÇÃO

A ocorrência de crises financeiras como a de 2007 – 2008 e mais recentemente a Pandemia de COVID-19 coloca em evidência a fragilidade dos Mercados Financeiros em meio a grandes eventos inesperados. Nesse contexto, diversos estudos buscam evidenciar a ocorrência e duração do efeito desses eventos na bolsa de valores e na Economia como um todo. Colocando em pauta questões como o controle do governo sobre a macroeconomia e sua capacidade de mitigação de danos, bem como na regulação do mercado financeiro, além da capacidade de gestão de risco dos investidores.

A retração na Economia como consequência do COVID-19, o novo coronavírus, é hoje visível no mundo todo. A descoberta dos primeiros casos, o aumento do contágio, o isolamento social necessário, o espalhamento do vírus pelo mundo, são alguns dos fatores que determinaram o pior desempenho da economia mundial. Muitos analistas tentam hoje estimar os efeitos da pandemia nas Economias dos países, mas qualquer estimativa desse tipo é ainda muito incerta por não se saber a real dimensão dos prejuízos causados.

Desde a descoberta dos primeiros casos, o mercado financeiro já mostrava sinais de preocupação com a doença que tinha início em uma das principais economias do mundo, a China. Esse comportamento por parte dos investidores pode ser visto analisando os índices das principais bolsas do mundo. Os índices das bolsas funcionam como um termômetro para o mercado de investimento, pois medem o desempenho de uma carteira teórica com uma composição ponderada das principais ações negociadas nesse mercado. Trata-se, portanto, de um importante indicador para os investidores que estão sempre atentos às mudanças e oscilações no mercado.

Os efeitos mais significativos foram sentidos em meados de março de 2020. Puxado por outros fatores para além do surto de Covid-19, entre eles a queda no preço do petróleo devido a um desacordo entre a Organização dos Países Exportadores de Petróleo (OPEP) e a Rússia para tentar cortar a produção da *commodity*, houve paralisações em diversas bolsas. Na bolsa brasileira, por exemplo o *Circuit Break*, mecanismo de segurança utilizado para interromper todas as operações da B3 caso as ações negociadas nesse mercado sofram grandes quedas consideradas atípicas em seus preços, foi acionado nos dias 9, 10, 11 e 16 de março.

Este trabalho busca entender e analisar os efeitos da COVID-19 nas bolsas mundiais, utilizando os principais índices de bolsas de 12 países que figuram entre os mais afetados pela crise sanitária. Para isso, utiliza-se metodologias de detecção de pontos de quebra, mais precisamente a desenvolvida por Zeileis (2005; 2007; 2010) e de estimação de correlação

dinâmica entre os mercados mundiais, de forma a fornecer evidências dos eventos associados a estas e de como se deu a propagação mundial. Além disso, evidencia-se a rápida recuperação das bolsas mundiais nesse período através de um comparativo com os fatos ocorridos na Crise Financeira 2007-2008.

Este estudo está organizado da seguinte maneira: seção 1, com esta introdução, a seção 2 visita algumas discussões importantes na literatura abrangendo o estudo de séries temporais, estimação de pontos de quebra e os efeitos de momentos de crise e incerteza nas bolsas de valores. Na seção 3 serão apresentadas as metodologias utilizadas na pesquisa, que consiste na identificação e seleção de pontos de quebra e posteriormente estimação de regressões segmentadas. Na seção 4 apresenta-se a base de dados, as principais estatísticas descritivas dessas séries e comentários sobre suas particularidades. A seção 5 traz a aplicação análise dos resultados obtidos. A seção 6 encerra este estudo revisitando alguns de seus pontos relevantes e trazendo algumas sugestões para futuros trabalhos.

2 REVISÃO DE LITERATURA

2.1. Séries Temporais e Séries Financeiras

As investigações empíricas dependem, em grande parte, de dados arranjados em forma cronológica e Análise de Séries Temporais (AST) e têm como objetivo descrever e analisar os comportamentos passados da série, visando à compreensão do comportamento da série e à consequente previsão de movimentos futuros (FONSECA et al., 1985).

Segundo Morettin e Tolo (2004), existem, basicamente, dois enfoques utilizados nos procedimentos de análise de séries temporais, ambos com objetivos determinados. No primeiro enfoque, a análise é realizada no domínio temporal, ou seja, é considerada a evolução temporal do processo e os modelos propostos são modelos paramétricos (com um número finito de parâmetros); já no segundo enfoque a análise é concebida no domínio de frequência e os modelos propostos são modelos não paramétricos.

Silva (2017) define ainda uma gama de possibilidades de análise obtidas através de uma série temporal, pode-se estar interessado em: investigar o mecanismo gerador da série temporal: fazer previsões de comportamento futuro da série; descrever o comportamento da série; ou ainda, procurar periodicidades relevantes nos dados.

As séries de dados temporais dos índices de mercado de ações são não-estacionárias com propriedades estatísticas que mudam sob diferentes campos de análise. Assim, a série de dados é dita heterogênea, o que significa que se pode obter diferentes valores de média, desvio padrão, etc., dependendo do intervalo de tempo em que são calculados. A análise e estudo de tais séries temporais é mais complicada porque os diversos métodos estatísticos comumente utilizados são baseados no pressuposto de estacionariedade dos dados analisados (YIN et al., 2015).

Grech e Mazur (2004) explicam que os mercados financeiros são sistemas dinâmicos abertos, complexos e não-lineares, descritos por um enorme número de parâmetros, em sua maioria desconhecidos e externos ao mercado, o que dificulta ainda mais a descrição completa do sistema. Os autores definem parâmetros externos como aqueles completamente fora do controle dos investidores, esses parâmetros normalmente têm origens aleatórias relacionadas com, por exemplo, distúrbios políticos, ataques terroristas, falências de empresas líderes, guerras, etc.

Além dos parâmetros externos, Grech e Mazur (2004) defendem ainda a existência de parâmetros internos, sendo estes dependentes dos investidores, que impulsionam o mercado,

mesmo na ausência de outros fenômenos externos inesperados. O pleno conhecimento de tais parâmetros internos é, por si só, um grande desafio para os economistas.

Dessa forma, Grech e Mazur (2004) afirmam que a evolução de um sistema financeiro ao longo do tempo é complexa e não pode ser prevista com detalhes. No entanto, mesmo que não se possa prever com exatidão o cenário e a evolução detalhada do mercado, é possível extrair algumas informações macroscópicas úteis do sistema. Fazendo uma analogia com a mecânica estatística, onde não é necessário saber com precisão a velocidade e localização de uma partícula para determinar o estado do sistema, por meio de parâmetros macroscópicos. Tais parâmetros são basicamente suficientes para aplicações práticas, como por exemplo, determinar a temperatura ou pressão do sistema em determinado momento.

2.2 Quebras Estruturais

A análise e o estudo de quebra estrutural estão associados com a econometria de séries temporais, sendo que por quebra estrutural entende-se que há uma ou mais mudanças no nível da série, na dispersão e/ou na inclinação. Segundo Stock & Watson (2004) essas mudanças nos parâmetros podem surgir em uma data precisa ou através de uma evolução gradual ao longo de um determinado período. Podendo ser resultado de mudanças na política econômica de um país, por exemplo a política de juros baixos atualmente adotada, assim como choques de forças externas.

Conforme Hansen (2001), o estudo prático e aplicado das séries de tempo é baseado na premissa de que ela é estacionária, sendo seus parâmetros, como a média e variância, estáveis ao longo do tempo. Essa premissa é violada se há uma quebra na série e caso essa informação não seja considerada, pode-se ter parâmetros viesados. Além disso, a presença de quebra estrutural pode tornar o desempenho de testes de raiz unitária viesado. Dado que as quebras podem interferir nas inferências e interpretações de modelos econométricos, o pesquisador precisa estar atento tanto com a identificação como com a modelagem das mesmas.

Shikida et al (2016) dividem a literatura de quebras em três subtópicos: 1) testes que procuram identificar a existência de quebra estrutural, 2) testes que buscam estimar a data da quebra e 3) testes que examinam a relação entre raiz unitária e quebra estrutural. As informações acerca desses subtópicos são resumidas no Quadro 1.

Quadro 1: Principais contribuições da Literatura de Quebras Estruturais

| | |
|--|--|
| <p>Testes que procuram identificar a existência de quebra estrutural</p> | <p>Chow (1960) compara um modelo restrito (até a data da quebra) contra um modelo irrestrito, sendo a hipótese nula a ausência de quebra.</p> <p>Quandt (1960) adapta o teste de Chow para o caso de uma quebra em data desconhecida ou conhecida dentro de um intervalo. Nesse caso utiliza-se a Razão de Verossimilhança de Quandt, também conhecida como estatística sup-Wald.</p> <p>O desconhecimento da data da quebra impedia a obtenção de valores críticos apropriados, fazendo com que o sup-Wald não tivesse aplicação prática. No início da década de 1990 esse tema foi abordado e solucionado por vários autores, destaca-se os trabalhos de Andrews (1993), Andrews & Ploberger (1994).</p> <p>Bai e Perron (1998) desenvolvem um método para múltiplas quebras. O método opera de forma sequencial. Primeiro testa-se a existência de uma única quebra. Caso a hipótese nula de constância dos parâmetros seja rejeitada, a amostra é dividida em duas (na data da quebra) e uma nova rodada de testes é realizada em cada subamostra. Os testes sequenciais continuam até que hipótese nula de ausência de quebra não seja rejeitada para cada subamostra. Perron (2005) pondera que o procedimento precisa ser realizado com cuidado, sendo comuns os casos em que o procedimento é encerrado com subestimação do número de quebras.</p> |
| <p>Testes que estimam a data da quebra</p> | <p>Bai (1994) estabelece os primeiros fundamentos para os testes de estimação de quebra, seguidos dos trabalhos de Bai (1997a, 1997b apud Zeileis et al., 2003) e Bai & Perron (1998). No teste de Bai-Perron, a amostra é dividida em subamostras nos candidatos a quebra e, nas subamostras, são estimados os parâmetros por MQO, com o cálculo e armazenamento da soma dos quadrados dos resíduos (SQR). Em seguida, o teste busca as datas das quebras que minimizam o SQR total, de toda a amostra.</p> |
| <p>Testes que examinam a relação entre raiz unitária e quebra estrutural</p> | <p>Perron (1989) argumenta que quando há quebra estrutural o teste Augmented-Dickey-Fuller (ADF) é estatisticamente viesado, a favor da não rejeição da hipótese nula de raiz unitária. O autor apresentou uma versão estendida do teste, considerando uma possível mudança de intercepto, inclinação ou ambos. Encontrando evidências que várias das séries de tendência estocástica estudadas por Nelson e Plosser (1982), na verdade eram <i>break</i>-estacionária. Ou seja, as séries eram estacionárias em torno de uma tendência determinada com quebra estrutural.</p> |

Fonte: *Elaboração Própria. Shikida et al (2016)*

Nesse trabalho, o enfoque é dados aos testes que estimam a data da quebra. Hansen (2001) afirma que, em muitas ocasiões, saber a data da quebra pode ser útil. Ao estimar essas datas, é possível confrontar com a informação obtida com os dados contra eventos históricos e sugerir quais destes teriam impacto significativo nas séries estudadas.

Segundo Zeileis (2005), existe uma ampla gama de métodos para detectar alterações estruturais ou instabilidades de parâmetros em modelos paramétricos. Cada um desses testes foi desenvolvido com foco em diferentes propriedades.

Os testes CUSUM ou CUSUMQ, desenvolvidos por Brown et al. (1975), foram as primeiras tentativas de localizar quebras estruturais assumindo que o ponto de quebra é desconhecido. Nesse método, calcula-se os parâmetros por mínimos quadrados de forma recursiva ao longo do tempo, senão há mudança no parâmetro, então α_t converge para α .

Esses testes normalmente são derivados sem ter um padrão específico de desvio da estabilidade dos parâmetros e foram enfatizados para serem também adequados como ferramenta exploratória. Em particular, testes de flutuação baseados em resíduos de OLS, como os testes CUSUM e MOSUM baseados em OLS são populares porque são fáceis calcular e interpretar.

Mais tarde, Nyblom (1989) desenvolveu um teste LM baseado na Função de Máxima Verossimilhança. Com parâmetros não fixos, o autor define que eles seguem um passeio aleatório tal que: $\alpha_t = \alpha_{t-1} + v_t$. Usando a hipótese de que os parâmetros devem ser independentes no tempo, deve-se ter $v_t \sim \text{iid } N(0, \sigma^2)$. Esse modelo foi estendido por Hansen (1992) para modelos de regressão linear. Hjort e Koning (2002) sugeriram uma classe geral de testes de mudança estrutural com base na Função de Máxima Verossimilhança (sem mencionar explicitamente que isso generaliza o teste de Nyblom – Hansen).

Uma outra classe de testes são os baseados nas estatísticas F (estatísticas de teste Wald, LR e LM). Esses testes foram desenvolvidos como uma alternativa a uma única mudança em um momento desconhecido. A teoria assintótica foi estabelecida para modelos estimado por métodos generalizados de momentos (GMM) por Andrews (1993) enfocando o teste *sup* F intuitivo e estendido por Andrews e Ploberger (1994), que mostraram que os testes *ave* F e *exp* F desfrutaram de certas propriedades de otimização.

Apesar de desenvolvidos para diferentes alternativas (não específico/passeio aleatório /mudança única) e para diferentes técnicas de estimação (OLS / LM / GMM), esses testes estão bastante relacionados entre si.

Zeileis e Hornik (2003) propõem uma visão unificadora de todas essas estruturas de testes incorporando representantes das três classes citadas na estrutura de teste de flutuação

M generalizada. Mais precisamente, os autores mostram que os testes que são baseados em uma única estimativa dos parâmetros na amostra completa (e não em múltiplas estimativas de crescimento recursivo ou subamostras rotativas) são na verdade casos especiais na estrutura da flutuação M.

Os testes de flutuação M são sempre derivados nas seguintes etapas:

1. Escolha um modelo e uma técnica de estimação
2. Calcule o processo de soma parcial das pontuações para as quais um teorema do limite central funcional (FCLT) é válido, e
3. Calcule uma estatística aplicando um funcional escalar que captura as flutuações no processo.

Portanto, os testes unificados são baseados no mesmo FCLT e basta usar diferentes funcionais para calcular um teste estatístico. Essa visão também ajuda a separar a técnica de estimativa dos funcionais empregados.

2.3 Eventos Mundiais e o Mercado Acionário

Ao investigar as causas dos principais movimentos do mercado de ações norte-americano, Siegel (2008) encontra que, entre 1885 e 2006, menos de um em cada quatro alterações diárias de mais de 5% (alta ou baixa) podem estar ligadas a um evento de notícias de grande importância política ou econômica. Para o autor, isso confirmaria a imprevisibilidade do mercado e a dificuldade em prever os movimentos dos preços das ações. Os investidores que no pânico da eclosão da Primeira Guerra Mundial venderam suas ações perderam 1915, ano que registra o melhor aumento em um único ano na história da Dow Jones, com as ações subindo um recorde de 82%. Os estoques continuaram subindo em 1916 e atingiram seu pico em novembro, com preços mais altos do dobro do nível em que estavam quando a guerra começou. Mas aqueles que compraram no início da Segunda Guerra Mundial, esperando uma repetição dos ganhos da Primeira Guerra Mundial, foram frustrados pela determinação do governo em limitar os lucros nesse período de guerra.

Os autores analisam ainda o efeito de outros conflitos como Guerra da Coreia (1950- 1953), Guerra do Vietnã (1955-1975) e a do Iraque (2003-2011), reportando que épocas de paz são de maior retorno, mas também são de maior volatilidade. Em teoria, guerras seriam períodos negativos para a bolsa, pois os governos direcionam recursos para os esforços de guerra, o que costuma envolver aumento de impostos e da dívida pública. Além disso, pode

haver a possibilidade de sanções no caso de derrota no conflito. Não há, entretanto, um padrão, visto que economias que saíram derrotas da Segunda Guerra Mundial, como a japonesa e alemã, se recuperaram relativamente rápido. De maneira geral, o autor conclui que eventos mundiais podem impactar profundamente o mercado no curto prazo, mas eles se mostraram incapazes de diminuir os retornos de longo prazo característicos das ações.

Hsu (1979) investiga a estabilidade da volatilidade do retorno semanal do Dow Jones de 02/07/1971 a 02/08/1974, aproximada por uma AR (1) para capturar potenciais autocorrelações. Assumindo que a média é constante e (aproximadamente) conhecida, o autor foca no estudo apenas da variância da série, encontrando um claro intervalo em meados de março de 1973. O período em questão compreende tanto alta (até no início de 1973) quanto baixa (no início de 1973) nos mercados de ações. Com alguns fatores agravantes no cenário político (como o caso Watergate em 1972), no cenário internacional (crise do petróleo em 1973) e um aumento constante das taxas de juros básicas nos EUA durante a última parte deste período.

Seguindo essa abordagem, Zeileis e Hornik (2007), utilizam a mesma base de dados, mas avaliando estabilidade tanto da média quanto da variância da série. Os parâmetros estimados são testados usando o processo de flutuação M e o funcional duplo máximo. Utilizando um nível de significância de $\pm 5\%$, Zeileis e Hornik (2007) argumentam que conforme um dos processos atravessa seu limite, há evidências de uma instabilidade geral do parâmetro no modelo. A flutuação no processo para a média encontrada é moderada e não significativa, enquanto há um aumento claro e significativo para o processo de variância, pode-se concluir que esta instabilidade é causada por uma mudança na variância enquanto a média permanece constante. Além disso, o pico claro no processo de variância transmite a informação de que há um único aumento abrupto na variância em março de 1973, correspondendo à quebra encontrada por Hsu (1979).

Zhang e Tian (2017) propõem um teste semiparamétrico para o problema de múltiplos pontos de quebra usando a probabilidade empírica máxima para obter as estimativas desses pontos. Utilizando simulações, é demonstrado que a abordagem sequencial é válida para encontrar o número de quebras e as estimativas dos pontos de mudanças são consistentes.

Utilizando dados da Bolsa de Valores de Xangai de 4 de setembro de 2006 a 11 de julho de 2014, Zhang e Tian (2017) encontram dois pontos de quebra: o primeiro na observação 222 (01/08/2007), e o segundo na observação 525 (30/10/2008). O primeiro ponto de mudança corresponde ao início da crise financeira global em 2008. Isso implica que antes e depois desse ponto, a distribuição do retorno das ações mudou, entrando em um período de crise. O segundo ponto de mudança corresponde a crise financeira em si, com os mercados

financeiros da China sendo confrontados com o pior período naquela tempestade financeira. Os autores também aplicam testes usando um conjunto de dados suavizados (utilizando preço de abertura, fechamento, máximo e mínimo) obtendo estimações de quebra nas observações 222 e 527. Apesar da proximidade entre os resultados, argumenta-se o conjunto de dados utilizando somente o preço de fechamento parece mais confiável pois os dados suavizados irão reduzir a sensibilidade no mercado.

Investigando um evento mais específico no mercado brasileiro, Oliveira e Rocco (2018) investigam os efeitos do processo de impeachment da ex-presidente Dilma Rousseff sobre o mercado acionário brasileiro. Com a tese de que essas modificações no cenário político têm impacto nas expectativas dos investidores e consequentemente no risco. Essa análise é feita pelo método de *Regression Discontinuity Design* (RDD) considerando que esse processo pode ser visualizado como uma variação exógena que afetou os investidores a partir de determinada data, ou seja, investiga-se se há uma descontinuidade pré e pós-afastamento e pré e pós-impeachment, isto é: antes e depois do tratamento.

Calculando o *value at risk* semanal de 132 ações no período de janeiro de 2015 a fevereiro de 2018 via regressão quântica, os resultados obtidos apontam a presença de efeitos significativos tanto para o afastamento quanto para o impeachment sobre o VaR das ações de empresas brasileiras, porém em uma parcela inferior a 20% do total de ativos analisados. Para os dois eventos, foram detectadas mais incidências positivas, com redução na medida de risco, ocasionando em maiores prêmios de risco e menores estimativas para o VaR (OLIVEIRA; ROCCO, 2018).

Estudando o efeito da pandemia em doze bolsas de valores mundiais, Zhang, Hu e Ji (2020) realizam uma análise estatística simples mostrando que o risco do mercado financeiro, medido pelo desvio padrão, e o risco sistêmico, pelas correlações, aumentam substancialmente em resposta à pandemia.

Comparando os meses de fevereiro e março de 2020, o desvio padrão médio passou de 0,0071 para 0,0196, sendo a China o único país onde houve redução de 0,0098 para 0,0084 e os Estados Unidos o que mais aumentou de 0,0069 para 0,0268. Segundo os autores, esse movimento não pode ser explicado de maneira única pelas expectativas de longo prazo pois, é quase certo que os fatores sentimentais desempenham um papel importante nesse processo, que é ainda mais amplificado pela disseminação de informações via mídias sociais.

Na análise do risco sistêmico, as correlações são calculadas com base em dados diários em um horizonte semanal, totalizando 8 observações. As correlações são relativamente

baixas em fevereiro, mas aumentam substancialmente em março, sendo que o nível mais alto aparece em 06/03/2020.

Albulescu (2020) traz o enfoque empírico do efeito dos anúncios oficiais de infectados e índices de fatalidade no novo coronavírus no mercado financeiro dos Estados Unidos. De maneira geral, a crise sanitária aumenta a volatilidade realizada do S&P500, de forma que seu prolongamento é um grande desafio para os gestores de risco. Utilizando o método de OLS e RLS, sendo o último menos sensível a à *outliers*, tanto o nível de infectados quanto a fatalidade mundial do vírus tem mais impacto na volatilidade realizada do que as variáveis pandêmicas locais.

Chevalier (2020) investiga os efeitos da pandemia de COVID-19 no contágio financeiro. Utilizando árvores de decisão e gráficos de mosaico, metodologias de Ciência de Dados, as análises revelam uma forte concentração de mercados de ações despencando em 16 de março de 2020, após um pico de infecção detectado em 3 de março.

Okorie e Lin (2020) fornece evidências empíricas sobre o efeito fractal de contágio do COVID-19 no mercado de ações das 32 principais economias afetadas pelo coronavírus (a partir de 31 de março de 2020). As técnicas de DMCA (*Detrended Moving Cross-Correlation Analysis*) e DCCM (*Detrended Cross-Correlation Analysis*) são usadas para testar a hipótese do efeito de contágio. Os resultados mostram que existe um efeito contágio significativo, mas de curta duração, tanto nos retornos como na volatilidade do mercado como resultado da pandemia de COVID-19.

Ainda no contexto da pandemia, Matos, Costa e Silva (2020) utilizam uma metodologia de domínio frequência para avaliar a relação condicional entre o retorno do S&P 500 e os casos ou mortes por COVID-19 em Hubei, China, países com registros mortes e no mundo. Analisando o período de 29 de janeiro a 30 de junho de 2020, os resultados indicam que os ciclos de curto prazo de mortes na Itália nos primeiros dias de março e, logo após, os ciclos de mortes no mundo lideram o mercado de ações dos EUA fora de fase.

Matos, Costa e Silva (2020) realizam ainda testes de dissimilaridades, causalidade de Granger e Coerência Parcial entre os índices setoriais e o S&P500, visando observar o contágio setorial. Nesta análise, o setor de energia foi o primeiro a reagir à pandemia e o que apresentou maiores perdas e volatilidade.

3 METODOLOGIA

Nesta seção serão abordadas as metodologias utilizadas no estudo. Na seção 3.1 apresenta-se a identificação de quebras proposta por Zeileis e Hornik (2003), que utiliza o teste de flutuação M generalizado para testar, monitorar e datar mudanças estruturais. Na Seção 3.2, aborda-se brevemente o *Multivariate Locally Stationary Wavelet Process* (LSW) proposto por Park et al (2014), que permite a estimação da dependência linear temporal entre séries de tempo.

3.1. Testagem e Datação de Mudanças Estruturais

3.1.1 Teste de Flutuação M generalizado

Assumindo n observações de uma variável dependente y_i e sua primeira defasagem y_{i-1} , tal que a distribuição condicional $y_i|y_{i-1}$ segue uma quase-verossimilhança $f(\cdot)$ com parâmetros θ_i , ou seja:

$$y_i \sim f(y_{i-1}, \theta_i), \text{ onde } i = 1, \dots, n. \quad (1)$$

Pode-se definir a Hipótese Nula de parâmetros estáveis de acordo com a equação (2), onde a Hipótese alternativa (negação da estabilidade) seria que pelo menos um dos parâmetros varia no tempo.

$$H_0: \theta_i = \theta_0 \quad (i = 1, \dots, n) \quad (2)$$

Assumindo a hipótese de estabilidade, os parâmetros θ podem ser estimados minimizando a log-verossimilhança negativa $\Psi_{NLL}(y_i, y_{i-1}, \theta) = -\log f(y_i|y_{i-1}, \theta)$, o parâmetro estimado $\hat{\theta}$ pode ser calculado a partir das condições de primeira ordem da equação (3), resultando na equação (4) onde $\psi(y_i, y_{i-1}, \theta) = \delta(\Psi_{NLL}(y_i, y_{i-1}, \theta))/\delta\theta$. Ou seja, deve-se ter valor esperado zero nos parâmetros verdadeiros: $E(\psi(y_i, y_{i-1}, \theta_i)) = 0$.

$$\underset{\theta \in \Theta}{\operatorname{argmin}} \sum_{i=1}^n \Psi(y_i, y_{i-1}, \theta) = \hat{\theta} \quad (3)$$

$$\sum_{i=1}^n \psi(y_i, y_{i-1}, \hat{\theta}) = 0 \quad (4)$$

As somas parciais correlacionadas à esquerda da expressão (4) podem ser usadas como o processo de flutuação que captura mudanças estruturais ao longo do tempo. O processo de pontuação cumulativa resultante é referido como o processo de flutuação empírico $efp(\cdot)$ e é formalmente definido como:

$$W_n(t, \theta) = n^{-1/2} \sum_{i=1}^{[nt]} \psi(y_i, y_{i-1}, \hat{\theta}) \quad (5)$$

$$efp(t) = \hat{J}^{-1/2} W_n(t, \hat{\theta}) \quad (6)$$

Onde \hat{J} é uma estimativa consistente adequada da matriz de covariância das pontuações $\psi(Y_i, \theta)$. O estimador mais simples seria:

$$\hat{J} = n^{-1} \sum_{i=1}^n \psi(y_i, x_i, \theta) \psi(y_i, x_i, \theta)^T \quad (7)$$

Sob a hipótese nula e considerando o FCLT (Teorema Central do Limite Funcional ou o teorema de Donsker): no intervalo $[0, 1]$, o processo de flutuação empírica $efp(\cdot)$ converge para uma ponte browniana k-dimensional $W^0(\cdot)$, que também pode ser escrita como $W^0(t) = W(t) - tW(1)$, em que $W(\cdot)$ é um movimento browniano padrão k-dimensional.

Enquanto o processo de flutuação empírica efp é governado pelo FCLT sob a hipótese nula de estabilidade dos parâmetros, na hipótese de mudança estrutural esse processo deve, geralmente, crescer. Em outras palavras, o efp exibe picos no momento em que mudanças em θ_i ocorrerem. Dessa forma, a comparação entre o efp calculado e o FCLT associado a este é a base do teste.

Para definir uma estatística de teste com base no processo de flutuação empírica é necessário um escalar funcional que capture as flutuações no processo. A distribuição limitante correspondente é então determinada pela aplicação do funcional ao processo limitante. Existem soluções de forma fechada para as distribuições implícitas em certos funcionais, mas valores críticos podem ser obtidos facilmente por simulações para qualquer tipo de funcional.

Enquanto o processo empírico é essencialmente uma matriz com n observações ao longo do tempo e k componentes (geralmente correspondentes aos parâmetros), essa função pode normalmente ser dividida em um funcional λ_{comp} que agrega sobre os k componentes (parâmetros) e um funcional λ_{time} que agrega ao longo do tempo. Se λ_{comp} é aplicado primeiro, é obtido um processo univariado que pode ser inspecionado para mudanças ao longo do tempo. No entanto, aplicando λ_{time} primeiro, o resultado é k estatísticas de teste independentes de modo que o componente / parâmetro que causa a instabilidade pode ser identificado.

Seguindo Zeileis (2005), o teste estatístico unificado tem a seguinte forma:

$$\lambda_{time} \left(\frac{\lambda_{comp}(efp(t))}{d(t)} \right) \quad (8)$$

Onde $d(t)$ é uma função de ponderação. Portanto, estatísticas baseadas nas pontuações de ML, Estatísticas F e resíduos de MQO podem ser apontadas com base no mesmo processo de flutuação empírica (e o mesmo FCLT). A única diferença é na escolha dos funcionais λ_{time} , λ_{comp} , e da função d .

A ideia básica dos testes de flutuação M é que desvios da estabilidade dos parâmetros podem ser obtidos através da avaliação de desvios das funções empíricas de estimativa $\psi(y_i, x_i, \hat{\theta})$ de sua média zero. Isso é feito aplicando algum funcional $\lambda(\cdot)$, conforme representado na equação (8), que agregue o processo de flutuação empírica $\lambda(efp)$, produzindo uma estatística de teste univariada. A distribuição limitante correspondente é o mesmo funcional (ou seu equivalente assintótico) aplicado a uma ponte browniana $\lambda(W^0)$ para que valores críticos e p-valores possam ser derivados.

Zeileis et al (2010) estabelece 4 casos especiais de funcionais:

$$S_{dmax} = \sup_{t \in [0,1]} \|efp(t)\|_{\infty} \quad (9)$$

$$S_{cvM} = n^{-1} \sum_{i=1}^n \|efp(i/n)\|_2^2 \quad (10)$$

$$S_{MOSUM} = \sup_{t \in [0,1-h]} \|efp(t+h) - efp(t)\|_{\infty} \quad (11)$$

$$S_{\text{sup}LM} = \sup_{t \in [\pi, 1-\pi]} \frac{\|efp(t)\|_2^2}{t(1-t)} \quad (12)$$

A questão de qual estatística adotar também é explorada pelos autores. A estatística S_{dmax} é particularmente útil para propósitos exploratórios, pois pode ser facilmente visualizada juntamente com valores críticos (derivados da distribuição do máximo de uma ponte browniana) para que o momento de uma mudança estrutural e o parâmetro afetado por ela possam ser identificados graficamente. No entanto, esse teste pode ter pouco poder na presença de uma alternativa de passeio aleatório ou de várias quebras. Em tal situação, uma estatística S_{CVM} ou S_{MOSUM} seria mais adequada. A estatística $S_{\text{sup}LM}$ é particularmente adequada para alternativas de quebra única. Além disso, as estatísticas de teste que empregam a norma L_2 para agregar os componentes do processo de flutuação (como S_{CVM} ou $S_{\text{sup}LM}$) terá melhor desempenho se vários (ou mesmo todos) componentes do vetor de parâmetros mudar ao mesmo tempo. Por outro lado, se apenas um dos muitos componentes no vetor de parâmetros estiver sujeito a uma mudança estrutural, as estatísticas baseadas na norma L_∞ (como S_{dmax} e S_{MOSUM}) normalmente terão maior poder.

3.1.2 Teste de Monitoramento

Se um modelo estável pode ser estabelecido para as observações $i = (1, \dots, n)$, A pergunta que se faz é se esse modelo permanece estável para observações $i = (n + 1, n + 2, \dots)$. Mais formalmente, o teste de monitoramento consiste em testar sequencialmente se:

$$H_0: \theta_i = \theta_0 \quad (i > n) \quad (13)$$

Ou seja, se a hipótese de estabilidade é válida para o período posterior contra a hipótese de que há alterações no chamado período de monitoramento ($i > n$).

Para isso basta estender o processo de flutuação empírica $efp(t)$ no período de monitoramento, calculando a função de estimação empírica para cada nova observação e atualizando o processo de soma cumulativo.

Esse processo ainda é governado por um FCLT em um intervalo prolongado $[0, T]$, com $T > 1$. Através desse FCLT, pode ser estabelecido um procedimento de teste que recalcula o funcional $\lambda(efp(t))$ para cada nova observação. A rejeição de H_0 ocorre se o valor calculado

exceder algum valor crítico de $b(t)$ para qualquer $t > 1$. Trata-se, portanto, de um teste sequencial, de forma que não basta um único valor crítico, mas sim uma função limite $b(t)$ para o processo de flutuação empírica.

Seguindo Zeileis et al (2010), para produzir um procedimento de teste de nível α , ele precisa cumprir:

$$1 - \alpha = P(\lambda(W^0(t)) \leq b(t) | t \in [1, T]) \quad (14)$$

Zeileis (2005) lista várias combinações de funcionais λ e limites $b(t)$ concebíveis que podem direcionar o poder contra mudanças que ocorrem logo no início do período de monitoramento ou mais ao final, ou ainda que tentam espalhar o poder uniformemente.

Nessa aplicação utiliza-se uma função funcional máxima e uma função limitante linear $b(t) = \pm c \cdot t$, que segundo Zeileis (2005) dão um certo nível de uniformidade no poder do teste. Dessa forma, uma quebra é detectada (H_0 rejeitada) se:

$$\|efp(t)\|_\infty > c \cdot t, \text{ onde } t \in [0, T] \quad (15)$$

3.1.3 Datação das Quebras

Uma das formas mais utilizadas de representar essa instabilidade é através de um modelo de regressão segmentado, ou seja, assumir conjuntos estáveis de parâmetros $\theta^{(j)}$ existem para $j = (1, 2, \dots, m)$ segmentos mutuamente exclusivos e cobrem o período da amostra. O objetivo da datação é determinar estimativas dos m pontos de quebra e dos parâmetros específicos dos $m + 1$ segmentos, geralmente seguido por uma seleção de modelo subsequente para o número de pontos de interrupção m .

Assim, a função objetivo segmentada baseada em ψ é dada por:

$$PSI(i_1, \dots, i_m) = \sum_{j=1}^{m+1} psi(i_{j-1} + 1, i_j), \quad (16)$$

$$psi(i_{j-1} + 1, i_j) = \sum_{i=i_{j-1}+1}^{i_j} \psi(y_i, y_{i-1}, \hat{\theta}^{(j)}), \quad (17)$$

Onde $psi(i_{j-1} + 1, i_j)$ é o valor mínimo da função objetivo para o modelo ajustado no j -ésimo segmento com parâmetro estimado associado $\hat{\theta}^{(j)}$. Encontram-se então os otimizadores globais $\hat{l}_1, \dots, \hat{l}_m$ da função objetivo segmentada. Isto é, resolve-se a equação (18) sujeito a uma restrição do tamanho mínimo do segmento $i_j - i_{j-1} + 1 \geq n_h \geq k$. O tamanho mínimo do segmento é escolhido diretamente ou derivado de n_h . O conjunto ótimo de pontos de quebra com respeito a ψ da equação (18) é chamado de partição m $l_{m,n} = [\hat{l}_1, \dots, \hat{l}_m]$.

$$(\hat{l}_1, \dots, \hat{l}_m) = \underset{i_1, \dots, i_m}{\operatorname{argmin}} PSI(i_1, \dots, i_m), \quad (18)$$

A otimização direta na equação (18) por busca exaustiva sobre todas as partições possíveis é de ordem n^m , o que torna computacionalmente oneroso. Felizmente, o princípio de otimização de Bellman pode ser aplicado ao problema de forma recursiva como:

$$PSI(l_{m,n}) = \min_{mn_h \leq i \leq n - n_h} [PSI(l_{m-1,i}) + psi(i + 1, n)]. \quad (19)$$

Assim, uma aproximação de programação linear pode ser empregada para resolver a minimização global. Esse processo é detalhado por Bai e Perron (2003), que descreve como um algoritmo de programação linear pode ser usado para minimizar a soma dos resíduos quadrados segmentados (RSS) em modelos de regressão linear.

Zeileis et al (2010) resume o processo em dois passos: Inicialmente, o algoritmo computa uma matriz triangular com $psi(i, j)$ para todo $j - i \geq [nh]$ e $i = 1, \dots, n - [nh] + 1$. A partir dessa matriz, o problema da equação (18) pode ser resolvido explorando a equação (19) para qualquer número de pontos de quebra m , tal que $(m + 1)[nh] < n$.

Através desse algoritmo, a segmentação ótima pode ser computada se o número de quebras m é conhecido. De maneira geral, a escolha de m pode ser feita com base nos próprios dados. Primeiramente computa-se a segmentação ótima para uma sequência de quebras $m = 0, 1, 2, \dots$, que pode ser computada da matriz triangular mencionada anteriormente, e escolhe-se m otimizando algum critério de informação $IC(m)$.

Considerando segmentações baseadas da função máxima verossimilhança, tais critérios de informação são facilmente calculados. Assim, se $PSI(l_{m,n})$ é baseado no Ψ_{NLL} , pode-se considera-lo como $NLL(l_{m,n})$ e o critério de informação é:

$$IC(m) = 2 \cdot NLL(l_{m,n}) + penalty \cdot ((m + 1)k + m) \quad (20)$$

A escolha da penalidade leva a diferentes critérios de informação. Bai e Perron (2003) considera dois critérios: BIC e o BIC Modificado:

$$penalty_{BIC} = \log(n) \quad (21)$$

$$penalty_{LWZ} = \alpha \cdot \log(n)^{2+\delta} \quad (22)$$

Nesse trabalho, seguindo as recomendações de Zeileis et al (2010) apud Bai Perron (2003), adota-se o critério *LWZ*, com as seguintes configurações: $\alpha = 0.299$ e $\delta = 0.1$. Assim, a penalidade é maior do que no critério BIC para $n > 20$.

3.2 Correlação Local e Correlação Local Parcial

Em função da globalização econômica e as facilidades de comunicação introduzidas pela internet nos últimos anos, a integração dos mercados financeiros mundiais tem se tornado cada vez maior. Movimentos de preços em um mercado podem se espalhar facilmente e, em geral, instantaneamente para outros mercados.

Nesse sentido, mercados financeiros são mais dependentes um dos outros e para entender melhor a estrutura dinâmica financeira global é importante considerar os mercados em conjunto. Um mercado pode conduzir outro mercado sobre algumas circunstâncias, mas ser conduzido em outros momentos. Assim, saber se os mercados estão inter-relacionados é de grande importância em finanças.

Uma série temporal multivariada consiste de várias séries únicas chamadas de componentes. O estudo de séries multivariadas, apesar de considerar fatores individuais das séries como estacionariedade e autocorrelação, possui enfoque maior em estudar a relação entre esses componentes.

A partir do pressuposto de que as suposições de estacionariedade não são sustentáveis em muitas séries multivariadas, devido à estrutura de segunda ordem do processo mudando com o tempo, Park et al. (2014) propõem uma extensão da estrutura de *wavelet*

localmente estacionária de Nason et al (2000) para um contexto de séries multivariadas. Essa abordagem permite a estimativa da estrutura espectral dentro do canal e espectro cruzado.

Park et al. (2014) também introduzem os conceitos de correlação local (*local coherence*) e, crucialmente, correlação local parcial (*partial coherence*) dentro da configuração de *wavelet* multivariada localmente estacionária.

Seguindo a notação de Taylor et al (2014), seja o vetor $X_{t:T} = [X_{t:T}^{(1)}, X_{t:T}^{(2)}, \dots, X_{t:T}^{(P)}]'$ um processo estocástico com comprimento diádico, isto é, $T = 2^J$ para algum $J \in \mathbb{N}$, é dito um processo mutivariado LSW (*locally stationary wavelet*) se pode ser representado como:

$$X_{t:T} = \sum_{j=1}^{\infty} \sum_k V_j(k/T) \psi_{j,k}(t) z_{j,k}. \quad (23)$$

Onde $\psi_{j,k}$ denota o conjunto de *wavelets* discretos não decimados para cada par de nível j e localização k . Os vetores aleatórios $z_{j,k} = (z_{j,k}^{(1)}, \dots, z_{j,k}^{(P)})'$ são inovações não correlacionadas com expectativa zero e matriz variância-covariância $I_{P \times P}$. Finalmente, $V_j(u)$ denota a matriz da função de transferência triangular inferior $P \times P$ para um dado índice de nível reescalado no tempo $u := t/T \in (0,1)$. Algumas condições de suavidade são assumidas para os elementos da matriz da função de transferência, controlando seu comportamento (ver Park et al. 2014, para detalhes).

Dentro da estrutura de modelagem acima, o principal elemento de interesse é, sem dúvida, a matriz de função de transferência. Uma vez que as inovações são ortogonais com variância unitária e as *wavelets* não são específicos do canal, todas as formas de dependência entre e dentro dos canais devem ser capturadas pela matriz da função de transferência. A matriz da função de transferência também é útil na formação da representação espectral de uma série temporal LSW multivariada. Especificamente, o poder contido em um processo LSW multivariado é descrito pelo espectro multivariado de *wavelet* evolutiva (EWS) assumindo a forma:

$$S_j(u) = V_j'(u) V_j(u), \quad (24)$$

Onde $V_j'(u)$ denota a transposta de $V_j(u)$. O elemento diagonal $S_j^{(p,p)}(u)$ denota o auto espectro para o canal p , enquanto o elemento fora da diagonal $S_j^{(p,q)}(u)$, para $p \neq q$,

denota o espectro cruzado entre o par de canais p e q , e descreve como o poder no processo é compartilhado entre canais.

A estrutura multivariada LSW permite a geração de uma série temporal que possui propriedades espectrais definidas por um EWS multivariado especificado. Por outro lado, o interesse aqui reside em compreender a estrutura espectral para uma determinada série temporal LSW multivariada. Tal esquema foi proposto por Park et al. (2014), estimando o EWS multivariado, $\{\hat{S}_{j,k}\}$ para os níveis $j = 1, \dots, J$ e localizações $k = 0, \dots, T - 1$. Para começar, cada canal da série temporal é transformado de forma independente com base em uma determinada *wavelet* para determinar o vetor empírico de coeficiente *wavelet* $d_{j,k} = [d_{j,k}^{(1)}, \dots, d_{j,k}^{(P)}]'$, com elementos:

$$d_{j,k}^{(p)} = \sum_{t=1}^T X_t^{(p)} \psi_{j,k}(t). \quad (25)$$

O periodograma *wavelet* é então definido pela matriz estabelecida para cada par de nível localização como:

$$I_{j,k} = d_{j,k} d_{j,k}' \quad (26)$$

Refletindo um resultado de Nason et al. (2000) para séries temporais univariadas, Park et al. (2014) estabeleceram que a Equação (26) é enviesada e a variância do estimador não desaparece. Esses problemas são superados suavizando e corrigindo a estimativa do periodograma bruto na definição do estimador EWS multivariado:

$$\hat{S}_{j,k} = \sum_{l=1}^J \sum_{m=-M}^M (A^{-1})_{j,l} w_M(m) I_{l,k+m}. \quad (27)$$

Aqui, $w_M(m)$ denota a função de kernel simétrica no suporte compacto $m \in [-M, M]$ e $(A^{-1})_{j,l}$ é o (j, l) -elemento da matriz de produto interno *wavelet* de autocorrelação invertida.

A correção de viés na Equação (27) significa que a matriz espectral estimada $\hat{S}_{j,k}$ não é mais garantida como positiva definida. Isso leva a dificuldades em avaliar as quantidades

que são derivadas do EWS multivariado, como a coerência localizada e a coerência parcial. Para contornar esse fato, Taylor, Park e Eckley (2019) sustentam que as matrizes da estimativa EWS multivariada devem ser regularizadas usando, por exemplo, a abordagem de Schnabel e Eskow (1999) para garantir que as estimativas derivadas subsequentemente sejam elas próprias válidas.

A dependência dentro de uma série temporal multivariada pode ocorrer dentro ou entre os canais. A coerência fornece uma medida da dependência linear entre qualquer par de canais. No entanto, se a série temporal multivariada não é estacionária, então a medida de coerência pode variar ao longo do tempo. Park et al. (2014) introduziu o conceito de coerência local com base na estrutura de *wavelet* localmente estacionário definido anteriormente. Particularmente, a matriz de função de coerência local é definida por:

$$\rho_j(u) = D_j(u)S_j(u)D_j(u) \quad (28)$$

Onde $D_j(u) = \text{diag}\{[S_j^{(p,p)}(u)]^{-1/2} : p = 1, \dots, P\}$. Os elementos fora da diagonal das matrizes de coerência localizadas podem assumir qualquer valor entre $[-1, 1]$, onde a dependência linear forte é identificada por valores próximos de ± 1 . Embora esta medida de coerência forneça uma indicação de forte dependência entre um par de canais, não consegue distinguir se esta relação é direta ou indireta. Em outras palavras, ela não pode identificar se os relacionamentos ocorrem por causa de dependências diretas entre outros canais (observados).

Para quantificar a dependência linear direta, Park et al. (2014) introduziu a função de matriz de coerência parcial local. Para qualquer nível, isso é definido da seguinte forma:

$$\Gamma_j(u) = -H_j(u)G_j(u)H_j(u) \quad (29)$$

Onde $G_j(u) = S_j(u)^{-1}$ e $H_j(u) = \text{diag}\{[G_j^{(p,p)}(u)]^{-1/2} : p = 1, \dots, P\}$.

4 BASE DE DADOS

O estudo é dividido em 2 etapas, com bases de dados diferentes. Considera-se o retorno acionário de 12 países que figuraram entre os com mais casos confirmados, alguns mercados não foram incluídos pela ausência de dados. Inicialmente, visando um período de mais estabilidade para aplicação dos testes apresentados na seção anterior e comparabilidade entre um período relativamente estável e o período pandêmico, selecionou-se o período de

02/01/2019 à 22/01/2021. Na seção 4.3, buscando um comparativo para um período mais longo, a base de dados é expandida para o período que compreende entre 16/05/2005 e 22/01/2020, a escolha aqui se deve as exigências quanto ao número de observações do modelo de Park et al (2014).

4.1. Índices Mundiais

A base de dados é composta por 12 índices das principais bolsas mundiais em frequência diária (5 dias). Os espaços em branco, correspondentes à feriados nacionais e internacionais, foram preenchidos utilizando o dia anterior. Em geral, espera-se que essas séries contenham uma raiz unitária, pois a série demora para reverter uma tendência, isso caracteriza um elevado componente autorregressivo. Uma solução simples é realizar a log-linearização das séries. Assim, os retornos diários são calculados como $r_t = \ln(p_t) - \ln(p_{t-1})$.

Na tabela 1 traz-se algumas estatísticas descritivas das séries de retorno. Para efeito comparativo, a amostra foi dividida em duas (jan/2019 a dez/2019 e jan/2020 a dez/2021). Em 2019 todas as séries tiveram retorno médio diário positivo, já em 2020 o retorno foi menor para onze das doze séries (com exceção da bolsa japonesa que manteve o mesmo retorno médio do ano anterior), sendo negativo para Espanha, França, Itália e Reino Unido.

A comparação da média com a mediana nos fornece uma medida da assimetria da distribuição. Em particular, uma média mais elevada que a mediana nos diz que os valores no topo da distribuição estão muito distantes do centro, em comparação aos valores que estão na parte de baixo da distribuição. Nesse sentido, não há uma caracterização clara da assimetria dessas séries.

Em relação ao desvio padrão, medida clássica de risco nas séries de retorno, o índice que se mostra menos arriscado em 2019 é o canadense, com um desvio padrão de 0,45%, enquanto o mais arriscado é o argentino com desvio padrão de 4,03% traduzindo a tensão política e econômica do país. As demais séries têm desvio padrão em torno de 1%.

Em um comparativo dos dois períodos, nota-se que apenas a Argentina teve queda no desvio padrão, mas continuando com o nível de risco mais alto entre as séries estudadas (3,26%). A China passa a ter o menor desvio padrão (1,27%) sendo a que teve menor aumento na volatilidade. Merece destaque também a bolsa canadense que teve um aumento de mais de quatro vezes no desvio padrão, chegando à 2,07%. Para as outras séries, o desvio padrão em média dobrou de um período para o outro, passando para uma média de 2%.

Em relação aos retornos mínimos e máximos reportados, em 2019 não há baixas ou

altas significativas em 10 das séries. A primeira exceção é a China, que teve uma alta de 5,45% em 25/02/2019 após o adiamento do aumento das tarifas alfandegárias contra os produtos chineses nos Estados Unidos por um avanço nas negociações comerciais China - EUA e baixa de 5,75% em 08/03/2019 com o aumento da tensão nas relações comerciais com os Estados Unidos.

Já na Argentina, esses outliers podem ser associados à questões de política interna, a bolsa argentina despencou 47,69% em 12/08/2019 graças ao resultado das eleições presidenciais primárias argentinas. O então presidente, o liberal Mauricio Macri sofreu uma grande derrota para chapa kirchnerista, liderada por Alberto Fernández. A maior alta foi de 9,73% apresentada pela bolsa argentina em 13/08/2019 (dia seguinte a maior baixa) um sinal de *overreaction* do mercado.

Em 2020 o cenário é bem diferente, com mínimas variando entre -6,27% e -18,74, para Japão e Itália, respectivamente. As mínimas ocorrem entre os dias 12/03/2020 e 16/03/2020, sendo que em 8 índices (DAX, BVSP, GSPTSE, IBEX, CAC40, FTSEMIB, FTSE e MOEX) o pior retorno aparece em 12/03/2020, data em que a OMS passou a classificar a COVID-19 como pandemia mundial.

A maioria das máximas reportadas em 2020 ocorreram ainda no mês de março, para o Brasil a máxima ocorreu já em 13/03/2020 com um retorno de 13% frente a queda de 16% do dia anterior. Nesse ponto o Brasil tinha apenas 52 casos confirmados, indicando *overreaction* do mercado brasileiro.

Analisando a amostra como um todo, metade das séries (DAX, GSPTSE, SP500, CAC40, FTSEMIB e FTSE) tiveram sua máxima no dia 24/03/2020, com os anúncios de pacotes de estímulo à Economia em diversos países, especialmente os Estados Unidos com o maior pacote de estímulos de sua história - o equivalente a US\$ 2,2 trilhões, utilizados para pagar benefícios às famílias americanas afetadas pela crise, aos desempregados, para financiar um programa de crédito para pequenas empresas e para reforçar os cofres dos governos locais e os repasses a hospitais e ao sistema de saúde. Nesse dia, todas as bolsas analisadas operaram em alta, sendo a menor delas na China com 2,3% e a maior no Canadá com alta de 11%.

Tabela 1: Estatísticas Descritivas dos Retornos 02/01/2019 à 22/01/2021

| PAÍS | ÍNDICE | MÉDIA | | MEDIANA | | DESVIO PADRÃO | | MÍNIMO | | MÁXIMO | | | |
|----------------|---------|-------------------|---------------------------|-------------------|---------------------------|-------------------|---------------------------|-------------------|---------------------------|-------------------|---------------------------|--------|------------|
| | | Até 30/11/2019 | A partir de 01/12/2020 | Até 30/11/2019 | A partir de 01/12/2020 | Até 30/11/2019 | A partir de 01/12/2020 | Até 30/11/2019 | A partir de 01/12/2020 | Até 30/11/2019 | A partir de 01/12/2020 | DATA | |
| ALEMANHA | DAX | 0.0009 | 0.0001 | 0.0013 | 0.0000 | 0.0088 | 0.0199 | -0.0316 | -0.1305 | 12/03/2020 | 0.0331 | 0.1041 | 24/03/2020 |
| ARGENTINA | MERV | 0.0005 | 0.0014 | 0.0020 | 0.0005 | 0.0413 | 0.0322 | -0.4769 | -0.1563 | 12/08/2019 | 0.0973 | 0.0977 | 28/04/2020 |
| BRASIL | BVSP | 0.0009 | 0.0003 | 0.0010 | 0.0002 | 0.0114 | 0.0268 | -0.0381 | -0.1599 | 12/03/2020 | 0.0349 | 0.1302 | 13/03/2020 |
| CANADÁ | GSPTSE | 0.0007 | 0.0001 | 0.0007 | 0.0015 | 0.0047 | 0.0199 | -0.0188 | -0.1318 | 12/03/2020 | 0.0149 | 0.1129 | 24/03/2020 |
| CHINA | SSEC | 0.0006 | 0.0007 | 0.0000 | 0.0004 | 0.0114 | 0.0123 | -0.0575 | -0.0804 | 03/02/2020 | 0.0545 | 0.0555 | 06/07/2020 |
| ESPAÑA | IBEX | 0.0004 | -0.0005 | 0.0004 | 0.0000 | 0.0077 | 0.0206 | -0.0281 | -0.1515 | 12/03/2020 | 0.0249 | 0.0823 | 09/11/2020 |
| ESTADOS UNIDOS | SP500 | 0.0009 | 0.0006 | 0.0009 | 0.0017 | 0.0080 | 0.0207 | -0.0302 | -0.1277 | 16/03/2020 | 0.0338 | 0.0897 | 24/03/2020 |
| FRANÇA | CAC40 | 0.0009 | -0.0002 | 0.0016 | 0.0002 | 0.0084 | 0.0197 | -0.0364 | -0.1310 | 12/03/2020 | 0.0269 | 0.0806 | 24/03/2020 |
| ITÁLIA | FTSEMIB | 0.0010 | -0.0002 | 0.0009 | 0.0004 | 0.0093 | 0.0215 | -0.0291 | -0.1854 | 12/03/2020 | 0.0331 | 0.0855 | 24/03/2020 |
| JAPÃO | NIKKEI | 0.0006 | 0.0006 | 0.0006 | 0.0000 | 0.0085 | 0.0152 | -0.0305 | -0.0627 | 13/03/2020 | 0.0258 | 0.0773 | 25/03/2020 |
| REINO UNIDO | FTSE | 0.0004 | -0.0005 | 0.0007 | 0.0005 | 0.0072 | 0.0177 | -0.0328 | -0.1151 | 12/03/2020 | 0.0214 | 0.0867 | 24/03/2020 |
| RUSSIA | MOEX | 0.0009 | 0.0004 | 0.0005 | 0.0013 | 0.0070 | 0.0156 | -0.0202 | -0.0865 | 12/03/2020 | 0.0239 | 0.0743 | 19/03/2020 |

Fonte: *Elaboração própria*.

4.2 Dados da Pandemia

Foram coletadas informações publicamente disponíveis sobre número de casos e número de óbitos dos 12 países. Devido a imprecisão de número de infectados correntes, optou-se por utilizar número de novos casos e óbitos diários.

Gráfico 1 – Média Móvel de 7 dias (Casos)


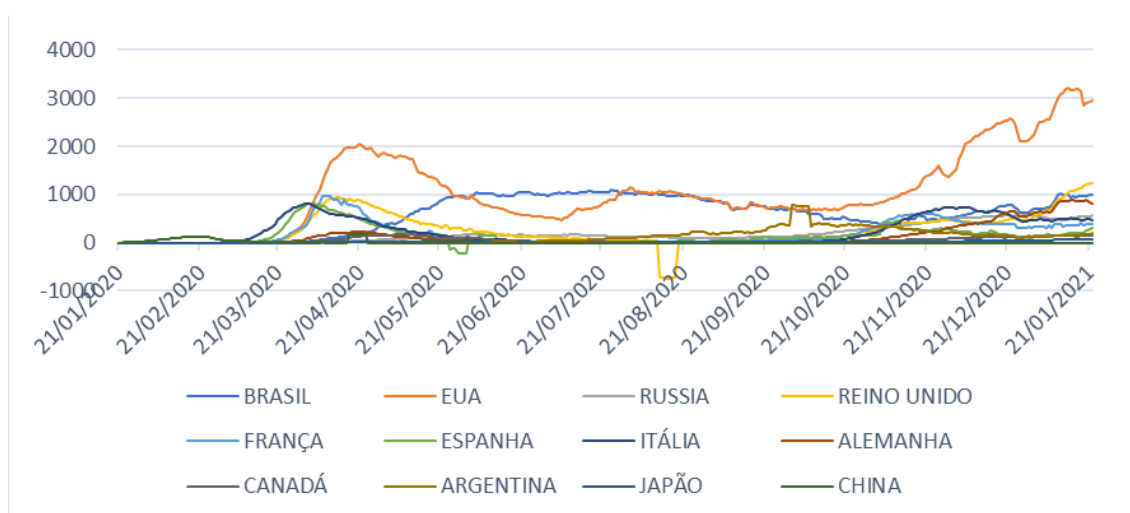


Gráfico 2 – Média Móvel de 7 dias (Óbitos)



A tabela 2 traz datas referentes a Confirmação do primeiro Caso e Óbito, Adoção de Medidas de Isolamento Iniciais e o Pico de Variação (considerado como o dia com maior variação percentual de casos confirmados entre dezembro de 2019 e dezembro

de 2020).

Tabela 2 – Datas referentes à Pandemia

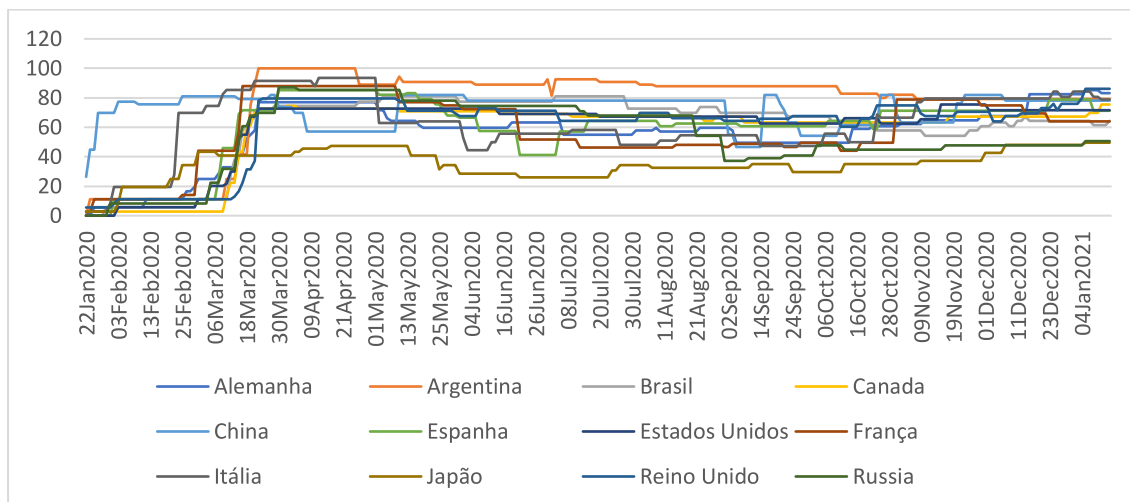
| País | 1º Caso | 1º Óbito | Isolamento Social | Pico de Variação |
|-------------|----------------|-----------------|--------------------------|-------------------------|
| Alemanha | 28/01/2020 | 10/03/2020 | 24/01/2020 | 28/01/2020 |
| Argentina | 04/03/2020 | 08/03/2020 | 23/01/2020 | 06/03/2020 |
| Brasil | 26/02/2020 | 18/03/2020 | 29/01/2020 | 05/03/2020 |
| Canadá | 26/01/2020 | 10/03/2020 | 22/01/2020 | 27/01/2020 |
| China | 01/12/2019 | 11/01/2020 | 05/01/2020 | 27/01/2020 |
| Espanha | 01/02/2020 | 05/03/2020 | 31/01/2020 | 25/02/2020 |
| EUA | 21/01/2020 | 01/03/2020 | 16/03/2020 | 28/02/2020 |
| França | 25/01/2020 | 15/02/2020 | 22/01/2020 | 27/02/2020 |
| Itália | 31/01/2020 | 23/02/2020 | 23/01/2020 | 21/02/2020 |
| Japão | 15/01/2020 | 13/02/2020 | 07/01/2020 | 14/02/2020 |
| Reino Unido | 01/02/2020 | 07/03/2020 | 02/02/2020 | 10/02/2020 |
| Rússia | 01/02/2020 | 27/03/2020 | 30/01/2020 | 06/03/2020 |

Fonte: Elaboração própria

Em relação aos indicadores da resposta do governo, utiliza-se o Índice COVID-19 de Rigor da Resposta do Governo¹, calculado e divulgado pela OXFOD, considerando 9 fatores: fechamento de escolas, fechamento de locais de trabalho, cancelamento de eventos públicos, restrições a aglomerações, fechamento de transporte público, restrições à circulação de pessoas, restrições a viagens internacionais e campanhas informativas.

¹ Para mais informações consulte <https://covidtracker.bsg.ox.ac.uk/>.

Gráfico 3 – Evolução Índice COVID-19 de Rigor da Resposta do Governo



4.3 Base de Dados Extendida

Para uma análise geral do comportamento dos mercados acionários considerados nesse estudo, a base de dados inicial foi estendida de forma a considerar os retornos diários no período entre 16/05/2005 e 22/01/2021, totalizando 4096 observações.

O número de observações é relevante para o cálculo da relação dinâmica entre os mercados. O pacote utilizado (mvLSW) exige que as séries temporais tenham tamanho diádico de forma que o número de observações seja 2^J para $J \in \mathbb{N}$.

As estatísticas descritivas relacionadas a esses dados constam na Tabela 3. Com exceção da bolsa italiana (FTSEMIB) com retorno médio de -0,01%, as médias dos retornos diários são positivas, sendo a maior referente a bolsa argentina (MERV) com um retorno médio em torno de 0,09%, sendo essa também a mais arriscada com um desvio padrão em torno de 2,23%.

Em relação à assimetria, os índices MERV, BVSP, SSEC, NIKKEI e MOEX apresentam assimetria positiva (média > mediana). Ou seja, há uma maior concentração no lado esquerdo da distribuição. Por outro lado, DAX, GSPTSE, IBEX, SP500, CAC40 e FTSEMIB possuem mediana > média, ou seja, valores mais altos que a média são mais frequentes.

Analisando os mínimos, oito das doze séries apresentam seu mínimo em

março de 2020, sendo sete delas no mesmo dia (12/03/2020). Para China, Japão e Rússia os mínimos se deram em meio à crise do *subprime*, respectivamente em 27/02/2007, 16/10/2008 e 06/10/2008. A Argentina continua com o posto de maior queda, quase 48%.

Tabela 3 – Estatísticas Descritivas (16/05/2005-22/01/2021)

| PAÍS | ÍNDICE | MÉDIA | MEDIANA | DESVIO | | |
|----------------|---------|---------|---------|--------|---------|--------|
| | | | | PADRÃO | MÍNIMO | MÁXIMO |
| ALEMANHA | DAX | 0.0003 | 0.0006 | 0.0135 | -0.1305 | 0.1080 |
| ARGENTINA | MERV | 0.0009 | 0.0003 | 0.0223 | -0.4769 | 0.1043 |
| BRASIL | BVSP | 0.0004 | 0.0000 | 0.0173 | -0.1599 | 0.1368 |
| CANADÁ | GSPTSE | 0.0002 | 0.0005 | 0.0113 | -0.1318 | 0.1129 |
| CHINA | SSEC | 0.0003 | 0.0001 | 0.0155 | -0.0926 | 0.0903 |
| ESPAÑA | IBEX | 0.0000 | 0.0003 | 0.0147 | -0.1515 | 0.1348 |
| ESTADOS UNIDOS | SP500 | 0.0003 | 0.0004 | 0.0123 | -0.1277 | 0.1096 |
| FRANÇA | CAC40 | 0.0001 | 0.0002 | 0.0138 | -0.1310 | 0.1059 |
| ITÁLIA | FTSEMIB | -0.0001 | 0.0002 | 0.0157 | -0.1854 | 0.1087 |
| JAPÃO | NIKKEI | 0.0002 | 0.0000 | 0.0144 | -0.1211 | 0.1323 |
| REINO UNIDO | FTSE | 0.0001 | 0.0001 | 0.0117 | -0.1151 | 0.0938 |
| RÚSSIA | MOEX | 0.0004 | 0.0000 | 0.0186 | -0.2066 | 0.2523 |

Fonte: Elaboração própria

5 RESULTADOS

5.1 Teste de Flutuação

Analisando os gráficos de flutuação no Apêndice A observa-se que a flutuação dos parâmetros com base no S_{dmax} , para o período pré-pandemia considerado (08/01/2019-30/11/2019), foi em geral pequena. As linhas vermelhas que representam os limites à 5% de significância é ultrapassada apenas pela variância na série chinesa. Esse fato pode ser associado a crescente tensão comercial com os Estados Unidos no período. Desde maio de 2019, os dois países endureceram a política comercial com novas tarifas incidindo sobre produtos importados, além de ameaças de novos aumentos tarifários.

Considerando os testes de flutuação da tabela 3, o S_{dmax} rejeita a hipótese nula de estabilidade no parâmetro autorregressivo para quatro séries: IBEX, SP500, CAC40 e FTSE. Para cinco séries (DAX, MERV, SP500, FTSEMIB e FTSE), apesar da não rejeição da hipótese de estabilidade, têm-se valores de teste muito próximos aos valores críticos, podendo levantar alguns questionamentos em relação à estabilidade.

Já para o S_{CVM} , sugerido por Zeileis et al (2010) como mais apropriado na presença de múltiplas quebras, a hipótese de estabilidade é rejeitada para metade das séries: MERV, BVSP, GSPTSE, SSEC, NIKKEI e MOEX. Esse resultado é aceitável devido à natureza de Passeio Aleatório desse tipo de série, sendo caracterizada por mudanças imprevisíveis.

Tabela 3- Testes de Flutuação

| País | Índice | S_{dmax} | P valor | S_{CVM} | P valor |
|-------------|---------|------------|---------|-----------|---------|
| Alemanha | DAX | 0.8724 | 0.8166 | 0.4573 | 0.4580 |
| Argentina | MERV | 0.8847 | 0.7990 | 0.4936 | 0.4149 |
| Brasil | BVSP | 1.1071 | 0.5433 | 0.5134 | 0.3915 |
| Canadá | GSPTSE | 1.2897 | 0.2004 | 0.8193 | 0.1090 |
| China | SSEC | 1.6268 | 0.0299 | 1.3393 | 0.0107 |
| Espanha | IBEX | 0.7220 | 0.9655 | 0.3079 | 0.6350 |
| EUA | SP500 | 0.8274 | 0.8752 | 0.4091 | 0.5151 |
| França | CAC40 | 0.7849 | 0.9199 | 0.3167 | 0.6246 |
| Itália | FTSEMIB | 0.8529 | 0.8434 | 0.3231 | 0.6170 |
| Japão | NIKKEI | 1.2397 | 0.2526 | 0.6058 | 0.2820 |
| Reino Unido | FTSE | 0.7762 | 0.9276 | 0.3868 | 0.5416 |
| Rússia | MOEX | 1.2199 | 0.2757 | 0.5172 | 0.3870 |

Fonte: Elaboração própria

5.2 Monitoramento

Nos gráficos de monitoramento do processo de flutuação (Apêndice B), observa-se que entre dezembro de 2019 e meados de fevereiro de 2020, apesar os indicativos iniciais da pandemia na China e início da disseminação em outros países, quase não há mudanças nos modelos estudados. Até mesmo na bolsa chinesa, verifica-se apenas uma mudança não significativa no processo de variância. Posteriormente, já com a maior disseminação do vírus no mundo, o intercepto também muda, mas não significativamente.

Esse cenário muda entre o final de fevereiro e início de março. Nota-se que com exceção de Argentina e China, as demais bolsas apresentam gráficos bem

semelhantes, com quebras significativas e mudanças tanto no componente autorregressivo quanto na variância. Esse fato claramente está relacionando à pandemia, apesar de outros fatores de instabilidade no período.

Conforme dados da Tabela 4, as primeiras quebras foram detectadas em 28/02/2020, em Rússia e Canadá. Nesta data, 49 países já haviam registrado casos da Covid-19. Naquele dia, ainda, a OMS classificou a situação como epidemia em vários países, mas a maioria dos casos eram de pessoas que visitaram os países por onde o vírus foi se espalhando, sem evidências de transmissão comunitária. Nesses dois países, por exemplo, não haviam óbitos registrados e o número de casos confirmados eram 2 e 16 respectivamente. Isso pode ser encarado como um temor antecipado do mercado, que gerou efeitos maiores do que o registrado em outros países. Além disso, as duas séries possuem estabilidade no período de flutuação (02/01/2019 – 30/11/2019) de acordo com os testes de flutuação da Tabela 3.

Tabela 4 – Monitoramento - 01/12/2019 – 22/01/2021

| País | Índice | Quebra detectada |
|-------------|---------------|-------------------------|
| Alemanha | DAX | 09/03/2020 |
| Argentina | MERV | - |
| Brasil | BVSP | 09/03/2020 |
| Canadá | GSPTSE | 28/02/2020 |
| China | SSEC | - |
| Espanha | IBEX | 05/03/2020 |
| EUA | SP500 | 04/03/2020 |
| França | CAC40 | 12/03/2020 |
| Itália | FTSEMIB | 06/03/2020 |
| Japão | NIKKEI | 09/03/2020 |
| Reino Unido | FTSE | 06/03/2020 |
| Rússia | MOEX | 28/02/2020 |

Fonte: Elaboração própria

Na primeira semana de março, entre os dias 03 e 06, as quebras foram detectadas em Itália, Reino Unido e EUA. Desses, todos já haviam registrado casos e óbitos. O terceiro grupo de países é composto por Japão, Alemanha e Brasil. Apesar de já apresentarem casos, esses países não estavam na classificação de epidemia da OMS, a

concentração de casos era mais visível em quatro países: China, Irã, Coreia do Sul e Itália, que concentravam 93% dos casos reportados segundo a OMS. No último grupo aparece a França, com quebra detectada em 12/03/2020, coincidindo com o aumento de casos em países europeus e declaração de pandemia mundial pela OMS.

A metodologia utilizada nessa seção é limitada à detecção de uma única quebra sendo, portanto, incompleta para a análise do período em questão. Além disso, como a maioria das séries não rejeitam a hipótese de instabilidade, a análise com base unicamente nesse critério pode apresentar distorções, já que as quedas iniciais nos índices podem ser entendidas como variações normais tendo como comparação um período não estável.

5.3 Datação e Regressões Segmentadas

Usando os retornos diários de 02/01/2019 a 22/01/2020, estima-se um modelo AR(1) segmentado. Para isso, determina-se o número de pontos de quebra ótimos para $m = 1, \dots, 10$, com tamanho de segmento mínimo de $n_h = 21$ observações (mais ou menos o período de 1 mês). Calcula-se então o critério NLL e LWZ segmentado associado selecionando então o número de quebras e conseqüentemente o número de segmentos ótimos (resultados no Apêndice C). Na ocorrência de quebras, observa-se que o NLL diminui com cada quebra adicional, mas com uma diminuição particularmente maior de 0 para 1 quebra e diminuições menores para mais quebras. Do mesmo modo, o critério LWZ claramente cai indo de 0 para 1 quebra, com exceção da série chinesa. O LWZ continua a cair atingindo seu mínimo para 2 quebras (ou 3 segmentos) nas onze séries restantes. Os resultados do número de quebras estimadas e as estimações segmentadas associadas podem ser vistos na Tabela 5.

Tabela 5 – Regressões Segmentadas considerando Modelos AR(1)

| Índice | Período | θ_0 | $\theta_{y_{t-1}}$ | σ^2 | R^2 | Adj R^2 |
|-------------------------------|------------------------|-------------------------|-------------------------|------------|--------|-----------|
| Alemanha (DAX) | 02/01/2019-21/02/2020 | 0.0008 (0.0005) | -0.0066 (0.0586) | 0.0001 | 0.0000 | -0.0033 |
| | 24/02/2020-11/06/2020 | -0.0016 (0.0036) | 0.0187 (0.1153) | 0.0010 | 0.0003 | -0.0126 |
| | 12/06/2020-22/01/2021 | 0.0010 (0.0010) | -0.0737 (0.0761) | 0.0002 | 0.0059 | -0.0004 |
| Argentina (MERV) | 02/01/2019-08/08/2019 | 0.0018 (0.0016) | 0.0694 (0.0801) | 0.0004 | 0.0048 | -0.0016 |
| | 09/08/2019-05/09/2019 | -0.0310 (0.0269) | -0.3929 (0.2220) | 0.0124 | 0.1482 | 0.1009 |
| | 06/09/2019-22/01/2021 | 0.0016 (0.0016) | 0.0035 (0.0522) | 0.0009 | 0.0000 | -0.0028 |
| Brasil (BVSP) | 02/01/2019-04/03/2020 | 0.0010 (0.0006) | -0.0385 (0.0579) | 0.0001 | 0.0015 | -0.0018 |
| | 26/02/2020- 08/04/2020 | -0.0165 (0.0121) | -0.3612 (0.1742) | 0.0041 | 0.1290 | 0.0990 |
| | 09/04/2020- 22/01/2021 | 0.0023 (0.0011) | -0.1598 (0.0685) | 0.0002 | 0.0259 | 0.0211 |
| Canadá (GSPTSE) | 02/01/2019-21/02/2020 | 0.0007 (0.0003) | 0.0884 (0.0581) | 0.0000 | 0.0078 | 0.0044 |
| | 24/02/2020-30/04/2020 | -0.0049 (0.0061) | -0.3206 (0.1387) | 0.0018 | 0.1020 | 0.0829 |
| | 01/05/2020-22/01/2021 | 0.0010 (0.0006) | -0.0076 (0.0705) | 0.0001 | 0.0001 | -0.0052 |
| China (SSEC) | 08/01/2019-08/07/2020 | 0.0007 (0.0005) | 0.0075 (0.0432) | 0.0001 | 0.0001 | -0.0018 |
| Espanha (IBEX) | 02/01/2019-21/02/2020 | 0.0004 (0.0004) | 0.0816 (0.0580) | 0.0001 | 0.0066 | 0.0033 |
| | 24/02/2020-24/03/2020 | -0.0268 (0.0110) | -0.4346 (0.2255) | 0.0020 | 0.1567 | 0.1145 |
| | 25/03/2020-22/01/2021 | 0.0007 (0.0011) | 0.0613 (0.0650) | 0.0003 | 0.0041 | -0.0005 |
| EUA (SP500) | 02/01/2019-21/02/2020 | 0.0010 (0.0004) | -0.0739 (0.0582) | 0.0001 | 0.0054 | 0.0021 |
| | 24/02/2020-06/04/2020 | -0.0122 (0.0086) | -0.5059 (0.1680) | 0.0021 | 0.2383 | 0.2120 |
| | 07/04/2020-22/01/2021 | 0.0020 (0.0009) | -0.1270 (0.0647) | 0.0002 | 0.0183 | 0.0135 |
| França (CAC40) | 02/01/2019-21/02/2020 | 0.0008 (0.0005) | 0.0254 (0.0581) | 0.0001 | 0.0006 | -0.0027 |
| | 24/02/2020- 06/04/2020 | -0.0116 (0.0082) | -0.0888 (0.1904) | 0.0018 | 0.0074 | -0.0268 |
| | 07/04/2020-22/01/2021 | 0.0012 (0.0010) | 0.0077 (0.0681) | 0.0002 | 0.0001 | -0.0048 |
| Itália (FTSEMIB) | 02/01/2019-21/02/2020 | 0.0010 (0.0005) | 0.0006 (0.0583) | 0.0001 | 0.0000 | -0.0034 |
| | 24/02/2020-24/03/2020 | -0.0240 (0.0130) | -0.3094 (0.2341) | 0.0028 | 0.0803 | 0.0343 |
| | 25/03/2020-22/01/2021 | 0.0012 (0.0010) | -0.0201 (0.0640) | 0.0002 | 0.0004 | -0.0040 |
| Japão (NIKKEI) | 02/01/2019-24/02/2020 | 0.0006 (0.0005) | -0.0895 (0.0578) | 0.0001 | 0.0080 | 0.0047 |
| | 25/02/2020-16/06/2020 | -0.0003 (0.0027) | 0.1695 (0.1138) | 0.0006 | 0.0273 | 0.0150 |
| | 17/06/2020-22/01/2021 | 0.0017 (0.0007) | -0.1034 (0.0741) | 0.0001 | 0.0123 | 0.0060 |
| Reino Unido (FTSE) | 02/01/2019-21/02/2020 | 0.0003 (0.0004) | 0.0967 (0.0579) | 0.0001 | 0.0093 | 0.0060 |
| | 24/02/2020-01/04/2020 | -0.0118 (0.0079) | -0.0928 (0.1971) | 0.0015 | 0.0085 | -0.0297 |
| | 02/04/2020-22/01/2021 | 0.0010 (0.0009) | -0.0361 (0.0676) | 0.0002 | 0.0014 | -0.0034 |
| Rússia (MOEX) | 02/01/2019-24/02/2020 | 0.0009 (0.0004) | -0.0039 (0.0580) | 0.0000 | 0.0000 | -0.0034 |
| | 25/02/2020-15/04/2020 | -0.0063 (0.0058) | -0.0888 (0.1727) | 0.0012 | 0.0075 | -0.0208 |
| | 16/04/2020-22/01/2021 | 0.0015 (0.0007) | -0.0150 (0.0669) | 0.0001 | 0.0003 | -0.0047 |

Fonte: Elaboração Própria. Valores em **negrito** são significativos à 10%.

Apesar de ser o epicentro inicial da doença, o modelo proposto para China não apresentou uma variação significativa no período, de forma que o teste rejeita a hipótese de quebra estrutural. Vale ressaltar que a grande maioria dos casos se concentraram na Província de Hubei (cerca de 80% dos casos totais no país e mais de 97% das mortes), além disso o Isolamento Social só foi aplicado regionalmente.

No caso chinês, o pico de expansão da doença foi registrado ainda no fim de janeiro, de acordo com a tabela 2. Além disso, a China já estava em um processo de recuperação da Pandemia quando os efeitos começaram a se espalhar pelo mundo. A partir daí há uma significativa recuperação, acompanhando a diminuição de casos ativos no país. No início de março, no entanto, novas quedas sucessivas são observadas, à medida que o contágio mundial do vírus aumenta, sendo declarado como pandemia em 11 de março.

Para a Argentina, o teste não detecta quebras no período de interesse (período pandêmico), apesar de que entre janeiro e março há um acúmulo negativo no retorno de mais de 60%. As quebras estimadas, no entanto, são explicadas pela instabilidade política no país, correspondente ao período de 09/08/2019 a 05/09/2019. Em 11/08/2019 por exemplo a bolsa despencou 49% graças ao resultado das eleições presidenciais primárias argentinas, o então presidente, o liberal Mauricio Macri sofreu uma grande derrota para chapa kirchnerista, liderada por Alberto Fernández. A tendência de baixa só munda início de setembro, após o país adotar medidas de controle de capitais, por exemplo a fixação de um limite de US\$ 10 mil por mês para a compra de moeda norte-americana por pessoas físicas.

Das dez séries restantes, as estimações apresentaram quebras próximas. Entre 21/02 (sexta-feira) e 24/02 (segunda-feira), as series de Alemanha, Canadá, Espanha, Estados Unidos, França, Itália e Reino Unido apresentaram uma quebra, todas passando de um intercepto positivo (significante para quatro delas) para um negativo (significante para as bolsas espanhola e italiana), e uma maior variância, passando de 0,01% para 0,28% na Itália e 0,28% na Espanha. A série com maior aumento na variância foi a canadense, que passou de cerca 0,002% para 0,18%, um aumento de aproximadamente 900%.

Entre 24/02 (segunda-feira) e 25/02 (terça-feira), mais dois países, Japão e Rússia entraram nesse processo de baixa, com intercepto negativo e aumento na variância. No caso da bolsa brasileira a quebra é estimada entre os dias 25/02 e 26/02, vale destacar que para o Brasil não houve pregão nos dias 24/02 e 25/02 (feriado de carnaval), a volta da bolsa só ocorreu dia 26/02, com uma queda de -7,26% em relação ao último pregão.

Ainda considerando os resultados para os modelos autorregressivos segmentados da Tabela 5, nota-se que há uma maior dispersão de datas para o segmento de recuperação. Para

Espanha e Itália, o segmento de recuperação inicia em 25/03/2020, pouco mais de um mês após à quebra, coincidindo com o período de redução da expansão da pandemia. Entre os dias 24/03 e 25/03 o aumento na Média Móvel de casos reportados foi de 12% para Espanha e 14% para a Itália, que chegaram a aumentos de 600% e 243%, respectivamente, nos momentos de maior expansão (Tabela 2).

No mês de abril, o modelo coloca mais cinco países na trajetória de recuperação: Reino Unido (02), França e Estados Unidos (07), Brasil (09) e Rússia (16). Desses somente a França apresentou queda na média móvel de casos (-12,74%), os demais apresentaram aumentos entre 9% e 12%. Posteriormente, tem-se o Canadá nessa trajetória de recuperação em 01/05/2020, tendo apresentado aumento de 0,42% neste dia. E, finalmente, Alemanha em 12/06/2020 e Japão em 17/06/2020, não tendo variação na média móvel de casos.


5.4 Análise Comparativa de Crises

A fim de compreender as diferenças do comportamento do mercado acionário em momentos de crises econômicas com origem diversa, propõe-se uma Análise comparativa em um horizonte maior de tempo: 16/05/2005 à 22/01/2021.

O período em questão abrange uma quantidade relativamente grande de eventos, desde de eventos com impactos mundiais: Crise do *subprime*, Crise do Euro, *Sell-off* Mundial e Pandemia, até eventos com impactos mais locais como atentados terroristas, desastres ambientais, greves, eleições e outros eventos políticos. Utilizando o teste de quebra apresentado anteriormente, proposto por Zeileis (2010), na nova amostra, seguiu-se com a estimação da Datação e Regressões Segmentadas no período.

O gráfico 4 traz os retornos nominais acumulados das séries tendo como base o dia 16/05/2005. Os períodos sombreados correspondem aos segmentos estimados de início de quedas e início de recuperação dos retornos, com base nos resultados do Apêndice D.

GRÁFICO 4 – Retornos Acumulados (Mar/2005 – Jan/2021)



Fonte: Elaboração Própria

Esses resultados mostram um boom no mercado acionário mundial até meados de 2007 com o início da crise. Diferente do que ocorreu mais recentemente na pandemia, com quebras simultâneas, os mercados parecem reagir de forma mais espaçada. As primeiras quebras são detectadas no mês de julho, iniciando nos Estados Unidos (SP500) e em cerca de uma semana chegando ao mercado europeu, na França (CAC40), Itália (FTSEMIB) e Reino Unido (FTSE). Enquanto para a Alemanha (DAX) e Espanha (IBEX), o período de baixa no mercado se inicia somente em janeiro de 2008.

Em setembro de 2008 a crise se agrava nos Estados Unidos (SP500), França (CAC40), Itália (FTSEMIB) e Reino Unido (FTSE) e chega aos demais países da amostra, com grande concentração de quebras entre os dias 02 e 04 de setembro, antes mesmo da conhecida segunda-feira negra (15 de setembro de 2008), grande marco da crise, com o anúncio de falência de um dos bancos de investimentos mais tradicionais dos Estados Unidos, o *Lehman Brothers*, levando Bolsas do mundo todo a despencarem.

Em termos nominais, a bolsa argentina (MERV) mostrou recuperação mais rápida, retornando à trajetória de crescimento no fim de 2008. Observa-se que o período entre dezembro de 2008 e agosto de 2019 foi de aumento constante no índice (cerca de 46 vezes), sem levar em consideração a desvalorização da moeda local.

Na maioria dos países europeus, a trajetória de recuperação é iniciada em abril de 2009, assim como para o Japão, cerca de nove meses após os efeitos negativos começarem a serem sentidos nesses países. Mesmo com sinais de recuperação, observa-se que este foi mais

lento para alguns países.

Para os Estados Unidos, berço da crise, a bolsa só retorna aos níveis pré-crise em 2013. A vertiginosa redução da demanda internacional, especialmente na área de eletrônicos e de automação, também afetou profundamente a economia japonesa.

Na Europa, a crise econômica de 2008 atingiu em cheio a chamada Zona do Euro. Sem uma política fiscal comum que regulasse o mercado, muitos Estados aumentaram seu endividamento de forma desmedida, levando a uma crise fiscal. O colapso iniciou-se na Grécia, chegando a outros países da Zona do Euro, que também estavam em condições fiscais debilitadas. Analisando os três países da Zona do Euro no Gráfico 4, França (CAC40), Espanha (IBEX) e Itália (FTSEMIB) apresentam uma tímida recuperação no mercado de capitais no pós-crise de 2008, além novas quedas no segundo semestre de 2011.

Partindo para um outro ponto de instabilidade no mercado de capitais observável na amostra, o *seel-off* 2015-2016 foi um período de declínio no valor dos preços das ações globalmente que ocorreu entre junho de 2015 a junho de 2016. Um “*sell-off*” é quando investidores optam por vender rapidamente os ativos que possuem em determinado momento, geralmente após notícias ou expectativas negativas, usualmente criando um “efeito bola de neve”, conforme as ordens de venda continuam a derrubar a pontuação do índice e ative o *stop loss* de outros investidores, impulsionando cada vez mais a queda.

A bolsa canadense (GSPTSE) foi a única a ter uma quebra acentuada detectada no período. No segmento 19/09/2014-19/02/2016 o intercepto estimado foi negativo, porém não significativo, e coeficiente autorregressivo positivo significativo, indicando certa persistência de retornos negativos. De maneira geral, economia do Canadá foi uma das que mais sofreu com o impacto do choque dos preços das commodities, especialmente do petróleo, afetando o desempenho do mercado acionário.

No caso da bolsa de valores chinesa (SSEC), a série parece ser segmentada por dois pontos de turbulência. O primeiro entre 08/12/2006 e 30/11/2009, onde apresentou grande crescimento seguido de quedas sucessivas devido à crise global. O segundo entre 02/12/2014 e 09/05/2016 com movimento parecido ao anterior, dessa vez relacionado ao ceticismo em relação ao setor bancário europeu, desaceleração na produção industrial mundial, desaceleração do crescimento do PIB da China, queda nos preços do petróleo, além de expectativas relacionadas ao *brexit*. Nesses dois momentos a variância foi de 0,5%, muito superior aos demais segmentos, em média 0,1%.

A ampliação da base de dados modifica o *efp* calculado e conseqüente o funcional $\lambda(\text{efp}(t))$ para cada nova observação. Por se tratar de um teste sequencial, onde todos os valores

passados são considerados, a função limite que determina os pontos críticos do processo difere da calculada na Seção 5.1. Nesse sentido, os resultados do Anexo 5 para o período pandêmico diferem um pouco dos apresentados na Tabela 4.

Com relação ao início da Pandemia têm-se resultados similares, com quebras em dez das doze séries estudadas – exceções são Argentina (MERV) e China (SSEC) – com ocorrência entre os dias 24 e 26 de fevereiro. A grande mudança aqui é a ausência do segmento de recuperação em algumas séries: DAX, IBEX, CAC40 e FTSE. Para as demais, o segmento de recuperação se inicia na mesma data anteriormente calculada tendo, portanto, os mesmos coeficientes estimados.

5.5 Análise da Correlação Local e Correlação Local Parcial

Utilizando a metodologia proposta por Park et al (2014), que desenvolve a estrutura *wavelet* multivariada localmente estacionária, fornecendo uma decomposição em escala de tempo dos sinais e, assim, captura naturalmente a dependência cruzada específica da escala em evolução no tempo entre os componentes dos sinais.

Esse esquema fornece um mecanismo para identificar relacionamentos dinâmicos ocultos dentro de uma rede de sinais não estacionários através de dois processos de dependência cruzada: No primeiro caso, a *Wavelet Coherence* (Correlação *Wavelet*), que se trata de uma medida ampla de dependência, que pode incluir associações indiretas, dependência entre um par de sinais impulsionado por outro sinal. Já no segundo, tem-se a *Partial Wavelet Coherence* (Correlação *Wavelet* Parcial) que mede a associação direta entre um par de sinais, ou seja, remove o efeito linear de outros sinais observados. Nesse sentido, esta pode ser aplicada na relação entre os retornos acionários representados pelos índices de cada país. Os resultados dessa aplicação retornam os gráficos constantes no Apêndice E que demonstram a evolução dessa ligação ao longo do tempo.

As figuras 1 e 2 descrevem a decomposição em escala tempo das séries de tempo multivariadas. O aspecto não estacionário estaria presente com a observação de picos nos gráficos apresentados. Esses picos são mais visíveis para a relação de cada série com ela própria, indicada pelos gráficos da diagonal. Para as relações cruzadas observar-se na figura 1 pequenas mudanças nos gráficos especialmente em dois momentos: entre 2008 e 2009 e em 2020, coincidindo com os momentos de crise. Já para o segundo nível, a mudança no espectro é visível somente no período 2008-2009.

As figuras 3 e 4 trazem a estimação da correlação local. Apesar das variações

temporais, observa-se, na figura 3, um forte relacionamento linear entre as bolsas europeias (FTSEMIB, FTSE, CAC40, DAX e IBEX) em todo o período. Já as bolsas asiáticas, representadas por SSEC e NIKKEI, aparecem pouco relacionadas entre si e com as demais. O SP500 parece mais relacionado com a bolsa canadense (GSPTSE), mas também há certo grau de relacionamento com algumas bolsas europeias e com a bolsa brasileira (BVSP).

Apesar de não ser tão visível o aumento do relacionamento entre as variáveis nos momentos de crise, o índice brasileiro (BVSP) aparece com um pico na correlação localizada com várias das outras séries no início de 2020. Na figura 4 (nível 2) esse efeito é mais visível e também pode ser encontrado para o relacionamento entre outras séries.

Ao remover os efeitos cruzados, focando apenas no efeito direto entre as séries, retorna-se as figuras 5 e 6. Ao considerar-se a correlação parcial localizada, a relação entre as séries parece ser menor. Nas bolsas europeias, que tiveram correlação mais alta no caso da correlação localizada, aparecem menos relacionadas apesar de alguns momentos com alta correlação.

Esse resultado para as bolsas europeias já foi encontrado em Taylor et al (2019) utilizando uma base de dados mais antiga (1994-1998). Isso indica que parte da dependência linear encontrada entre os pares de índices ocorrem indiretamente pelo relacionamento com outros mercados observados.

6 CONCLUSÃO

Embora as economias estejam atualmente em diferentes caminhos de crescimento, se deparam com condições macroeconômicas e sanitárias únicas que determinam a estabilidade e resiliência de seus respectivos sistemas financeiros, as diferentes respostas políticas que são adotadas por diferentes economias em o combate à pandemia irá, em grande medida, determinar a gravidade, duração e gestão tanto da saúde quanto os consequentes efeitos colaterais na economia.

Por serem movidas, em grande parte por expectativas do mercado, as bolsas de valores são consideradas importantes termômetros para a economia ou do que se espera dela. Nesse sentido, se faz relevante um estudo sobre o efeito da pandemia no comportamento dos investidores em diferentes países.

Ao analisar o comportamento das bolsas de valores de 12 países (Alemanha, Argentina, Brasil, Canadá, China, Espanha, Estados Unidos, França, Itália, Japão, Reino Unido e Rússia) no período pandêmico, sob a ótica da metodologia de quebras proposta por Zeileis et

al (2005), os resultados mostraram uma grande concentração de quebras nos principais índices entre os dias 24 e 26 de fevereiro de 2020, ficando de fora desse resultado somente Argentina e China.

As estimações também constaram a rápida recuperação das bolsas. Oito das dez bolsas que apresentaram quebras em fevereiro tiveram uma nova quebra estimada entre março e abril de 2020, entrando em um segmento de recuperação nos índices bursáteis. Essa recuperação pode ser observada nos parâmetros estimados: têm-se interceptos positivos, inclusive maiores do que os do período pré-pandêmico, indicando uma persistência de retornos positivos. Há ainda uma grande redução da variância, apesar de esta continuar um pouco acima da variância do primeiro segmento.

A rápida recuperação das bolsas de valores pode ser vista de diferentes aspectos: de início, por ser uma situação de saúde pública, os governos puderam agir de forma rápida e com a injeção de grande quantidade de recursos. Além disso, a partir do final de março os números da pandemia caíram bastante na China, gerando uma expectativa de reabertura da Economia.

No caso do Brasil, esse movimento pode ter sido potencializado pelo cenário de baixa taxa de juros, chegando a uma mínima histórica de 2,25% para SELIC. Esse cenário, aliado com as facilidades de se investir, já vinha aumentando a migração de investidores para a bolsa de valores desde 2019, segundo dados da B3 o número de CPFs cadastrados mais que dobrou entre 2018 e 2019. Em julho de 2020, o aumento em relação a 2019 já chegou à 68 %, um aumento de 1.143.206 investidores.

Um outro ponto a se considerar é que as empresas que compõem a bolsa de valores brasileira não são representativas para a Economia Brasileira por se tratarem de empresas maiores, logo com maior capacidade de caixa e de obtenção de crédito. Dessa forma, o cenário de juros baixos e instabilidade levam os investidores a procurar ações de empresas mais sólidas.

Outra análise interessante é a comparação desses acontecimentos com os ocorridos em outros cenários de crise. Para isso, a base de dados proposta inicialmente foi expandida de maneira a considerar o período 2005-2021. Nesse período foram observados alguns pontos de instabilidade no mercado mundial, os principais são, além da recente pandemia, a crise do subprime (2008 - 2009), crise do euro (2011 – 2012) e “*sell-off*” global (2014 – 2016). Além de acontecimentos mais localizados como atentados terroristas e decisões políticas.

Utilizando o teste para detecção de múltiplas quebras nesse período, há uma certa diversidade no número de quebras (entre 4 e 8) e, conseqüentemente, de segmentos estimados (entre 5 e 9) para cada série. Apesar dessas diferenças, todas as séries aparecem com uma quebra no período mais ou menos correspondente a crise do *subprime*.

A série chinesa é a mais destoante desse resultado, a quebra é detectada como um pico de variância entre 08/12/2006 e 30/11/2009, período onde apresentou grande crescimento seguido de uma queda. Um movimento parecido ocorreu entre 02/12/2014 e 09/05/2016, com a desaceleração da economia mundial. Esse movimento também parece ter afetado de maneira mais crítica a bolsa canadense, que apresentou intercepto negativo e coeficiente do comonente autorregressivo positivo, indicando uma certa persistência em retornos negativos, entre 19/09/2014 e 19/02/2016.

Ao analisar as datas das quebras, no entanto, observa-se um certo espalhamento entre as quebras. Os índices de Estados Unidos (SP500), França (CAC40), Itália (FTSEMIB) e Reino Unido (FTSE) refletiram os efeitos negativos da crise ainda em setembro de 2007; Alemanha (DAX) e Espanha (IBEX) em janeiro de 2008; e os demais somente em setembro de 2008.

Mesmo com a mudança na base de dados, que modifica o cálculo do *efp* e consequentemente da estatística de teste, as datas anteriormente encontradas como quebras para o período pandêmico (entre 24 e 26 de fevereiro de 2020) são as mesmas das calculadas com a base de dados estendidas. Ou seja, o efeito provocado pela crise sanitária foi praticamente simultâneo entre as bolsas estudadas.

Há inúmeras diferenças entre esses dois momentos. Em 2008 a crise se iniciou em um país e em um setor (mercado financeiro imobiliários dos Estados Unidos), ou seja, ela nasceu no mercado financeiro, espalhou pelo mercado financeiro global e, depois, atinge a economia global. Já em 2020, o problema é sanitário e o contágio sobre a atividade econômica em todo o mundo foi imediato e acelerado. A crise nasceu no lado sanitário, afetando diretamente o lado real da economia e o lado financeiro.

Os meios disponíveis para enfrentamento da crise também divergem. A utilização de Política Monetária para estimular o crédito é limitada pois os juros já estão em níveis baixos, e os investimentos e consumos são afetados diretamente pelas medidas de isolamento. Além disso, a necessidade de resposta rápida faz com que a expansão do gasto seja o principal meio de enfrentamento aos problemas sanitários e econômicos

Com isso, a injeção de um grande volume de recursos na economia na tentativa de amortecer a queda da atividade econômica já no início da pandemia, acaba levando recursos para as bolsas de valores. Fato que é ainda potencializado pelos juros baixos e influência das mídias sociais. De maneira geral, a saúde política e econômica nem sempre pode ser medida pelo mercado de ações. A única coisa que ele reflete é a opinião de investidores a respeito da saúde financeira e da possibilidade de geração de lucros das empresas de capital aberto.

Outra questão relacionada à rápida recuperação é o fenômeno conhecido como *Fear Of Missing Out*, efeito relacionado ao efeito manada. Esse fenômeno explica boa parte das pessoas que entram ou saem da bolsa de valores em momentos de alta e baixa, respectivamente. Esses investidores realizam investimentos observando somente os movimentos de mercado: decide entrar em um momento de subida e sair em momento de queda, se guiando apenas pelos momentos de euforia e pessimismo.

Além disso, o Brasil e boa parte do mundo demonstra grande dificuldade para controlar a pandemia mesmo com o início da vacinação, o que pode ser visto com o avanço da segunda onda no final de 2020, até mesmo em países que foram considerados exemplos a serem seguidos na primeira onda, como o caso da Alemanha. Além disso, alertas de novas variantes

A crise sanitária também pode agrava situações de crises políticas e institucionais preexistentes, assim como questões macroeconômicas relacionadas, principalmente, ao endividamento público. Isso porque, além do aumento de gastos, há também uma profunda redução na arrecadação como consequência das medidas restritivas ao funcionamento das empresas. Nesse sentido, a ocorrência de eventos de grande revela fragilidades no sistema financeiro devendo ligar o alerta de prevenção de riscos para os investidores e para os órgãos reguladores.

Apesar da amostra limitada, esse estudo mostrou resultados importantes para a análise da atual situação das bolsas de valores mundiais representadas por índices de doze bolsas que figuram entre as maiores do mundo. Para futuros estudos, pode-se propor uma expansão para outras bolsas, de maneira a incluir mercados menores e analisar as diferenças nas reações desses mercados em relação aos maiores.

Uma outra análise interessante seria a comparação entre os tipos de medidas econômicas adotadas por cada país e as respostas geradas para o Mercado Financeiro. Elgin et al (2020) lista medidas (fiscais, monetárias e cambiais) adotadas por 166 países em resposta à pandemia COVID-19, usando a análise de componentes principais (PCA), os autores criaram o índice CESI (Índice de Estímulo Econômico COVID-19) que combina todas as medidas políticas adotadas. Este índice padroniza as respostas econômicas tomadas pelos governos e nos permite estudar as diferenças de políticas entre os países.

REFERÊNCIAS

- ALBULESCU, Claudiu Tiberiu. **COVID-19 and the United States financial markets volatility**. Finance Research Letters, V. 38, 2021.
- ANDREWS, D. K. **Tests for parameter instability and structural change with unknown change point**, Econometrica 61(4), 821–856. 1993.
- ANDREWS, D. K. & PLOBERGER, W. **Optimal tests when a nuisance parameter is present only under the alternative**, Econometrica 62(6), 1383–1414. 1994.
- BAI, J. **Least squares estimation of a shift in linear processes**, Journal of Time Series Analysis 15(5), 453–472. 1994.
- BAI, J.; PERRON, P. **Estimating and testing linear models with multiple structural changes**, Econometrica 66(1), 47–78. 1998.
- BAI, J; PERRO, P. **Computing and analysis of multiple structural change models**, Journal of Applied Econometrics, V.18, 1 -22. 2003.
- CHEVALLIER, Julien. **COVID-19 Pandemic and Financial Contagion**. Journal of Risk and Financial Management. 13, 309. 2020.
- CHOW, G. C. **Tests of equality between sets of coefficients in two linear regressions**. Econometrica 28(3), 591–605. 1960.
- D. A. Hsu. **Detecting Shifts of Parameter in Gamma Sequences with Applications to Stock Price and Air Traffic Flow Analysis**. Journal of the American Statistical Association, 74:365, 31-40, 1979.
- ELGIN, Ceyhun; BASBUG, Gokce; YALAMAN, Abdullah. **Economic policy responses to a pandemic: Developing the Covid-19 economic stimulus index**. Covid Economics 3, 10: 40-53, 2020.
- FONSECA, J.S.; MARTINS, G.A.; TOLEDO, G.S. **Estatística aplicada**. 2^a.ed. São Paulo: Atlas, 1985.
- GRECH, D., MAZUR, Z. **Can one make any crash prediction in finance using the local Hurst exponent idea?**. Physica A: Statistical Mechanics and its Applications, v. 336.1, p. 133-145, 2004.
- HANSEN, B. E. **The new econometrics of structural change: Dating breaks in U.S. labor productivity**, The Journal of Economic Perspectives 15(4), 117–128, 2001.
- HJORT, N L; KORNIK, A. **Tests for constancy of model parameters over time**, Nonparametric Statistics 14, 113-132, 2002.
- OKORIE, David Iheke; LIN, Boqiang. **Stock Market and the COVID-19 fractal contagion effects**. Finance Research Letters, v. 38, Article 101591, 2020.

OLIVEIRA, Franklin Alves de; ROCCO, Leandro (2018). **Efeitos do impeachment presidencial no value at risk das ações negociadas na bolsa de valores de São Paulo**. In: Encontro Nacional de Economia, 46., 2018. Disponível em: https://www.anpec.org.br/encontro/2018/submissao/files_I/i8-b436a1cf297d323dec971d0f91099037.pdf. Acesso em: 22 abr. 2020.

MATOS, Paulo; COSTA, Antonio; SILVA, Cristiano. **COVID-19, stock markets and sectorial contagion in US: a time frequency analysis**. 2020
Disponível em: <https://feaac.ufc.br/wp-content/uploads/2020/09/matos-costa-and-da-silva-covid-us-stock-market>.

MORETTIN, P.A.; TOLOI, C.M.C. **Análise de Séries Temporais**, ABE - Projeto Fisher. Editora Edgard Blucher LTDA, São Paulo, 2004.

NELSON, C. R. e PLOSSER, C. I. **Trends and random walks in macroeconomics time series: some evidence and implications**, Journal of Monetary Economics 10, 139–162. 1982.

NYBLON, J. **Testing for the constancy of parameters over time**, Journal of the American Statistical Association 84, 223-230. 1989.

PARK, Timothy; ECKLEY, Idris A; OMBAO, Hernando. **Estimating Time-Evolving Partial Coherence Between Signals via Multivariate Locally Stationary Wavelet Processes**. IEEE Transactions of Signals Processing, V. 62 (20), 5240-5250. 2014.

PERRON, P. **The great crash, the oil-price shock, and the unit-root**, Econometrica 57(6), 1361–1401. 1989.

PERRON, P. **Dealing with structural breaks**, in ‘Mimeo forthcoming in the Palgrave Handbook of Econometrics, Volume 1: Econometric Theory’. 2005.

QUANDT, R. E, **Tests of the hypothesis that a linear regression system obeys two separate regimes**, Journal of the American Statistical Association 55(290), 324–330. 1960.

SHIKIDA, Cláudio; PAIVA, Guilherme Leite; ARAÚJO, Ari Francisco. **Análise de quebras estruturais na série do preço do boi gordo no estado de São Paulo**. Economia Aplicada, v. 20, n. 2, pp. 265-286, 2016.

SIEGEL, Jeremy J.. **WHEN WORLD EVENTS IMPACT FINANCIAL MARKETS**. In: SIEGEL, Jeremy J.. **Stocks for the Long Run**. 4. ed.: Mc Graw Hill, 2008. Cap. 13

SILVA, Diego Roberto Cintra. **Utilização do Dentedred Fluctuation Analysis e do Dentedred Cross-Correlation Analysis para estudo do espectro de correlação de ações constantes no Ibovespa no período de crise do subprime**. 2017. 87 f. Dissertação (Mestrado em Engenharia de Produção) - Programa de Pós-Graduação em Engenharia de Produção, Universidade Estadual Paulista, Bauru, 2017.

STOCK, J. H. & WATSON, M. W. (2004), **Econometria**, 1. Ed.: Pearson Education do Brasil, 2004.

TAYLOR, Simon A C; PARK, Timothy; ECKEY, Idris A. **Multivariate Locally Stationary Wavelet Analysis with the mvLSW R Package**. Journal of Statistical Software, v. 90 , 11. 2019.

YIN, Y.; SHANG, P.; XIA, J. **Compositional segmentation of time series in the financial markets**. Applied Mathematics and Computation, v. 268, p. 399-412, 2015.

ZEILEIS, Achim. **A Unified approach to structural change tests based on ML scores, F statistics, and OLS Residuals**. Econometric Review, vol 24, p 445 – 466. 2005.

ZEILEIS, Achim; HORNIK, Kurt. **Generalized M-fluctuation tests for parameter instability**. Netherlands Society for Statistics and Operations Research, vol. 61(4), p 488-508. 2007.

ZEILEIS, A., KLEIBER, C., KRAMER, W. & HORNIK, K. **Testing and dating of structural changes in practice**, Computational Statistics & Data Analysis 44(1-2), 109–123. 2003.

ZEILEIS, A., LEISCH, F., HORNIK, K. & KLEIBER, C. **Strucchange: An R package for testing for structural change in linear regression models**, Journal of Statistical Software 7(2), 1–28. 2002.


ZEILEIS, Achim; SHAH, Ajay; PATNAIK, Ila. **Generalized M-fluctuation tests for parameter instability**. Computation Statistics and Data Analysis, vol. 54, p 1996-1706. 2010.

ZHANG, Dayong; HU, Min, Ji, Qiang. **Financial markets under the global pandemic of COVID-19**. Finance Research Letters, 2020.


ZHANG, Shuxia; TIAN, Boping. **Semiparametric Method for Identifying Multiple Change-points in Financial Market**, Communications in Statistics - Simulation and Computation, 2017.

APÊNDICE A – GRÁFICOS TESTE DE FLUTUAÇÃO M (02/01/2019 – 30/11/2019)


a) Alemanha




d) Canadá



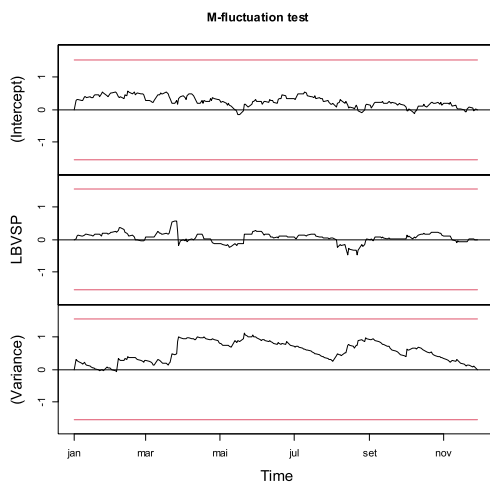
b) Argentina




e) China




c) Brasil



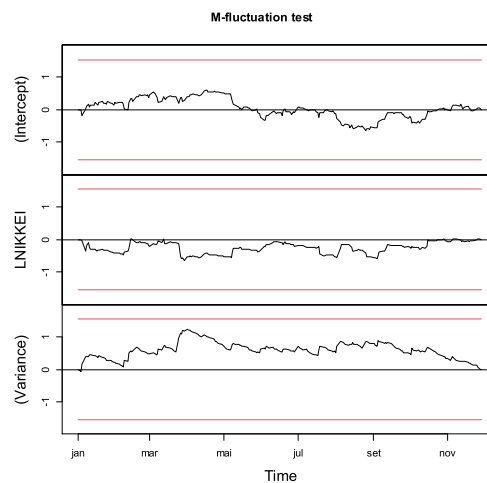
f) Espanha




g) Estados Unidos




j) Japão




h) França




k) Reino Unido



i) Itália

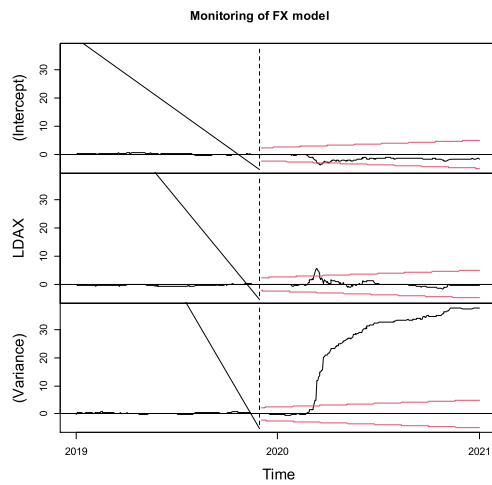


l) Rússia




APÊNDICE B – GRÁFICOS DE MONITONAMENTO (01/12/2019 – 22/01/2021)


a) Alemanha




d) Canadá




b) Argentina



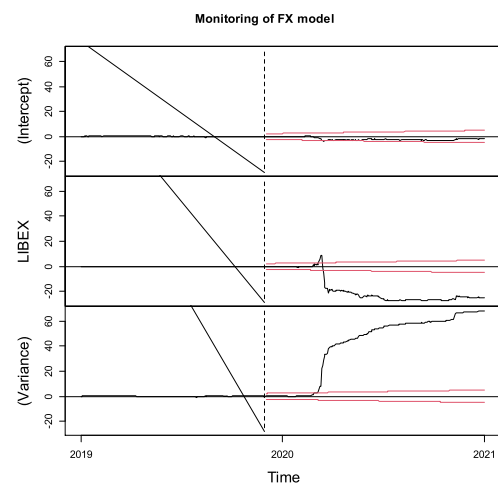
e) China




c) Brasil



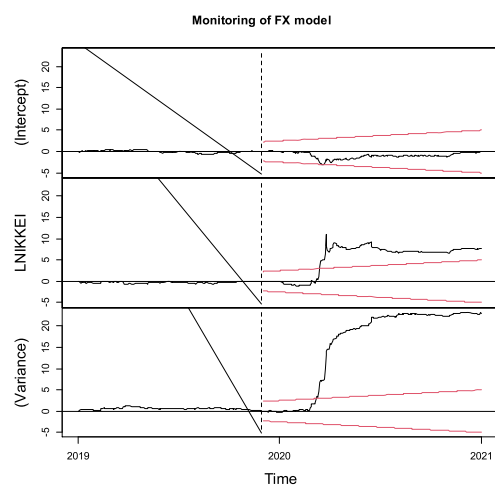
f) Espanha




g) Estados Unidos



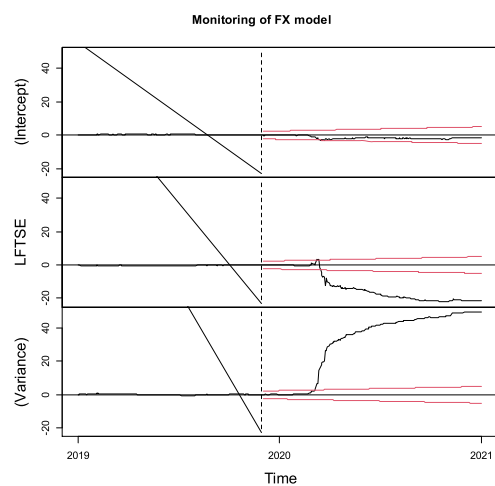
j) Japão




h) França




k) Reino Unido



i) Itália

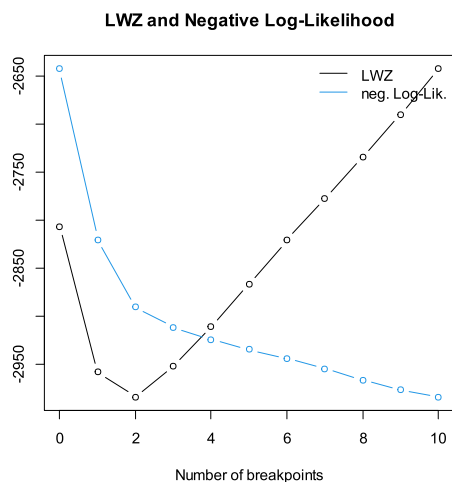


l) Rússia

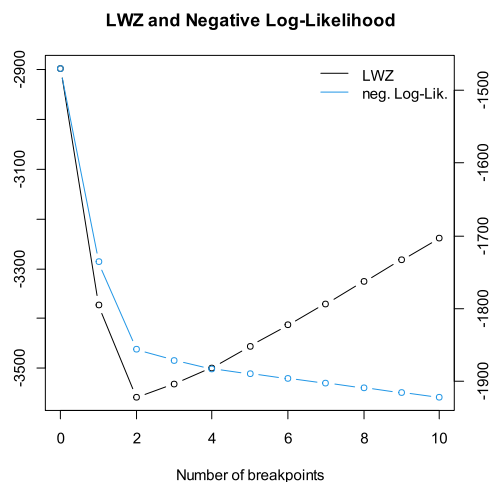


APÊNDICE C – LOG-VEROSSIMILHANÇA NEGATIVA E CRITÉRIO DE INFORMAÇÃO LWZ (02/01/2019 – 22/01/2021)


a) Alemanha




d) Canadá




b) Argentina




e) China




c) Brasil




f) Espanha




g) EUA




j) Japão




h) França




k) Reino Unido



i) Itália



l) Rússia



APÊNDICE D – REGRESSÕES SEGMENTADAS 2005 - 2021

a) Alemanha

| | θ_0 | $\theta_{y_{t-1}}$ | σ^2 | | |
|-----|-------------|--------------------|---------------|--------|--|
| DAX | 16/05/2005- | 0.0009 | -0.0397 | 0.0001 | |
| | 14/01/2008 | (0.0003) | (0.0379) | | |
| | 15/01/2008- | -0.0013 | -0.0501 | | |
| | 02/07/2009 | (0.0012) | (0.0513) | | |
| | 03/07/2009- | 0.0004 | 0.0409 | | |
| | 12/07/2016 | (0.0003) | (0.0232) | | |
| | 13/07/2016- | 0.0003 | -0.0200 | | |
| | 21/02/2020 | (0.0003) | (0.0326) | | |
| | 24/02/2020- | 0.0001 | -0.0041 | | |
| | 22/01/2021 | (0.0014) | (0.0648) | | |

b) Argentina

| | θ_0 | $\theta_{y_{t-1}}$ | σ^2 | | |
|------|-------------|--------------------|---------------|--------|--|
| MERV | 16/05/2005- | 0.0002 | -0.0187 | 0.0002 | |
| | 08/09/2008 | (0.0004) | (0.0339) | | |
| | 09/09/2008- | -0.0090 | 0.0881 | | |
| | 01/12/2008 | (0.0066) | (0.1326) | | |
| | 02/12/2008- | 0.0013 | 0.0607 | | |
| | 08/08/2019 | (0.0004) | (0.0189) | | |
| | 09/08/2019- | -0.0260 | -0.3589 | | |
| | 06/09/2019 | (0.0257) | (0.2148) | | |
| | 09/09/2019- | 0.0015 | -0.0029 | | |
| | 22/01/2021 | (0.00118) | (0.0528) | | |

c) Brasil

| | θ_0 | $\theta_{y_{t-1}}$ | σ^2 | | |
|------|--------------|--------------------|----------------|--------|--|
| BVSP | 16/05/2005- | 0.0010 | -0.0451 | 0.0003 | |
| | 03/09/2008 | (0.0005) | (0.0340) | | |
| | 04/09/2008 - | -0.0002 | -0.0107 | | |
| | 18/05/2009 | (0.0028) | (0.0746) | | |
| | 19/05/2009 - | 0.0029 | -0.0253 | | |
| | 25/02/2020 | (0.0002) | (0.0188) | | |
| | 26/02/2020 - | -0.01635 | -0.3612 | | |
| | 08/04/2020 | (0.0121) | (0.1742) | | |
| | 08/04/2020 - | 0.0023 | -0.1598 | | |
| | 22/01/2021 | (0.0011) | (0.0685) | | |


d) Canadá

| | θ_0 | $\theta_{y_{t-1}}$ | σ^2 | |
|------------|-------------|--------------------|----------------|--------|
| GSPTSE | 16/05/2005- | 0.0005 | -0.0513 | 0.0001 |
| | 01/09/2008 | (0.0003) | (0.0341) | |
| | 02/09/2008- | -0.0015 | -0.1006 | 0.0008 |
| | 25/06/2009 | (0.0020) | (0.0686) | |
| | 26/06/2009- | 0.0001 | 0.0627 | 0.0001 |
| | 08/08/2012 | (0.0003) | (0.0349) | |
| | 09/08/2012- | 0.0005 | 0.0154 | 0.0000 |
| | 18/09/2014 | (0.0002) | (0.0426) | |
| | 19/09/2014- | -0.0004 | 0.1002 | 0.0001 |
| | 19/02/2016 | (0.0005) | (0.0518) | |
| | 22/02/2016- | 0.0003 | 0.0548 | 0.0000 |
| | 21/02/2020 | (0.0002) | (0.0309) | |
| | 24/02/2020- | -0.0049 | -0.3206 | 0.0018 |
| | 30/04/2020 | (0.0061) | (0.1387) | |
| | 01/05/2020- | 0.0010 | -0.0076 | 0.0001 |
| 22/01/2021 | (0.0006) | (0.0705) | | |



e) China

| | θ_0 | $\theta_{y_{t-1}}$ | σ^2 | |
|------|-------------|--------------------|------------|--------|
| SSEC | 16/05/2005- | 0.0016 | 0.0302 | 0.0002 |
| | 07/12/2006 | 0.0006 | 0.0495 | |
| | 08/12/2006- | 0.0005 | -0.0159 | 0.0005 |
| | 30/11/2009 | 0.0008 | 0.0359 | |
| | 01/12/2009- | -0.0001 | 0.0098 | 0.0001 |
| | 01/12/2014 | 0.0003 | 0.0276 | |
| | 02/12/2014- | 0.0001 | 0.0705 | 0.0005 |
| | 09/05/2016 | 0.0012 | 0.0517 | |
| | 10/05/2016- | 0.0004 | -0.0170 | 0.0000 |
| | 05/02/2018 | 0.0003 | 0.0460 | |
| | 06/02/2018- | 0.0000 | -0.0101 | 0.0001 |
| | 22/01/2021 | 0.0004 | 0.0360 | |



f) Espanha

| | θ_0 | $\theta_{y_{t-1}}$ | σ^2 | |
|------|-------------|--------------------|---------------|--------|
| IBEX | 16/05/2005- | 0.0007 | -0.0372 | 0.0001 |
| | 14/01/2008 | (0.0003) | (0.0379) | |
| | 15/01/2008- | -0.0018 | -0.0563 | 0.0006 |
| | 02/04/2009 | (0.0014) | (0.0565) | |
| | 03/04/2009- | 0.0000 | 0.0483 | 0.0002 |
| | 05/08/2016 | (0.0003) | (0.0228) | |
| | 08/08/2016- | 0.0001 | 0.0087 | 0.0001 |
| | 21/02/2020 | (0.0003) | (0.0328) | |
| | 24/02/2020- | -0.0009 | -0.0531 | 0.0004 |
| | 22/01/2021 | (0.0014) | (0.0647) | |



g) Estados Unidos

| | θ_0 | $\theta_{y_{t-1}}$ | σ^2 | |
|-------------|---------------|--------------------|----------------|--------|
| SP500 | 16/05/2005- | 0.0005 | -0.0258 | 0.0000 |
| | 09/07/2007 | (0.0003) | (0.0422) | |
| | 10/07/2007- | -0.0007 | -0.1792 | |
| | 03/09/2008 | (0.0007) | (0.0568) | 0.0001 |
| | 04/09/2008- | -0.0029 | -0.1479 | |
| | 20/04/2009 | (0.0026) | (0.0783) | 0.0011 |
| | 21/04/2009- | 0.0006 | -0.0973 | 0.0001 |
| | 20/12/2011 | (0.0005) | (0.0376) | |
| | 21/12/2011- | 0.0004 | -0.0113 | 0.0001 |
| | 09/11/2016 | (0.0002) | (0.0279) | 0.0000 |
| | 10/11/2016- | 0.0009 | -0.0863 | |
| | 25/01/2018 | (0.0002) | (0.0557) | 0.0001 |
| | 26/01/2018- | 0.0002 | 0.0108 | 0.0001 |
| | 21/02/2020 | (0.0004) | (0.0431) | |
| | 24/02/2020- | -0.0122 | -0.5059 | 0.0020 |
| 06/04/2020 | (0.0086) | (0.1679) | 0.0001 | |
| 07/04/2020- | 0.0020 | -0.1270 | | |
| 22/01/2021 | (0.0008) | (0.0647) | | |



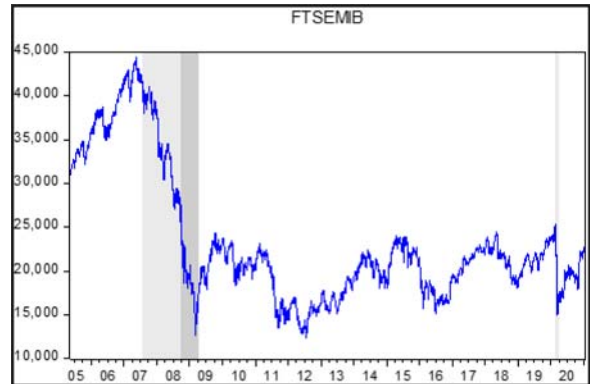
h) França

| | θ_0 | $\theta_{y_{t-1}}$ | σ^2 | |
|-------|-------------|--------------------|----------------|--------|
| CAC40 | 16/05/2005- | 0.0008 | -0.0575 | 0.0001 |
| | 17/07/2007 | (0.0003) | (0.0420) | |
| | 18/07/2007- | -0.0012 | -0.1725 | 0.0002 |
| | 03/09/2008 | (0.0008) | (0.0576) | |
| | 04/09/2008- | -0.0028 | -0.0721 | 0.0010 |
| | 02/04/2009 | (0.0026) | (0.0824) | |
| | 03/04/2009- | 0.0002 | -0.0067 | 0.0002 |
| | 12/07/2016 | (0.0003) | (0.0229) | |
| | 13/07/2016- | 0.0003 | 0.0213 | 0.0001 |
| | 21/02/2020 | (0.0002) | (0.0325) | |
| | 24/02/2020- | -0.0003 | -0.0002 | 0.0004 |
| | 22/01/2021 | (0.0013) | (0.0648) | |




i) Itália

| | θ_0 | $\theta_{y_{t-1}}$ | σ^2 | |
|---------|-------------|--------------------|----------------|--------|
| FTSEMIB | 16/05/2005- | 0.0005 | -0.1185 | 0.0000 |
| | 19/07/2007 | (0.0003) | (0.0417) | |
| | 20/07/2007- | -0.0014 | -0.1054 | 0.0001 |
| | 03/09/2008 | (0.0007) | (0.0581) | |
| | 04/09/2008- | -0.0036 | 0.0115 | 0.0010 |
| | 02/04/2009 | (0.0027) | (0.0826) | |
| | 03/04/2009- | 0.0000 | -0.0320 | 0.0002 |
| | 05/08/2016 | (0.0004) | (0.0228) | |
| | 08/08/2016- | 0.0004 | -0.0434 | 0.0001 |
| | 21/02/2020 | (0.0003) | (0.0328) | |
| | 24/02/2020- | -0.0239 | -0.3094 | 0.020 |
| | 24/03/2020 | (0.0130) | (0.2341) | |
| | 25/03/2020- | 0.0012 | -0.0200 | 0.0002 |
| | 22/01/2021 | (0.0010) | (0.0640) | |



j) Japão

| | θ_0 | $\theta_{y_{t-1}}$ | σ^2 | |
|------------|-------------|--------------------|----------------|--------|
| NIKKEI | 16/05/2005- | 0.0001 | -0.0436 | 0.0002 |
| | 15/09/2008 | (0.0004) | (0.0339) | |
| | 16/09/2008- | -0.0023 | 0.0259 | 0.0013 |
| | 02/04/2009 | (0.0031) | (0.0846) | |
| | 03/04/2009- | 0.0004 | -0.0625 | 0.0002 |
| | 14/11/2016 | (0.0003) | (0.0223) | |
| | 15/11/2016- | 0.0003 | -0.0215 | 0.0001 |
| | 24/02/2020 | (0.0003) | (0.0342) | |
| | 25/02/2020- | -0.0002 | 0.1695 | 0.0005 |
| | 16/06/2020 | (0.0027) | (0.1138) | |
| | 17/06/2020- | 0.0017 | -0.1034 | 0.0001 |
| 22/01/2021 | (0.0007) | (0.0741) | | |



k) Reino Unido

| | θ_0 | $\theta_{y_{t-1}}$ | σ^2 | |
|------|-------------|--------------------|----------------|--------|
| FTSE | 16/05/2005- | 0.0006 | -0.068 | 0.0000 |
| | 17/07/2007 | (0.0003) | (0.0420) | |
| | 18/07/2007- | -0.0007 | -0.1889 | 0.0002 |
| | 02/09/2008 | (0.0008) | (0.0574) | |
| | 03/09/2008- | -0.0023 | -0.0416 | 0.0008 |
| | 03/04/2009 | (0.0024) | (0.0814) | |
| | 06/04/2009- | 0.0003 | 0.0179 | 0.0001 |
| | 11/07/2016 | (0.0002) | (0.0229) | |
| | 12/07/2016- | 0.0001 | 0.0170 | 0.0000 |
| | 21/02/2020 | (0.0002) | (0.0325) | |
| | 24/02/2020- | -0.0004 | -0.0276 | 0.0003 |
| | 22/01/2021 | (0.0012) | (0.0648) | |



1) Russia

| | θ_0 | $\theta_{y_{t-1}}$ | σ^2 |
|-------------|---------------|--------------------|------------|
| 16/05/2005- | 0.0011 | -0.0690 | 0.0004 |
| 02/09/2008 | (0.0006) | (0.0340) | |
| 03/09/2008- | -0.0128 | 0.0626 | 0.0066 |
| 24/11/2008 | (0.0110) | (0.1374) | |
| 25/11/2008- | 0.0035 | -0.0842 | 0.0009 |
| 16/11/2009 | (0.0019) | (0.0599) | |
| 17/11/2009- | 0.0002 | 0.0123 | 0.0002 |
| 22/02/2016 | (0.00003) | (0.0247) | |
| 23/02/2016- | 0.0005 | 0.0173 | 0.0001 |
| 24/02/2020 | (0.0003) | (0.0309) | |
| 25/02/2020- | -0.0063 | -0.0888 | 0.0011 |
| 15/04/2020 | (0.0058) | (0.1727) | |
| 16/04/2020- | 0.0015 | -0.0149 | 0.0001 |
| 22/01/2021 | (0.0007) | (0.0669) | |

MOEX



APÊNDICE E – GRÁFICOS DA ANÁLISE WAVELET

Figura 1 – Gráficos do primeiro nível da estimação EWS multivariada




Figura 1: Mostra a decomposição em escala tempo das séries de tempo multivariadas no primeiro nível. O aspecto não estacionário estaria presente com a observação de picos nos gráficos apresentados. Esses picos são mais visíveis para a relação de cada série com ela própria, indicada pelos gráficos da diagonal superior. Para as relações cruzadas observar-se na figura 1 pequenas mudanças nos gráficos especialmente em dois momentos: entre 2008 e 2009 e em 2020, coincidindo com os momentos de crise.

Figura 2 – Gráficos do segundo nível da estimação EWS

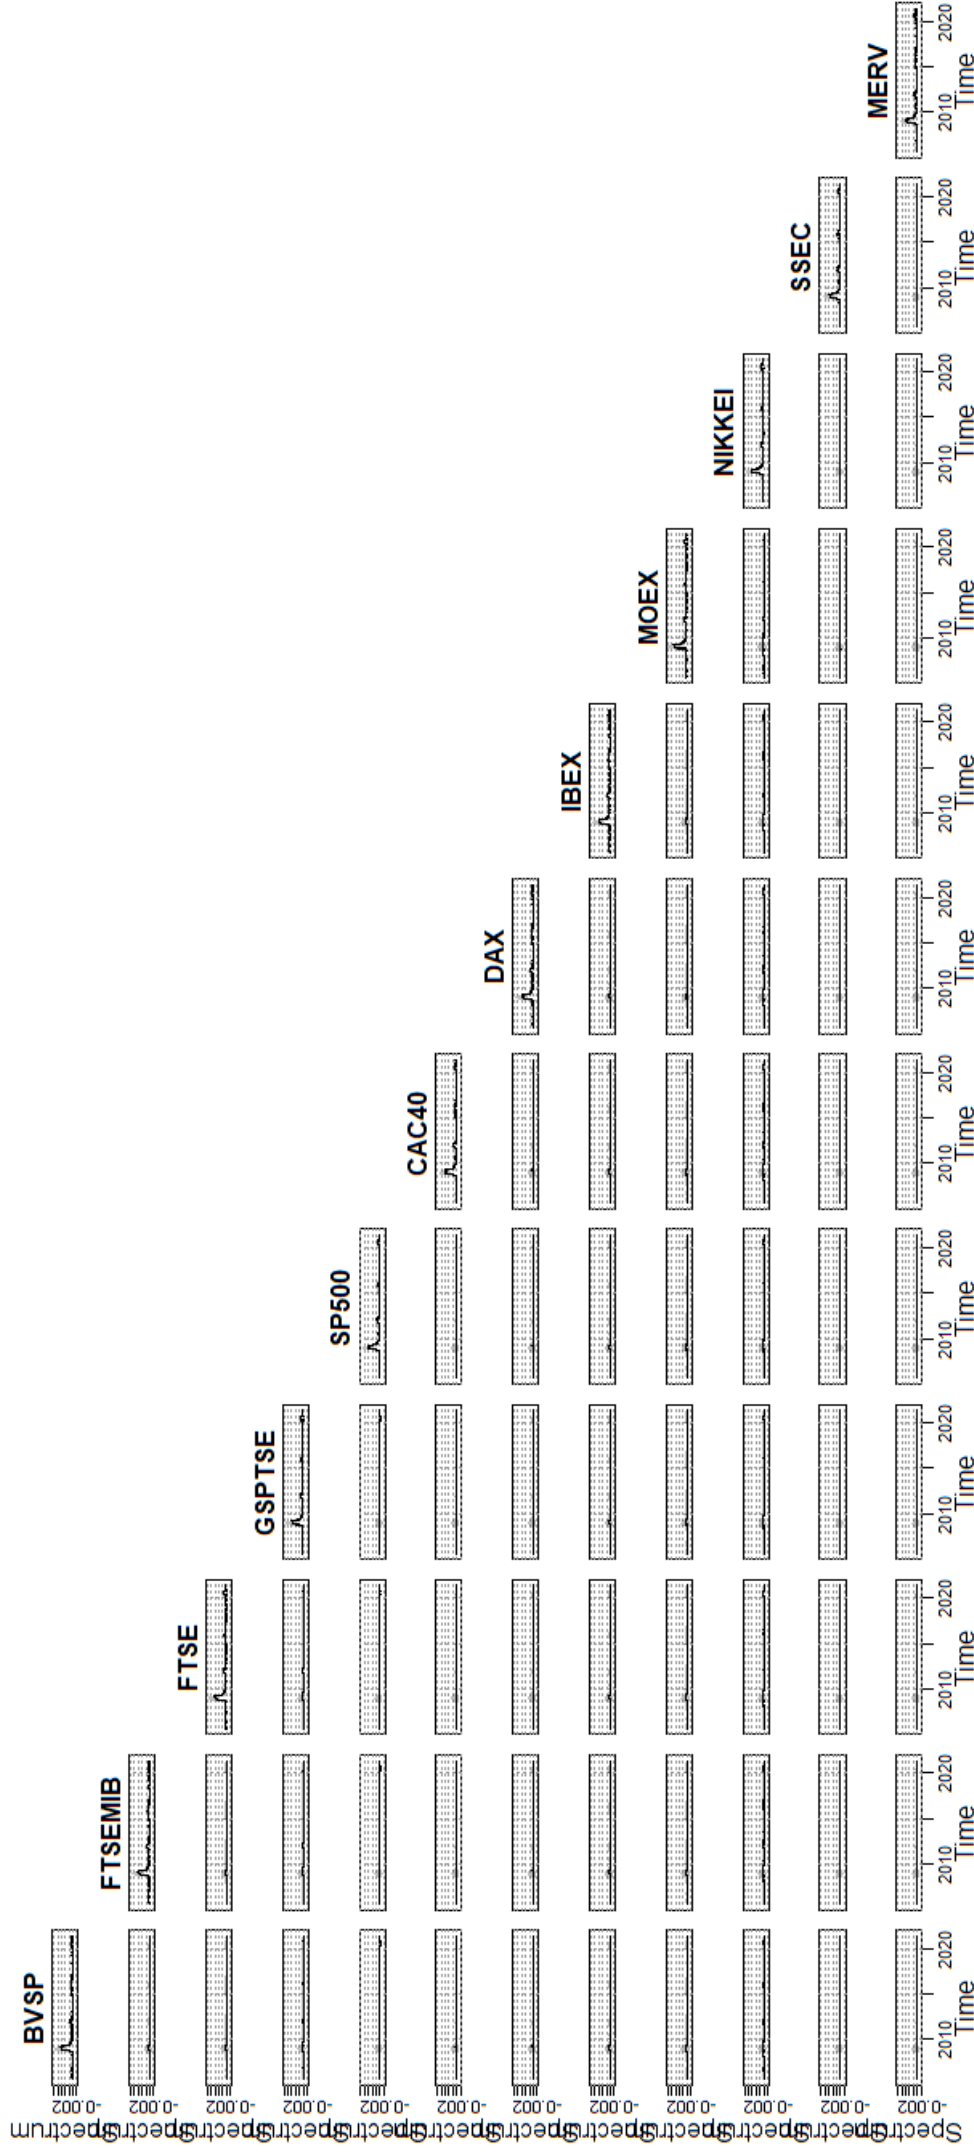


Figura 2: Mostra a decomposição em escala tempo das séries de tempo multivariadas no segundo nível. O aspecto não estacionário estaria presente com a observação de picos nos gráficos apresentados. Esses picos são mais visíveis para a relação de cada série com ela própria, indicada pelos gráficos da diagonal superior. Para as relações cruzadas, a mudança no espectro é visível somente no período 2008-2009.

Figura 3 – Gráficos do primeiro nível da estimação da Correlação Localizada entre os índices

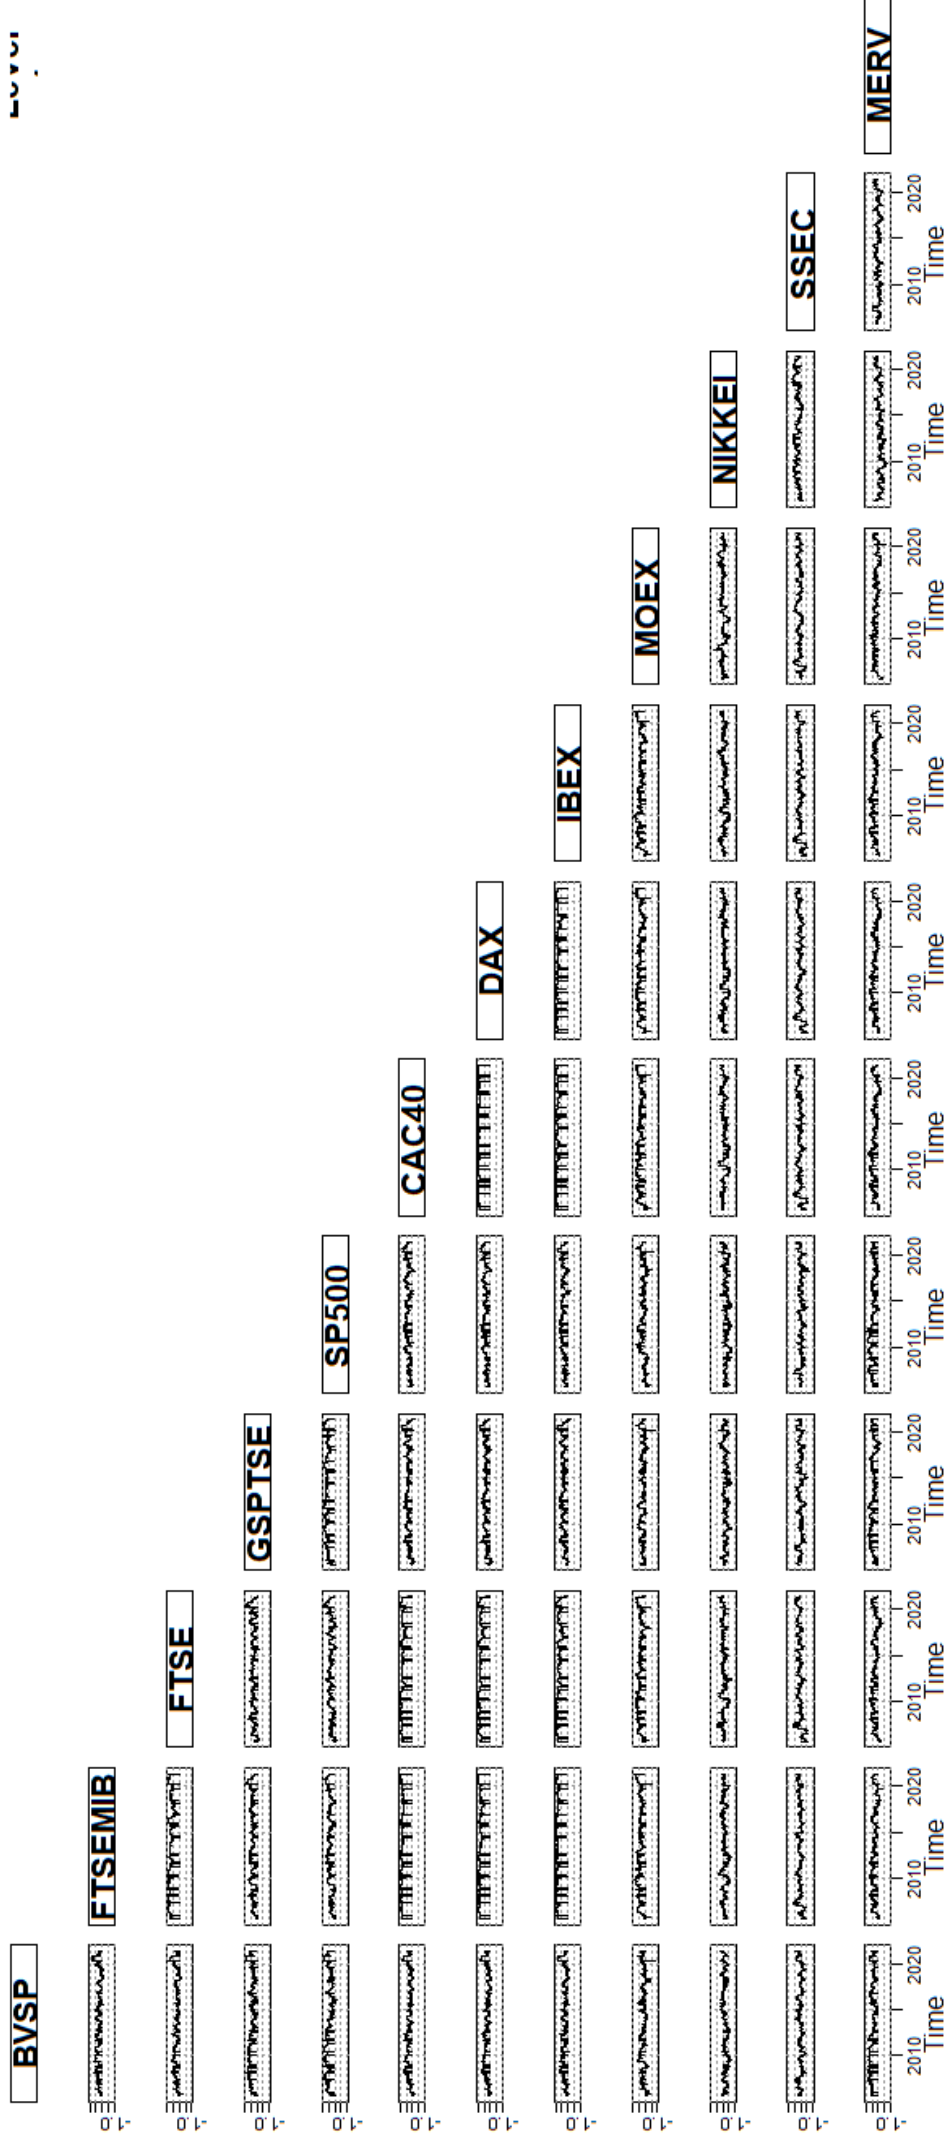


Figura 3: Estimação da Correlação Local no primeiro nível. Apesar das variações ocorridas, observa-se, um forte relacionamento linear entre as bolsas europeias (FTSEMIB, FTSE, CAC40, DAX e IBEX) em todo o período. Já as bolsas asiáticas, representadas por SSEC e NIKKEI, aparecem pouco relacionadas entre si e com as demais. O SP500 parece mais relacionado com a bolsa canadense (GSPTSE), mas também há certo grau de relacionamento com algumas bolsas europeias e com a bolsa brasileira (BVSP).

Figura 4 – Gráficos do segundo nível da estimação da Correlação Localizada entre os índices




Figura 4: Estimação da Correlação Local no segundo nível. Observa-se pouca variação na relação entre as séries, ficando próxima de zero em quase todo o período. São captados picos temporários na correlação no início de 2020.

Figura 5 – Gráficos do primeiro nível da estimação da Correlação Parcial Localizada entre os índices

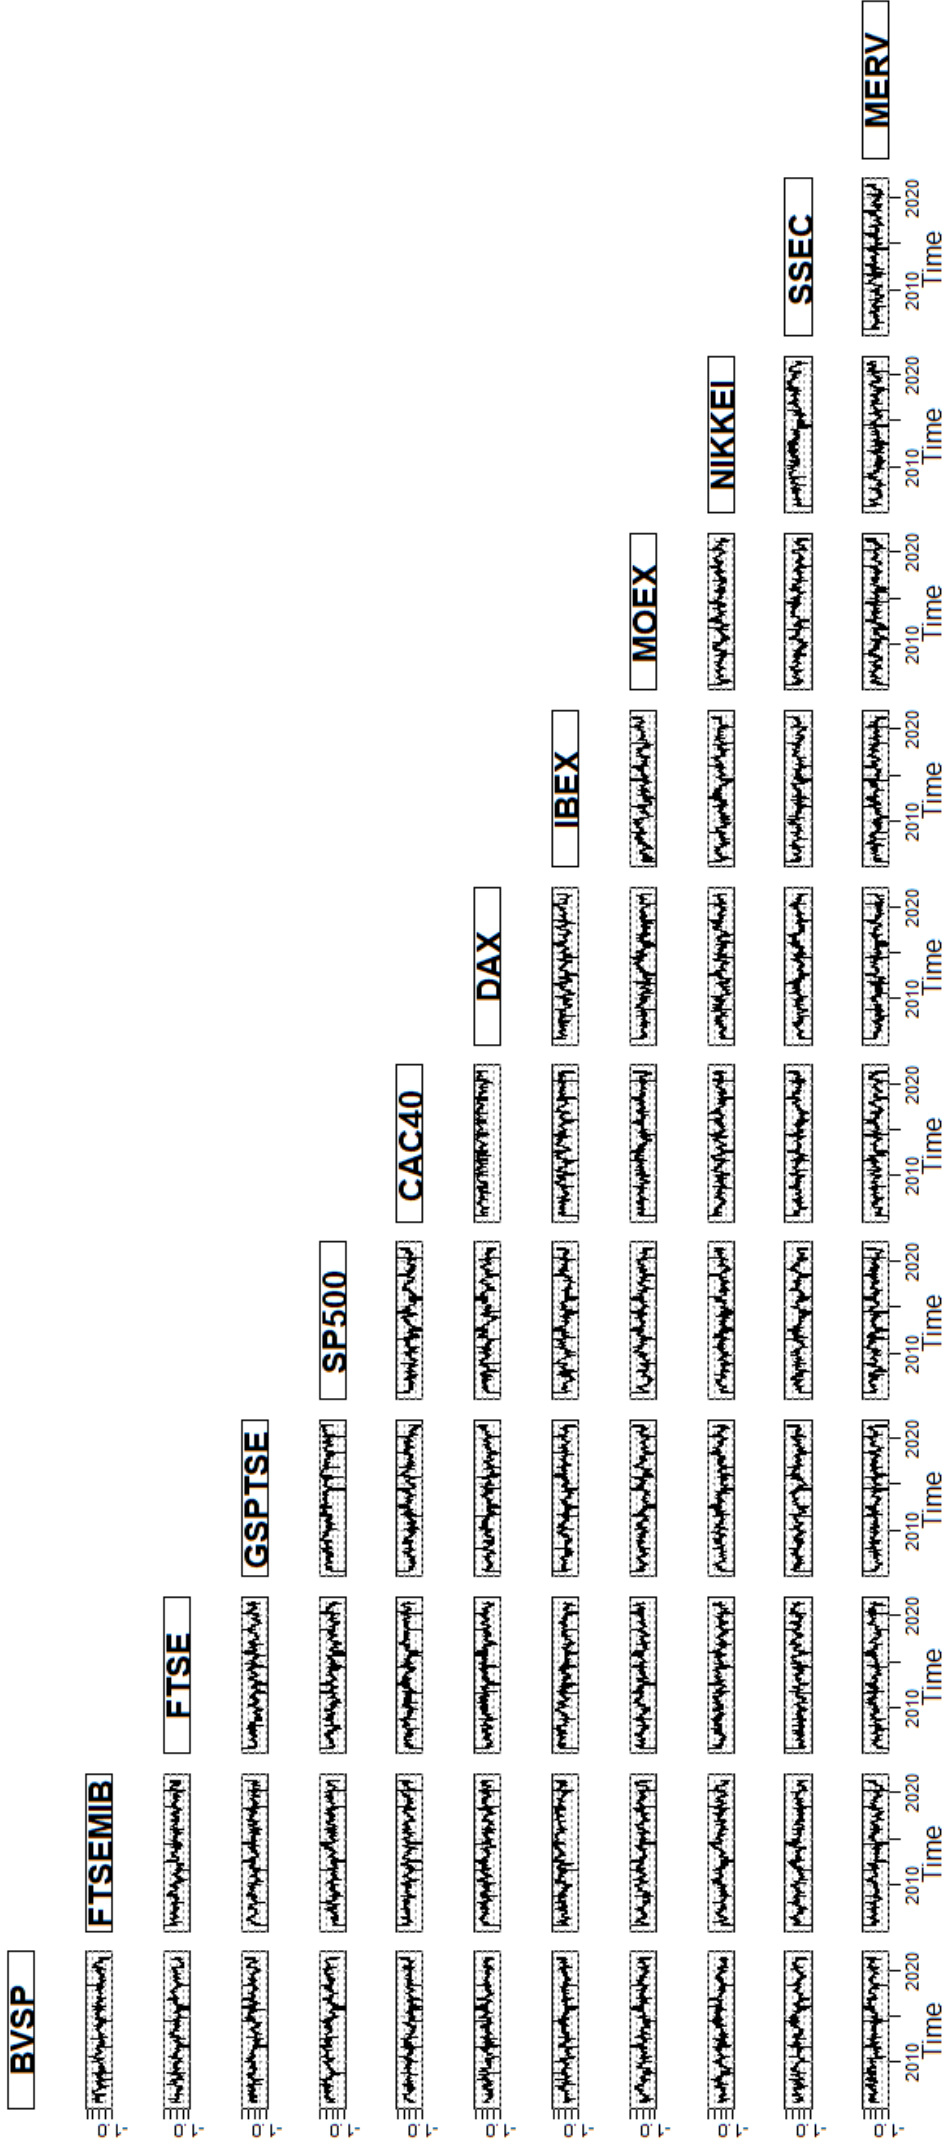


Figura 5: Considerar a correlação parcial localizada no primeiro nível. Nas bolsas europeias, que tiveram correlação mais alta no caso da correlação localizada, aparecem menos relacionadas apesar de alguns momentos com alta correlação. A alta correlação se mantém mais forte entre as séries GSPTSE e SP500.

Figura 6 – Gráficos do primeiro nível da estimação da Correlação Localizada entre os índices




Figura 6 : Considera a correlação parcial localizada no segundo nível. As correlações aparecem com valores próximos de zero. Com variações pontuais entre 2008 e 2009 e no início de 2020, mostrando uma relação mais forte, apesar de não parecer claro o sinal da relação, nesses dois momentos.

