

UNIVERSIDADE FEDERAL DE MINAS GERAIS
Faculdade de Ciências Econômicas
Centro de Pós-Graduação e Pesquisas em Administração

Letícia Drummond Rezende

DESEMPENHO EMPRESARIAL EM CRISES GLOBAIS:
Uma Análise da Volatilidade e Retornos das Ações, e do Desempenho Financeiro das
Empresas da B3, no Início da Guerra Russo-Ucraniana e da Pandemia da Covid-19

Belo Horizonte
2024

Letícia Drummond Rezende

**DESEMPENHO EMPRESARIAL EM CRISES GLOBAIS:
Uma Análise da Volatilidade e Retornos das Ações, e do Desempenho Financeiro das
Empresas da B3, no Início da Guerra Russo-Ucraniana e da Pandemia da Covid-19**

Tese apresentada ao Centro de Pós-Graduação e Pesquisa em Administração da Universidade Federal de Minas Gerais, como requisito parcial à obtenção do título de Doutora em Administração. Linha de Pesquisa: Finanças

Orientador: Prof. Dr. Antônio Artur de Souza

Belo Horizonte
2024

Ficha catalográfica

R467d Rezende, Letícia Drummond.

2024 Desempenho empresarial em crises globais [manuscrito]: uma análise da volatilidade e retornos das ações, e do desempenho financeiro das empresas da B3, no início da guerra russo-ucraniana e da pandemia da Covid-19 / Letícia Drummond Rezende. – 2024.
1v.: il.

Orientador: Antônio Artur de Souza
Tese (doutorado) – Universidade Federal de Minas Gerais, Centro de Pós-Graduação e Pesquisas em Administração.

Inclui bibliografia.

1. Crises – Teses. 2. Ações (Finanças) - Teses. 3. Bolsa de valores - Teses 4. Administração – Teses. I. Souza, Antônio Artur de. II. Universidade Federal de Minas Gerais. Centro de Pós-Graduação e Pesquisas em Administração. III. Título.

CDD: 338.542

Elaborado por Fabiana Santos CRB-6/2530

Biblioteca da FACE/UFMG. – FS 181/2023

ERRATA

Página	Linha	Onde se lê
4	10	“DESEMPENHO EMPRESARIAL EM CRISES GLOBAIS: Uma Análise dos Impactos da Pandemia da Covid-19 e da Guerra Russo-Ucraniana nos Resultados Financeiros, Volatilidade das Ações e Retornos da Empresas Brasileiras”
		Leia-se
		“DESEMPENHO EMPRESARIAL EM CRISES GLOBAIS: Uma Análise da Volatilidade e Retornos das Ações, e do Desempenho Financeiro das Empresas da B3, no Início da Guerra Russo-Ucraniana e da Pandemia da Covid-19”



UNIVERSIDADE FEDERAL DE MINAS GERAIS

ATA

FACULDADE DE CIÊNCIAS ECONÔMICAS
CENTRO DE PÓS-GRADUAÇÃO E PESQUISAS EM ADMINISTRAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM ADMINISTRAÇÃO

ATA DA DEFESA DE TESE DE DOUTORADO EM ADMINISTRAÇÃO da Senhora **LETÍCIA DRUMMOND REZENDE**, REGISTRO Nº 327/2024. No dia 31 de julho de 2024, às 13:00 horas, a Comissão Examinadora de Tese, indicada pelo Colegiado do Centro de Pós-Graduação e Pesquisas em Administração do CEPEAD, em 19 de julho de 2024, para julgar o trabalho final intitulado **"DESEMPENHO EMPRESARIAL EM CRISES GLOBAIS: Uma Análise dos Impactos da Pandemia da Covid-19 e da Guerra Russo-Ucraniana nos Resultados Financeiros, Volatilidade das Ações e Retornos das Empresas Brasileiras"**, requisito para a obtenção do **Grau de Doutora em Administração**, linha de pesquisa: **Finanças**. Abrindo a sessão, o Senhor Presidente da Comissão, Prof. Dr. Antônio Artur de Souza, após dar conhecimento aos presentes o teor das Normas Regulamentares do Trabalho Final, passou a palavra à candidata para apresentação de seu trabalho. Seguiu-se a arguição pelos examinadores com a respectiva defesa da candidata. Logo após, a Comissão se reuniu sem a presença da candidata e do público, para julgamento e expedição do seguinte resultado final:

☒ (x) APROVAÇÃO

☐ () REPROVAÇÃO

O resultado final foi comunicado publicamente à candidata pelo Senhor Presidente da Comissão. Nada mais havendo a tratar, o Senhor Presidente encerrou a reunião e lavrou a presente ATA, que será assinada por todos os membros participantes da Comissão Examinadora. Belo Horizonte, 31 de julho de 2024.

Prof. Dr. Antônio Artur de Souza
ORIENTADOR - CEPEAD/UFMG

Prof. Dr. Antônio Dias Pereira Filho
CEPEAD/UFMG

Prof. Dr. Hudson Fernandes Amaral
Centro Universitário Unihorizontes

Prof. Dr. Lélis Pedro de Andrade
IFMG

Profª. Drª. Simone Evangelista Fonseca

UFOP

Pro^{fa}. Dr^a. Simone Leticia Raimundini Sanches
UEM



Documento assinado eletronicamente por **Antonio Artur de Souza, Professor do Magistério Superior**, em 02/08/2024, às 11:19, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Antonio Dias Pereira Filho, Professor do Magistério Superior**, em 02/08/2024, às 12:19, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Hudson Fernandes Amaral, Membro**, em 04/08/2024, às 18:32, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Simone Leticia Raimundini Sanches, Usuário Externo**, em 06/08/2024, às 08:31, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Lelis Pedro de Andrade, Usuário Externo**, em 06/08/2024, às 08:37, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Simone Evangelista Fonseca, Usuária Externa**, em 06/08/2024, às 11:48, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no site https://sei.ufmg.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador 3395929 e o código CRC 61578120.

Agradecimentos

Apreendi sobre gratidão ao longo de vários anos na minha adultidade. Desde a infância, fui ensinada a dizer “obrigada” para o que ganhava ou recebia, sem compreender o valor dessa palavra. Nos caminhos que percorri, fui compreendendo mais sobre sentir gratidão... “Demorei” muitos estudos, palestras, documentários e livros para começar a perceber como essa palavra se traduzia dentro de mim... Agora, em meio à preparação final desta tese, reflito sobre os seres pelos quais sinto profunda gratidão!

Começo pela minha mãe, Gina, que partiu cedo para o mundo espiritual, dias antes da minha arguição para a seleção do doutorado. De onde ela estava, ajudou-me a lidar com toda a dor que eu sentia e com a percepção da finitude da vida física, experiências que me impulsionaram a tomar as rédeas da minha vida, realizar meus sonhos e não adiar minha felicidade. Muito obrigada, mãe, amo você!

Aos meus pais agradeço sempre pelas oportunidades, e por mais esta!

Agradeço imensamente ao querido e estimado Professor Antônio Artur de Souza, que foi a única pessoa, além de mim, a acreditar na minha competência e capacidade para fazer este doutorado. Desde o início, confiou em mim e abriu portas para diversos aprendizados na área de Finanças: avaliar trabalhos e TCCs, discutir projetos com outros orientandos, escrever artigos, participar de eventos, como investir, entre muitos outros; sempre entremeados pela constante disponibilidade de orientação para esta pesquisa e compreensão das minhas dificuldades. Sua confiança em mim encorajou meu coração e minha mente a fazerem e aprenderem o que eu precisava. “Gratificada” demais pela oportunidade, Prof.!

Aos Professores Lélis Pedro de Andrade e Hudson Fernandes Amaral agradeço pela participação na minha pesquisa desde o início, com questionamentos, considerações e sugestões que me permitiram reconduzir minha tese a um nível mais robusto e profundo na abrangência do tema e no entendimento do que realmente era válido investigar. Muito obrigada, professores!

Obrigada às profissionais da secretaria do Cepead, Luciana Coelho, Vera Dias, Erika Lage, Nádia e Danielle Cardoso, que me auxiliaram com informações e orientações durante minha jornada no doutorado. Agradeço também ao encontro com as(os) colegas Cristina Camila Teles Saldanha, Camila Teresa Martuchelli, João Eduardo Ribeiro, especialmente à Simone Evangelista Fonseca e Daniel Pereira Alves de Abreu, que gentilmente se dispuseram a me ensinar e ajudar com minhas dificuldades e dúvidas, dividindo atividades, oportunizando minha participação em alguns de seus trabalhos e contribuindo para meus aprendizados metodológicos

nesta tese. Agradeço também ao Professor Robert Aldo Iquiapaza pela gentileza no auxílio da coleta de alguns dados de que precisei na fase final da tese. Obrigada a cada um de vocês!

Um agradecimento precioso vai para os cães mais fofos e lindos que amo infinitamente, meus companheiros em todos os dias, compartilhando conquistas, inquietações e a poltrona que uso para estudar, escrever artigos, ensaios, projetos, análises no R, esta tese... Obrigada Neve, Liza, Clara e Guinness (que partiram ao longo dessas caminhadas), e Zeca, Gabriel, Valentina, Ginger, Pantufa, Sol, Uli, Loba, Maya e Snoopy que seguem por aqui — amo vocês para sempre!

À Fundação Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES)
pelo apoio financeiro nos últimos quatro anos.

RESUMO

A pandemia da Covid-19 desencadeou efeitos significativos nas economias globais, abalando os mercados, devido às estratégias de contenção da doença que impactaram a produção e o consumo. Em março de 2020 os mercados acionários mundiais enfrentaram volatilidades anormais, refletidas, por exemplo, nos sucessivos acionamentos do *circuit breaker*, como ocorreu no Brasil. Após dois anos do início da pandemia, quando as nações se encontravam em recuperação dos danos sanitários e econômicos causados pelo novo Coronavírus, uma nova crise surgiu com a invasão russa em território ucraniano. Esse conflito também provocou crises econômicas no cenário internacional, devido às sanções comerciais impostas à Rússia. Nos contextos dessas crises sobre as economias globais, o objetivo geral desta tese foi investigar se os primeiros meses das crises da Covid-19 e da guerra entre Rússia e Ucrânia impactaram o desempenho financeiro, a volatilidade dos preços e o retorno das ações das empresas brasileiras de capital aberto. A tese foi composta por três artigos, que analisam cada uma dessas três perspectivas, ou seja, o desempenho financeiro, os preços e os retornos das ações das empresas listadas na bolsa de valores brasileira (B3). O primeiro artigo identificou e analisou a relação entre as informações sobre a guerra na Ucrânia e os retornos das ações das empresas. A partir da Hipótese do Mercado Eficiente (HME), a metodologia utilizada foi o estudo de eventos que investigou o efeito do conflito sobre os retornos das ações, verificando se os mercados são eficientes, ou seja, se esses retornos refletem toda a informação disponível em momentos de crise. Os resultados indicaram que a guerra não teve impactos relevantes sobre os retornos das ações da B3. O segundo artigo avaliou a volatilidade dos preços das ações das empresas da B3, considerando o início da crise da Covid-19, no período entre janeiro/2020 e maio/2020. A análise, fundamentada na Teoria Moderna de Seleção de Portfólio de Markowitz, utilizou a metodologia de modelagem de heterocedasticidade condicional autorregressiva (ARCH). Os resultados mostraram que todos os setores apresentaram *clusters* de volatilidade, sendo os setores de tecnologia e saúde aqueles que apresentaram volatilidades mais intensas em meados de março/2020; isso sugeriu impactos mais importantes da pandemia nesses setores no pior momento da crise sanitária e econômica. O terceiro artigo analisou o comportamento do desempenho financeiro das empresas brasileiras, no período entre janeiro/2019 e março/2023, em reposta às crises da Covid-19 e da Guerra Russo-Ucraniana. A metodologia utilizada foi a análise de dados em painel. Os resultados sugeriram impactos de ambas as crises sobre o desempenho financeiro das empresas, sendo mais intensos no período inicial da pandemia. Uma contribuição desta pesquisa foi a validação da HME na prática por meio do estudo de eventos sobre a resposta do mercado acionário a notícias relacionadas às crises globais. As evidências empíricas sobre os efeitos da pandemia da Covid-19 e da guerra na Ucrânia nos mercados financeiros analisadas contribuem com o conhecimento sobre esses eventos e seus impactos no desempenho das empresas. Na prática, tal conhecimento fornece a investidores e organizações *insights* para avaliar os riscos e oportunidades em cenários de crises geopolíticas, auxiliando-os na melhor compreensão e gerenciamento dos riscos financeiros associados a eventos semelhantes no futuro, bem como na tomada de decisões de investimento mais racionais e planejadas. Nesse sentido, o entendimento sobre como os mercados reagem a eventos críticos pode fornecer insumos para o planejamento estratégico das empresas, com a finalidade de adaptarem suas estratégias de negócios de acordo com o ambiente econômico em momentos incertos e de mudança repentina.

Palavras-Chave: desempenho financeiro; crise da Covid-19; guerra Rússia-Ucrânia; retorno acionário; volatilidade; *circuit breaker*.

ABSTRACT

The Covid-19 pandemic has had significant effects on global economies, shaking the markets due to strategies to contain the disease that have impacted production and consumption. In March 2020, the world's stock markets faced abnormal volatility, reflected, for example, in the successive circuit breaker triggers, as occurred in Brazil. Two years after the start of the pandemic, when nations were recovering from the health and economic damage caused by the new Coronavirus, a new crisis arose with the Russian invasion of Ukrainian territory. This conflict also caused economic crises on the international stage, due to the trade sanctions imposed on Russia. In the context of these crises for global economies, the general objective of this thesis was to investigate whether the first few months of the Covid-19 crisis and the war between Russia and Ukraine had an impact on the financial performance, price volatility and return on shares of Brazilian listed companies. The thesis consists of three articles, which analyze each of these three perspectives, i.e. the financial performance, prices and returns of the shares of companies listed on the Brazilian stock exchange (B3). The first article identified and analyzed the relationship between information about the war in Ukraine and company stock returns. Based on the Efficient Market Hypothesis (EMH), the methodology used was an event study which investigated the effect of the conflict on stock returns, checking whether markets are efficient, i.e. whether these returns reflect all the information available in times of crisis. The results indicated that the war had no relevant impact on B3 stock returns. The second article evaluated the volatility of the share prices of B3 companies, considering the start of the Covid-19 crisis, in the period between January/2020 and May/2020. The analysis, based on Markowitz's Modern Portfolio Selection Theory, used the autoregressive conditional heteroscedasticity (ARCH) modeling methodology. The results showed that all sectors showed clusters of volatility, with the technology and health sectors showing the most intense volatility in mid-March/2020; this suggested more significant impacts of the pandemic on these sectors at the worst moment of the health and economic crisis. The third article analyzed the financial performance of Brazilian companies between January 2019 and March 2023 in response to the Covid-19 and Russian-Ukrainian War crises. The methodology used was panel data analysis. The results suggested that both crises had an impact on companies' financial performance, which was more intense in the initial period of the pandemic. One contribution of this research was to validate the HME in practice by studying events on the stock market's response to news related to global crises. The empirical evidence on the effects of the Covid-19 pandemic and the war in Ukraine on the financial markets analyzed contributes to knowledge about these events and their impacts on company performance. In practice, such knowledge provides investors and organizations with insights to assess the risks and opportunities in geopolitical crisis scenarios, helping them to better understand and manage the financial risks associated with similar events in the future, as well as to make more rational and planned investment decisions. In this sense, understanding how markets react to critical events can provide input for companies' strategic planning, with the aim of adapting their business strategies according to the economic environment in times of uncertainty and sudden change.

Keywords: financial performance; Covid-19 crisis; Russia-Ukraine war; stock returns; volatility; circuit breaker.

LISTA DE FIGURAS

Figura I. 1: Resposta fiscal à crise da Covid-19, em países por grupo de renda	16
Figura II.1 - Cenários para análise do evento da guerra Russo-Ucraniana sobre os retornos das ações da B3	37
Figura II.2 - Série temporal para a GR-U original, regressão linear e histograma.....	39
Figura II.3 - Série temporal para GR-U winsorizada a 5% à esquerda e sua regressão linear à direita	40
Figura II.4 - Decomposição da série temporal para GRU	41
Figura II.5 - Séries temporais e histogramas originais dos retornos setoriais, no início da GRU	46
Figura II.6 - Decomposições das séries temporais setoriais winsorizadas, na GRU	50
Figura III.1: Risco x Quantidade de Ações	62
Figura III.2: Carteira com Duas Ações	72
Figura III.3 – Metodologia Box-Jenkins para modelagem de séries temporais	72
Figura III.4 - Série temporal para a Covid-19 original, regressão linear e histograma	79
Figura III.5 - Série temporal para Covid-19 winsorizada a 5% à esquerda e sua regressão linear à direita	80
Figura III.6 - Decomposição da série temporal para Covid-19	81
Figura III.7 - Logaritmo neperiano da série temporal para Covid-19	81
Figura III.8 - 1ª Diferença (<i>log return</i>) da série temporal para Covid-19	81
Figura III.9 - Histograma da <i>st_precoscovid_diff1</i>	82
Figura III.10a - FAC para a série <i>st_precoscovid_diff1</i>	83
Figura III.10b - Dispersão da FAC para a série <i>st_precoscovid_diff1</i>	83
Figura III.10c - PFAC para a série <i>st_precoscovid_diff1</i>	83
Figura III.11 - FAC (esquerda) e PFAC (direita) para a série <i>st_precoscovid_diff1</i> ao quadrado	84
Figura III.12 - Sobreposição dos ajustes SARIMA (verde) à série <i>st_precoscovid_diff1</i> (azul)	85
Figura III.13 - FAC (esquerda) e PFAC (direita) para os resíduos da série após ajuste SARIMA	85
Figura III.14 - Volatilidades X Retornos da <i>st_precoscovid_diff1</i> no modelo TGARCH	86
Figura III.15 - FAC (esquerda) e FAC ao quadrado (direita) para o modelo TGARCH da <i>st_precoscovid_diff1</i>	87

Figura III.16 - Resíduos padronizados para o modelo TGARCH da <i>st_precoscovid_diff1</i>	87
Figura III.17 - Curva de impacto de notícias para o modelo TGARCH da <i>st_precoscovid_diff1</i>	88
Figura III.18 - Volatilidades X Retornos da <i>st_precoscovid_diff1</i> no modelo GARCH	90
Figura III.19 - FAC (esquerda) e FAC ao quadrado (direita) para o modelo GARCH da <i>st_precoscovid_diff1</i>	90
Figura III.20 - Resíduos padronizados para o modelo GARCH da <i>st_precoscovid_diff1</i>	91
Figura III.21 - “Calibração covid” em amarelo	92
Figura III.22 - “Previsão-covid” em azul	92
Figura III.23 - Perfil dos resíduos: a) Ajuste SARIMA (1,1,1); b) QQplot e regressão linear; c) FAC; d) PFAC	93
Figura III.24 - Previsões GARCH: a) 7 dias; b) 4 dias; c) 10 dias	94
Figura III.25 - Séries temporais Covid-19 (esquerda) e seus Histogramas (direita)	97
Figura III.26 - 1ª diferença das séries temporais setoriais da Covid-19	101
Figura III.27 - FAC e PFAC dos quadrados das séries setoriais para Covid-19	105
Figura III.28 - Sobreposição dos processos SARIMA (verde) às séries setoriais (azul)	107
Figura III.29 - “Calibração covid” (amarelo) e “previsão covid” (azul)	112
Figura III.30 - Previsões GARCH (azul)	115
Figura IV.1 - Impacto da Covid-19 sobre as vendas nas empresas em todo o mundo em meados de 2020	124
Figura IV.2a – ROA na Covid-19 (esquerda) e início da GR-U (direita)	155
Figura IV.2b – ROE na Covid-19 (esquerda) e início da GR-U (direita)	156
Figura IV.2c – ROIC na Covid-19 (esquerda) e início da GR-U (direita)	156
Figura IV.2d – Magem EBITDA na Covid-19 (esquerda) e início da GR-U (direita)	157
Figura IV.2e – Margem EBIT na Covid-19 (esquerda) e início da GR-U (direita)	157
Figura IV.2f – Preço/Lucro na Covid-19 (esquerda) e início da GR-U (direita)	158
Figura IV.2g – Liquidez Geral na Covid-19 (esquerda) e início da GR-U (direita)	158
Figura IV.2h – Liquidez Corrente na Covid-19 (esquerda) e início da GR-U (direita)	159
Figura IV.2i – Liquidez Seca na Covid-19 (esquerda) e início da GR-U (direita)	159
Figura IV.2j – Índice de Endividamento na Covid-19 (esquerda) e início da GR-U (direita)	159
Figura IV.2k – Índice de Cobertura na Covid-19 (esquerda) e início da GR-U (direita)	160
Figura IV.2l – Q de Tobin na Covid-19 (esquerda) e início da GR-U (direita)	160
Figura IV.2m – <i>Price to Book Value</i> na Covid-19 (esquerda) e início da GR-U (direita)	161

Figura IV.3a – DF x Rentabilidade: Covid-19 (esquerda) e início da GR-U (direita)	166
Figura IV.3b – DF x Lucratividade: Covid-19 (esquerda) e início da GR-U (direita)	167
Figura IV.3c – DF x Liquidez: Covid-19 (esquerda) e início da GR-U (direita)	168
Figura IV.3d – DF x Estrutura de Capital: Covid-19 (esquerda) e início da GR-U (direita) ..	169
Figura IV.3e – DF x Indicadores Financeiros: Covid-19 (esquerda) e início da GR-U (direita) .	169

LISTA DE QUADROS E TABELAS

Tabela II.1 – Quantidade de Empresas da B3 Classificadas por Setor	36
Tabela II.2 – Retornos médios e suas variâncias, antes e após o evento em 24/02/2022	42
Tabela II.3 – Testes de diferenças entre retornos médios e suas variâncias antes e após a GRU 41	
Tabela II.4 – Setores de Atividades no Período Inicial da GRU	43
Tabela II.5 – Retornos médios setoriais e variâncias, antes e após a invasão em 24/02/2022 .	50
Tabela II.6 – Testes de diferenças entre retornos e variâncias para os setores da B3, antes e após a GRU	52
Quadro III.1 – Padrões de FAC e FACP para modelos AR, MA e ARMA	72
Quadro III.2 – Padrões de FAC e FACP para modelos ARCH e GARCH	75
Tabela III.1 – N.º de Empresas da B3 por Setor, para Análise de Volatilidade	77
Tabela III.2 – Valores de AIC para os ajustes SARIMA de <i>st_precoscovid_diff1</i>	85
Tabela III.3 – Parâmetros do Modelo TGARCH para a série <i>st_precoscovid_diff1</i>	88
Tabela III.4- Teste ARCH-LM para os resíduos do Modelo TGARCH	89
Tabela III.5 – Estatísticas do Modelo GARCH	90
Tabela III.6 – Testes estatísticos para modelo GARCH	91
Tabela III.7 – Resultados da previsão do Modelo GARCH após o ajuste SARIMA (1,1,1) ...	94
Tabela III.8 – Setores de Atividades no Período Inicial da Covid-19	95
Tabela III.9 – Erros dos ajustes SARIMA para os setores	105
Tabela III.10 – Ordens dos processos SARIMA de cada setor, no início da Covid-19	107
Tabela III.11– Teste de Dickey-Fuller: estacionariedade setorial, no início da Covid-19	108
Tabela III.12 – Teste de Breusch-Godfrey: autocorrelação setorial nos resíduos	109
Tabela III.13 – Estatísticas do Modelo GARCH para os setores de atividades	110
Tabela III.14 – Testes dos resíduos dos modelos GARCH, no início da Covid-19	110
Tabela III.15 – Previsões dos Modelos GARCH após os ajustes SARIMA, para os setores .	112
Quadro IV.1 – GR-U: Perspectivas Econômicas sobre o Crédito Global	143
Quadro IV.2 – Indicadores e <i>Proxies</i> para Avaliação do Desempenho Financeiro das Empresas 146	
Tabela IV.1 – N.º de observações por <i>proxy</i> e por amostra, para Análise de Desempenho Financeiro	147
Quadro IV.3 – Modelos de Dados em Pannel	149
Tabela IV.2 – Estatísticas descritivas na pandemia e no início da guerra	153

Tabela IV.3 – Resultados dos testes de modelos de análises de dados em painel para o desempenho financeiro das empresas da B3 no início das crises da Covid-19 e da GR-U 162

LISTA DE ABREVIATURAS E SIGLAS

ANVISA = Agência Nacional de Vigilância Sanitária

ARCH = Heterocedasticidade condicional autorregressiva (*Autoregressive conditional heteroskedasticity*)

BACEN = Banco Central do Brasil

B3 = Brasil Bolsa Balcão (bolsa de valores brasileira)

BCB = Banco Central do Brasil

Covid-19 ou COVID-19 (*Coronavirus Disease*) = Doença provocada pelo coronavírus SARS-CoV-2, identificado no ano de 2019 na China

EGARCH = Heterocedasticidade condicional autorregressiva generalizada exponencial (*Exponential general autoregressive conditional heteroskedasticity*)

GARCH = Heterocedasticidade condicional autorregressiva generalizada (*Generalized autoregressive conditional heteroskedasticity*)

GR-U = Guerra Russo-Ucraniana

HME = Hipótese do Mercado Eficiente

IBGE = Instituto Brasileiro de Geografia e Estatística

IPEA = Instituto de Pesquisa Econômica Aplicada

MS = Ministério da Saúde

OMS = Organização Mundial da Saúde

PIB = Produto Interno Bruto

ROA = Retorno sobre o Ativo Total

ROE = Retorno sobre o Capital Próprio

ROIC = Retorno sobre o Capital Investido

TGARCH = Heterocedasticidade condicional autorregressiva generalizada limiar (*Threshold autoregressive conditional heteroskedasticity*)

SUMÁRIO

I. INTRODUÇÃO	19
I.1 PANDEMIA DA COVID-19 E IMPACTOS ECONÔMICOS INICIAIS NO MUNDO	19
I.2 IMPACTOS DA GUERRA RUSSO-UCRANIANA NAS ECONOMIAS MUNDIAIS	21
I.3 TEMA E PERGUNTA DE PESQUISA	23
I.4 OBJETIVO, RELEVÂNCIA E JUSTIFICATIVA	24
I.5 ESTRUTURA DA TESE	26
REFERÊNCIAS	27
II. O INÍCIO DA GUERRA ENTRE RÚSSIA E UCRÂNIA E OS RETORNOS DAS EMPRESAS DA B3	30
II.1 INTRODUÇÃO	30
II.2 REVISÃO DA LITERATURA	32
II.2.1 Hipótese do mercado eficiente	32
II.2.2 Reações do mercado acionário à guerra Russo-Ucraniana.....	35
II.3 METODOLOGIA	38
II.3.1 Estudo de eventos	38
II.3.2 Delimitação da pesquisa, população e amostra	40
II.3.3 Coleta dos dados.....	41
II.3.4 Método de análise dos dados	42
II.4 ANÁLISE E DISCUSSÃO DOS RESULTADOS	42
II.4.1 Retornos na guerra Russo-Ucraniana (sem segmentação setorial).....	43
II.4.2 Retornos na guerra Russo-Ucraniana (com segmentação setorial)	48
II.5 CONCLUSÕES	58
REFERÊNCIAS	59
III. VOLATILIDADE DOS PREÇOS DAS AÇÕES BRASILEIRAS NO INÍCIO DA PANDEMIA DA COVID-19	63
III.1 INTRODUÇÃO	63
III.2 REVISÃO DA LITERATURA	66
III.2.1 Teoria Moderna de Seleção de Portfólio.....	66
III.2.2 Reações do mercado acionário à crise da Covid-19 e efetividade(?) do circuit breaker sobre a volatilidade dos preços de ações.....	68
III.3 METODOLOGIA	81
III.3.1 Delimitação da pesquisa, população e amostra	81
III.3.2 Coleta dos dados.....	82
III.3.3 Análise dos dados.....	83
III.4 ANÁLISE E DISCUSSÃO DOS RESULTADOS	83
III.4.1 Preços na Covid -19 (sem segmentação setorial).....	83
III.4.2 Preços na Covid-19 (por setor de atividade)	100
III.5 CONCLUSÕES	120
REFERÊNCIAS	123
APÊNDICES	126
IV. DESEMPENHO FINANCEIRO DAS EMPRESAS DA B3 NAS CRISES DA COVID-19 E DA GUERRA RUSSO-UCRANIANA	129

IV.1 INTRODUÇÃO	129
IV.2 REVISÃO DA LITERATURA	133
IV.2.1 Desempenho financeiro.....	133
IV.2.2 Mensuração do desempenho financeiro	136
IV.2.3 Desempenho financeiro em ambiente de crise.....	141
IV.2.4 Efeitos da crise da Covid-19 nos mercados financeiros	142
IV.2.5 Vestígios da pandemia e impactos da guerra na Ucrânia nos mercados acionários	145
IV.3 METODOLOGIA	150
IV.3.1 Delimitação da pesquisa, população e amostra.....	150
IV.3.2 Definição de indicadores e proxies para mensurar o desempenho financeiro	150
IV.3.3 Coleta dos dados	153
IV.3.4 Regressão de dados em painel	154
IV.3.5 Análise de dados	158
IV.4 ANÁLISE E DISCUSSÃO DOS RESULTADOS	158
IV.4.1 Estatísticas descritivas e gráficos das séries temporais.....	158
IV.4.2 Análise de dados em painel	166
IV.5 CONCLUSÕES.....	174
REFERÊNCIAS	175
V. CONSIDERAÇÕES FINAIS.....	185
V.1 PRINCIPAIS RESULTADOS.....	185
V.2 CONTRIBUIÇÕES E LIMITAÇÕES DA PESQUISA	186
V.3 SUGESTÕES PARA PESQUISAS FUTURAS.....	187

I. INTRODUÇÃO

I.1 Pandemia da Covid-19 e impactos econômicos iniciais no mundo

Em relatório divulgado em 21 de janeiro de 2020 (WHO, Report-1, 2020), a Organização Mundial da Saúde (OMS) anunciou que, no final de dezembro de 2019, foram relatados casos de um tipo de pneumonia diagnosticados na cidade de Wuhan, província de Hubei, China, cujo agente causal ainda não havia sido identificado na época. No mês seguinte, as autoridades chinesas identificaram um novo tipo de coronavírus (denominado *2019-nCoV*) que causava a doença **Covid-19** (*Coronavirus Disease*) e os primeiros casos de contágio na Tailândia, Japão e República da Coreia; até que, em 20 de janeiro de 2020, foram confirmados 282 casos nesses países, com a China com 278 (sendo 51 pessoas gravemente doentes, 12 em estado crítico e 6 óbitos), além de 2 casos na Tailândia, 1 no Japão com 1 e 1 na República da Coreia (WHO, Report-1, 2020).

Com alta capacidade de transmissão, o novo coronavírus chegou à Itália no final de janeiro de 2020, com os dois primeiros casos de Covid-19 diagnosticados em pessoas que tinham histórico de viagens para Wuhan. Em resposta, a Equipe de Comunicação de Risco da OMS lançou a Rede de Informação da OMS para Epidemias, uma plataforma de informação destinada a compartilhar dados e informações preliminares sobre a doença com grupos-alvo específicos (WHO, Report-11, 2020). Com mais de 6.000 casos confirmados em 54 países, a OMS publicou em 29 de fevereiro de 2020 o documento *Rational Use of Personal Protective Equipment for COVID-19*, recomendando o uso adequado de equipamentos de proteção individual em ambientes de saúde e comunitários (WHO, Report-40, 2020).

Em 11 de março de 2020 o Diretor-Geral da OMS declarou que a Covid-19 caracterizava-se como pandemia (WHO, Report-51, 2020). O órgão destacou que o novo vírus infectava pessoas de todas as idades, apresentando maior risco de comprometimento da saúde para pessoas idosas e/ou em condições médicas subjacentes (comorbidades). Com a oficialização da pandemia, o Brasil declarou Emergência de Saúde Pública de Importância Nacional, com o Ministério da Saúde (MS) estabelecendo medidas sistemáticas de prevenção e controle da doença para a população.

Desde o início da pandemia, a OMS tem publicado relatórios que sintetizam os eventos mundiais relacionados à evolução dessa crise sanitária, que impactou a saúde e as economias mundiais. Segundo o relatório do Banco Mundial, *Finance for as Equitable Recovery* (World Bank, 2022), embora a renda das famílias e a receita das empresas tenham sido diretamente afetadas pela crise, o impacto da pandemia repercutiu em toda a economia, por meio de

inúmeros canais que conectam a saúde financeira das famílias e empresas, instituições financeiras e governos. Quando os lares e as empresas enfrentam estresse financeiro, o setor financeiro corre risco maior de inadimplência de empréstimos e é menos capaz de fornecer crédito. Da mesma forma, quando a situação financeira do setor público se deteriora, sua capacidade de apoiar as famílias e empresas pode enfraquecer.

No contexto de uma crise econômica como a gerada pela pandemia, políticas direcionadas à saúde financeira das famílias, das empresas e do setor financeiro desempenharam um papel importante. Em resposta aos *lockdowns* e às restrições de mobilidade necessárias para conter a propagação do novo coronavírus, muitos governos apoiaram mutuários por meio de transferências de dinheiro e ferramentas de política financeira, como moratórias de dívidas e garantias de crédito (*World Bank*, 2022). Governos, bancos centrais e reguladores também utilizaram ferramentas políticas para ajudar instituições financeiras e evitar que os riscos do setor financeiro se propagassem para outros setores da economia. Assim, bancos centrais reduziram taxas de juros, injetaram liquidez no mercado, ampliaram o acesso a refinanciamento e requisitos reduzidos de provisionamento; tais medidas permitiram bancos e outras instituições a manterem a oferta de financiamento às famílias e empresas (*World Bank*, 2022).

Os Bancos Centrais também fizeram uso de ferramentas de política monetária não convencionais, como programas de compra de ativos. Dessa forma, vinte e sete economias emergentes adotaram tais programas pela primeira vez. Tais medidas visaram à prevenção de uma crise de liquidez e a salvaguarda da estabilidade econômica; entretanto, a moratória da dívida e a provisão de liquidez adicional para o setor financeiro não alteram as condições econômicas subjacentes dos mutuários. Dessa forma, a resposta à crise também precisou incluir políticas para riscos decorrentes dos altos níveis da dívida soberana e garantir que os governos preservassem sua capacidade de apoiar efetivamente a recuperação (*World Bank*, 2022).

As medidas adotadas para mitigar o impacto imediato da pandemia nos lares e nas empresas exigiram gastos governamentais incrementais em uma época na qual muitos governos já estavam onerados por elevados níveis de dívida pública. A gestão e a redução de altos níveis de dívida soberana foram, portanto, uma condição importante para uma recuperação equitativa. O Banco Mundial identificou desigualdades consideráveis entre as respostas à crise pelos países, resultados das diferenças em recursos e ferramentas políticas disponíveis para os governos (*World Bank*, 2022). Como consequência, muitos países de baixa renda lutaram para mobilizar recursos para combater os efeitos imediatos da pandemia, ou assumiram nova dívida

para financiar a resposta à crise. Como exemplo, durante o primeiro ano da pandemia, o estoque da dívida dos países do G20 aumentou de 54% para 61% do PIB, limitando ainda mais a capacidade de resposta a uma recuperação prolongada. A Figura 1 mostra a variação expressiva entre esses países na escala da resposta fiscal nesse período.




Figura I.1 – Resposta fiscal à crise da Covid-19 no primeiro ano, em países por grupo de renda.

Fonte: *World Bank*, 2022, com base no Fundo Monetário Internacional.

Nota: Dados são a partir de 27 de setembro de 2021.

A magnitude da resposta fiscal como parte do PIB foi elevada uniformemente por qualquer métrica histórica em países de alta renda, e pequena ou inexistente em países de baixa renda. Nos países de renda média, como o Brasil, a resposta fiscal variou significativamente, refletindo diferenças na capacidade e vontade dos governos de mobilizar recursos fiscais para programas de apoio. Medidas de emergência fiscal foram apoiadas por grandes intervenções de política monetária, principalmente em países desenvolvidos. Já em países de baixa renda, os governos foram constrangidos na resposta à crise, uma vez que a política monetária não foi capaz de desempenhar um papel de apoio semelhante (*World Bank*, 2022). Como resultado, o impacto inicial da pandemia se traduziu no aumento da desigualdade entre os países.

I.2 Impactos da guerra Russo-Ucraniana nas economias mundiais

Em anos recentes, tem ocorrido um aumento de pesquisas sobre a relação entre petróleo bruto e o mercado financeiro, especialmente o acionário, e seu comportamento multifractal e persistente (Mensi, Hamdi, & Yoon, 2018; Mensi, Tiwari, & Al-Yahyaee, 2019; Tiwari, Aye, & Gupta, 2019; Yao, Lu, & Ju, 2020; Rehman, Ahmad, & Vo, 2022). Uma das razões para tal

movimento na literatura científica é o aumento da incerteza gerada por diferentes atividades e crises econômicas (Adekoya, Asl, Oliyide, & Izadi, 2022). A forma como a maioria dessas crises evolui localmente, espalha-se rapidamente a nível global e contamina o mercado financeiro, permanece sendo uma preocupação entre os pesquisadores (Adekoya *et al.*, 2022^a).

Em sua maioria, as crises influenciam os preços dos ativos devido à incerteza provocada nos investidores e suas decisões, afetando a volatilidade e a viabilidade de investimento desses ativos. Enquanto o mundo ainda enfrentava os efeitos da pandemia da Covid-19, o ataque russo ao território ucraniano no início de 2022, foi descrito como o conflito mais severo na Europa desde a Segunda Guerra Mundial (Adekoya, Oliyide, Yaya, & Al-Faryan, 2022).

Ao contrário de outros eventos de *black swan*¹, a guerra tem uma tendência crescente de influenciar os mercados acionários globais. Isso porque os conflitos aumentam a incerteza dos investidores sobre a rentabilidade futura das empresas nos países envolvidos direta e indiretamente na guerra, resultando em flutuações nos preços de suas ações (Choudhry, 2010). Ademais, as relações comerciais entre os países em guerra e aqueles que não estão em guerra são impactadas pelo pós-guerra, afetando negativamente a produção, a rentabilidade, as decisões e os preços das ações.

Embora a guerra seja entre a Rússia e a Ucrânia, ela gerou repercussões a nível internacional, levando a diferentes sanções contra a Rússia por parte de países como Estados Unidos, Canadá, Reino Unido e alguns da União Europeia. Tais medidas provocaram medo nos investidores, influenciando suas decisões de investimento em ativos (Parveen, Satti, Subhan, & Jamil, 2020). Como a Rússia é um dos maiores produtores e exportadores mundiais de petróleo bruto, a guerra causou uma escassez no fornecimento dessa *commodity*, levando a aumentos significativos no seu preço.

A escassez de oferta de petróleo bruto tem implicações importantes para os países que dependem da sua exportação pela Rússia, mas também de outras *commodities* e ativos financeiros que têm uma conexão com o petróleo (Adekoya, & Oliyide, 2021; Adekoya *et al.*, 2022b). Como explicam Ma, Wei, Huang e Zhao (2013) e Wang e Xie (2012), a instabilidade do petróleo bruto pode representar dúvidas sobre a eficiência, persistência e natureza multifractal de outros ativos financeiros.

¹ O evento de *black swan* no mercado acionário consiste em um evento imprevisível, além do que normalmente se espera de uma situação e tem consequências potencialmente graves. Tais eventos são caracterizados por sua extrema raridade, impacto severo e a insistência generalizada de que eles eram óbvios em retrospectiva (<https://www.investopedia.com/terms/b/blackswan.asp>).

Vários estudos documentam como a guerra Rússia-Ucrânia afetou o desempenho dos mercados financeiros e as inter-relações sob perspectivas diferentes. Considerando o grau de dependência dos países em relação às *commodities* russas, Lo, Marcelin, Bassene e Sene (2022) revelam que a guerra tem um efeito negativo mais forte sobre a volatilidade do mercado financeiro do que os retornos. Os autores complementam que os impactos são sentidos pelos mercados desenvolvidos mais expressivamente do que pelos emergentes. O impacto negativo da guerra no retorno das ações também é confirmado por Boungou e Yatie (2022), que analisaram 94 países, sendo aqueles nas fronteiras da Rússia e da Ucrânia os mais afetados.

Trazendo o foco dessa análise para o Brasil, em uma nota técnica do Instituto de Pesquisa Econômica Aplicada (IPEA) (IPEA, n.º 54, 2022), os efeitos da guerra entre Rússia e Ucrânia foram observados nos desequilíbrios do fornecimento de petróleo e derivados, produtos agrícolas (trigo, milho e óleo de girassol) e fertilizantes. Instabilidades como estas acometem a segurança energética e alimentar, refletindo na alta dos seus preços e em possível escassez de fertilizantes, essenciais para a produção agrícola nacional.

O Brasil exporta produtos agrícolas à Rússia, como soja em grãos, carnes e tabaco, que representam 53,2% das exportações brasileiras ao mercado russo e 15,9% das exportações brasileiras totais desses produtos (IPEA, n.º 54, 2022). No caso do comércio entre Brasil e Ucrânia, as exportações ucranianas para o Brasil não são economicamente expressivas, assim como as exportações brasileiras para a Ucrânia (IPEA, n.º 54, 2022). Em todo o mundo, os pontos mais preocupantes são o aumento generalizado do preço do barril de petróleo, do gás e derivados, provocando uma elevação da inflação global, e o aumento no preço dos grãos.

Esses impactos destacam a interconexão e interdependência das economias globais, nas quais conflitos em uma região do mundo podem ter repercussões significativas em outras partes do planeta, como no Brasil. Essa complexa rede de interações econômicas reforça a importância dos eventos geopolíticos e suas consequências nos mercados financeiros e na economia dos países (IPEA, n.º 54, 2022).

I.3 Tema e pergunta de pesquisa

O tema da presente pesquisa versa sobre os efeitos de crises econômicas sobre o desempenho financeiro, a volatilidade dos preços e os retornos das ações de empresas brasileiras de capital aberto. A necessidade de examinar o mercado financeiro em momentos de crise torna-se crucial devido ao seu papel fundamental na economia, como um ecossistema que assegura que os fluxos monetários ocorram de forma adequada, permitindo que atividades

produtivas tragam benefícios à coletividade (Pereira, 2017). A regulação do mercado financeiro visa garantir que o fluxo de informações seja acessível a todos os interessados e que a assimetria de informações seja reduzida, diminuindo a ocorrência de operações vantajosas (por especulação ou arbitragem) apenas para determinadas pessoas, empresas ou grupos.

Nesse sentido, esta tese propôs a análise dos efeitos iniciais das crises da pandemia da Covid-19 e da guerra entre a Rússia e a Ucrânia sobre o desempenho financeiro, a volatilidade dos preços das ações e seus retornos das empresas brasileiras listadas na B3. O estudo realizado analisou os efeitos imediatos das crises, como interrupção de atividades econômicas, isolamento social, acionamento do *circuit breaker*, altas inflacionárias e cambiais, bem como os efeitos gerados pela disseminação de notícias relacionadas a tais crises e seus impactos sobre os preços e retornos das ações dessas empresas.

Considerando os dois cenários de crise, a pergunta de pesquisa desta tese foi: **houve impactos sobre o retornos e a volatilidade dos preços das ações, e sobre o desempenho financeiro das empresas brasileiras de capital aberto no início da pandemia da Covid-19 e da Guerra Russo-Ucraniana, no período entre 2020 e 2023?** Tal pergunta visou investigar e quantificar os efeitos de ambas as crises no mercado financeiro brasileiro, especificamente sobre as empresas listadas na B3.

I.4 Objetivo, relevância e justificativa

O objetivo geral desta tese foi mensurar os impactos no desempenho financeiro, na volatilidade dos preços das ações e nos respectivos retornos de empresas brasileiras de capital aberto (listadas na B3), decorrentes das crises econômicas da Covid-19 e da guerra entre Rússia e Ucrânia. Para alcançar esse objetivo, foram definidos três objetivos específicos. Na esteira da pandemia sobre os mercados internacionais, o conflito entre a Rússia e a Ucrânia surgiu em um momento crítico para a economia global, postergando as perspectivas de recuperação econômica relativas à crise da Covid-19. Isso instigou a investigação do comportamento do mercado acionário brasileiro mediante o evento da guerra. Assim, o primeiro objetivo específico foi:

a) Analisar a relação entre o início do conflito na Ucrânia e os retornos das ações do mercado brasileiro, no período entre janeiro/2022 e junho/2022.

O período definido levou em conta que, no Brasil, a partir de agosto/2022, iniciou-se a veiculação de propaganda eleitoral que poderia enviesar os dados, em função das perspectivas de propostas político-econômicas dos candidatos e sua influência no comportamento dos

investidores do mercado acionário; dessa forma, limitando o estudo ao mês de julho/2022, a expectativa foi de coleta de dados não “contaminados” pelo processo eleitoral. O segundo objetivo específico foi:

b) Avaliar a volatilidade dos preços das ações de empresas da B3, entre janeiro/2020 e maio/2020 em função da pandemia da Covid-19.

Considerou-se o mês de março/2020 como o “pico” das quedas das ações das empresas da B3, quando a bolsa acionou em seis momentos o mecanismo do *circuit breaker* na tentativa de controlar as altas volatilidades. O terceiro objetivo específico teve a intenção de averiguar o comportamento dos resultados financeiros das empresas da B3, como forma complementar de análise das respostas do mercado acionário nacional às crises em tratadas nesta pesquisa. Assim, o terceiro objetivo foi:

c) Analisar o desempenho financeiro de empresas listadas na B3 frente aos efeitos das crises da Covid-19 (janeiro/2019 a dezembro/2021) e da Guerra Russo-Ucraniana (janeiro/2022 e março/2023).

A janela temporal desse objetivo foi definida considerando o início dos indícios da Covid-19 no mundo e o 1º ano desde o início da guerra em 2022. A análise da crise da Covid-19 até dezembro/2021 incluiu o início do protocolo vacinal no Brasil, enquanto a guerra permanece em andamento.

A relevância desta pesquisa centrou-se, em parte, na importância de analisar os efeitos de uma pandemia sobre o mercado acionário brasileiro, dada sua abrangência socioeconômica e mundial, e a duração prolongada (Avelar, Ferreira, da Silva, & Ferreira, 2021). O entendimento dos seus impactos torna-se crucial para as empresas formularem estratégias econômicas e de investimento futuras que considerem ações de contingenciamento de possíveis danos financeiros. Backes Arias, Storopoli e Ramos (2020) reforçam essa relevância, afirmando que para alguns países, a crise econômica será mais profunda e duradoura, especialmente em economias pouco desenvolvidas e emergentes.

O fato de a maioria dos estudos científicos sobre os efeitos da crise da Covid-19 em mercados acionários abordarem essencialmente mercados europeus e asiáticos apresentou-se como uma justificativa para trazer o foco ao mercado brasileiro. Segundo Avelar *et al.* (2021), o fato de a Covid-19 ser uma crise relativamente recente oferece oportunidades investigativas sobre o tema. Okorie e Lin (2021) também sublinham a importância desta pesquisa, ao relatarem que os efeitos da crise da Covid-19 sobre a eficiência das informações de mercado (*ex-ante* e *ex-post*) foram significativos nas quatro principais economias afetadas pela

pandemia²: Estados Unidos (4.703.727 casos), Brasil (2.66.298 casos), Índia (1.697.054 casos) e Rússia (839.981 casos).

Uma outra parte desta tese foi dedicada à análise da relação entre a guerra entre a Rússia e a Ucrânia e o mercado acionário brasileiro, cuja relevância deveu-se às implicações nas relações comerciais do país, especialmente no setor do agronegócio, responsável por 23,8% do PIB do Brasil em 2023, segundo estudo do Centro de Estudos Avançados em Economia Aplicada (Cepea) da Esalq/USP, em parceria com a Confederação da Agricultura e Pecuária do Brasil (CNA) (CEPEA, 2024). A importância da discussão de um conflito geopolítico nos preços e retornos das ações de empresas brasileiras ganha respaldo em um contexto de interconectividade econômica e financeira global, bem como na escassez de estudos sobre os efeitos desse conflito no mercado de capitais brasileiro.

Quanto à influência da guerra nas relações comerciais entre Brasil e Rússia, principalmente no setor do agronegócio, de acordo com um relatório do banco mundial (Ruta, 2022), a Rússia e Bielorrússia são, respectivamente, o segundo e o terceiro maiores produtores mundiais de fertilizante de potássio, e o Brasil importa quase a metade dos fertilizantes desses países. Como a maior parte da soja do Brasil é exportada para a China, uma interrupção no fornecimento de fertilizantes para o Brasil poderia causar uma reação em cadeia, afetando os preços de vários alimentos no Brasil e o da carne na China, por exemplo, uma vez que este país utiliza a maior parte da soja brasileira para alimentação da sua produção pecuária (Ruta, 2022).

I.5 Estrutura da tese

Esta tese é composta por cinco capítulos, sendo que os capítulos II, III e IV foram elaborados em forma de artigos, para submissão a periódicos nacionais e internacionais. O primeiro capítulo introduz o tema e a pergunta de pesquisa, bem como os objetivos geral e específicos, a relevância e a justificativa do estudo. O segundo capítulo (1º artigo) relaciona-se ao primeiro objetivo específico, concernente à investigação do evento da guerra na Ucrânia e possíveis efeitos sobre os retornos das ações das empresas da bolsa de valores brasileira (B3).

O terceiro capítulo (2º artigo) está associado ao segundo objetivo específico, avaliando a volatilidade dos preços das ações das empresas do capítulo anterior, no cenário do início da pandemia da Covid-19. O capítulo quatro (3º artigo) corresponde à análise do desempenho financeiro das empresas brasileiras, face às crises da Covid-19 e da Guerra Russo-Ucraniana.

² Com base no número de casos confirmados de coronavírus. Recuperado de: <https://www.worldometers.info/coronavirus/>.

Finalmente o capítulo cinco traz as conclusões gerais da pesquisa, pontuando os principais resultados encontrados, contribuições e limitações da pesquisa, bem como sugestões para estudos futuros que possam ampliar o conhecimento sobre o comportamento de mercados acionários no enfrentamento de crises mundiais.

Referências

- Adekoya, O. B., Asl, M. G., Oliyide, J. A., & Izadi, P. (2022^a). Multifractality and cross-correlation between the crude oil and the European and non-European stock markets during the Russia-Ukraine war. *Resources Policy*, 80.
- Adekoya, O. B., & Oliyide, J. A. (2021). How Covid-19 Drives Connectedness Among Commodity and Financial Markets: Evidence from TVP-VAR and Causality-in-Quantiles Techniques. *Resour. Pol*, 70.
- Adekoya, O.B., Oliyide, J.A., Yaya, O.S., & Al-Faryan, M.A.S. (2022b). Does oil connect differently with prominent assets during war? Analysis of intra-day data during the Russia-Ukraine saga. *Resour. Pol*. 77. <https://doi.org/10.1016/j.resourpol.2022.102728>.
- Avelar, E. A., Ferreira, P. O., da Silva, B. N. E. R., & Ferreira, C. O. (2021). Efeitos da Pandemia de Covid-19 sobre a Sustentabilidade Econômico-Financeira de Empresas Brasileiras. *RGO – Revista Gestão Organizacional*, 14(1), 131-152.
- Backes, D. A. P., Arias, M. I., Storopoli, J. E., & Ramos, H. R. (2020). Os Efeitos da Pandemia de Covid-19 sobre as Organizações: Um Olhar para o Futuro. *Iberoamerican Journal of Strategic Management*, 19(5), 1-10. Editorial. Recuperado de: <https://doi.org/10.5585/riac.v19i4.18987>.
- Boungou, W., & Yatie, A. (2022). The impact of the Ukraine-Russia war on world stock returns. *Econ. Lett.* 215, 110516.
- CEPEA. PIB do Agronegócio Brasileiro. 26/03/2024. Recuperado de: <https://www.cepea.esalq.usp.br/br/pib-do-agronegocio-brasileiro.aspx#:~:text=Diante%20disso%2C%20%20PIB%20do,trimestres%20reverteram%20a%20tend%C3%Aancia%20positiva>.
- Choudhry, T. (2010). World war II events and the Dow Jones industrial index. *J. Bank. Finance*, 34 (5), p. 1.022-1.031.
- Fama, E. F. (1970). Efficient Capital Markets: A Review of Theory and Empirical Work. *Journal of Finance*, 25(2), 383-417.
- IPEA. Nota Técnica. Nonnenberg, M. J. B., & Martins, M. M. V. Como a guerra na Ucrânia poderá afetar o comércio exterior? Efeitos sobre o Brasil. Carta de Conjuntura, n.54, Nota de Conjuntura 22, 1º trimestre de 2022.

Lo, G., Marcelin, I., Bassene, T., & Sene, B. (2022). The Russo-Ukrainian war and financial markets: the role of dependence on Russian commodities. *Finance Res. Lett.* 50, 103194.

Ma, F., Wei, Y., Huang, D., & Zhao, L. (2013). Cross-correlations between West Texas Intermediate crude oil and the stock markets of the BRIC. *Phys. Stat. Mech. Appl.* 392 (21), 5356–5368. <https://doi.org/10.1016/j.physa.2013.06.061>.

Mensi, W., Hamdi, A., & Yoon, S. (2018). Modelling multifractality and efficiency of GCC stock markets using the MF-DFA approach: a comparative analysis of global, regional and Islamic markets. *Physica A*, 503, p. 1.107-1.116.

Mensi, W., Tiwari, A.K., & Al-Yahyaee, K.H. (2019). An analysis of the weak form efficiency, multifractality and long memory of global, regional and European stock markets. *Q. As. Econ. Finance*, 72, p. 168-177.

Moreira, J. C. C., Nganga, C. S. N., & Telles, S. V. (2020). *Impacto da COVID-19 no Retorno das Ações do Mercado Brasileiro*. Anais XX USP International Conference in Accounting. São Paulo/SP.

Okorie, D. I., & Lin, B. (2021). Adaptative Market Hypothesis: The Story of the Stock Markets and Covid-19 Pandemic. *The North American Journal of Economics and Finance*, 57:101397.

Parveen, S., Satti, Z.W., Subhan, Q.A., & Jamil, S. (2020). Exploring market overreaction, investors' sentiments and investment decisions in an emerging stock market. *Borsa Istanbul Review*, 29(3), p. 224-235.

Pereira, A. L. L. (2017). A Moderna Teoria Financeira: Origem, Evolução e Importância na Atualidade. *Negócios em Projeção*, 8(1), p. 127-138.

Rehman, M.H., Ahmad, N., & Vo, X.V. (2022). Asymmetric multifractal behaviour and network connectedness between socially responsible stocks and international oil before and during Covid-19. *Physica A*, 126489.

Ruta, Michele. (2022). World Bank. *The Impact of the War in Ukraine on Global Trade and Investment. Trade, Investment and Competitiveness; Equitable Growth, Finance and Institutions Insight*. Washington, D.C.: World Bank Group. Recuperado de: <http://documents.worldbank.org/curated/en/099750104252216595/IDU0008eed66007300452c0beb208e8903183c39>.

Tiwari, A.K., Aye, G.C., & Gupta, R. (2019). Stock market efficiency analysis using long spans of Data: a multifractal detrended fluctuation approach. *Finance Res. Lett.*, 28, p. 398-411.

Wang, G., & Xie, C. (2012). Cross-correlations between WTI crude oil market and US stock market: a perspective from econophysics. *Acta Phys. Pol., B* 43.

WHO (World Health Organization). *Novel Coronavirus (2019-nCoV)*. Situation Report-1. (2020). Recuperado de: <https://www.who.int/emergencies/diseases/novel-coronavirus-2019/28situation-reports>.

WHO (World Health Organization). *Novel Coronavirus (2019-nCoV)*. Situation Report-11. (2020). Recuperado de: <https://www.who.int/emergencies/diseases/novel-coronavirus-2019/situation-reports>.

WHO (World Health Organization). *Novel Coronavirus (2019-nCoV)*. Situation Report-40. (2020). Recuperado de: <https://www.who.int/emergencies/diseases/novel-coronavirus-2019/situation-reports>.

WHO (World Health Organization). *Novel Coronavirus (2019-nCoV)*. Situation Report-51. (2020). Recuperado de: <https://www.who.int/emergencies/diseases/novel-coronavirus-2019/situation-reports>.

World Bank. (2022). *World Development Report 2022: Finance for an Equitable Recovery*. Washington, DC: World Bank. Doi:10.1596/978-1-4648-1730-4.

Yao, C., Liu, C., & Ju, W. (2020). Multifractal analysis of the WTI crude oil market, US stock market and EPU. *Physica A*, 550, 124096.

II. O INÍCIO DA GUERRA ENTRE RÚSSIA E UCRÂNIA E OS RETORNOS DAS EMPRESAS DA B3

II.1 Introdução

A invasão da Ucrânia pela Rússia perdura até o presente momento, tendo reflexos na devastação das vidas dos cidadãos ucranianos, na economia local e no comércio internacional (Nonnenberg & Martins, 2022). Os mercados de capitais também sentiram esses reflexos, em decorrência das sanções econômicas impostas à Rússia pelos Estados Unidos e alguns países europeus. Os autores relatam que a essas sanções impostas sobre o sistema financeiro e o banco central russos, somam-se diversas medidas tomadas por empresas privadas, com grande potencial para afetar tanto exportações quanto importações da Rússia, estendendo-se à Bielorrússia. Como consequência, isso promoveria elevações de preços e efeitos importantes sobre a produção e renda globais, com efeitos secundários sobre o comércio.

Nonnenberg e Martins (2022) afirmam que os mercados dos principais produtos potencialmente afetados, petróleo e derivados, milho, trigo e óleo vegetal e fertilizantes (importantes no caso do Brasil) foram impactados pelas sanções, uma vez que a Rússia é o principal fornecedor mundial de trigo, o segundo maior exportador de óleo vegetal (15,5%) e oitavo maior ofertante de milho (2%). Já a Ucrânia é a maior fornecedora mundial de óleo vegetal, com 42,3% das exportações mundiais, a sexta maior economia exportadora de trigo e quarta maior exportadora de milho (11,6%). Os dois países juntos respondem por 49,5%, 57,8% e 13,6% das exportações globais, respectivamente, de trigo, óleo de girassol e milho (Nonnenberg & Martins, 2022).

Sobre o comércio entre Brasil e Ucrânia, os principais produtos ucranianos adquiridos pelo Brasil variam entre medicamentos para fins terapêuticos ou profiláticos e aquecedores elétricos para diversas finalidades, além de malte e laminados planos de ferro ou aço, porém representando um valor comercial relativamente reduzido. Já nas importações ucranianas de produtos brasileiros, predominam itens agrícolas processados (tabaco e extratos, essências ou preparações à base de café, chá e mate), produtos minerais primários ou processados (alumínio bruto e ferro-ligas) e veículos usados (Nonnenberg & Martins, 2022).

Pinheiro e Matos (2022) afirmam que um primeiro efeito do conflito entre Rússia e Ucrânia foi a disparada nos preços globais de *commodities* de energia e agrícolas. As sanções que contribuíram para reduzir a oferta desses produtos, elevando seus preços. No caso do Brasil e de alguns países da América Latina, o fato de serem economias exportadoras líquidas de

commodities e, ao mesmo tempo, terem relações comerciais limitadas com a Rússia atenuou o choque externo (Pinheiro, & Matos, 2022).

Guerras trazem uma componente adicional de incerteza para as economias, elevando o risco de aumento de inflação e aprofundando o desarranjo da cadeia de suprimentos, com possível impacto direto em setores importantes. Nesse cenário de atividade econômica fragilizada e sem perspectivas sustentáveis, é esperado que consumidores e empresários se mantenham pessimistas e cautelosos (Pinheiro & Matos, 2022). Senna (2022) afirmou que, anteriormente ao conflito, a economia mundial já se defrontava com um sério problema inflacionário, incluindo a influência direta da “inflação da pandemia”, referindo-se à parcela do processo inflacionário associada à crise sanitária.

O risco geopolítico gerado pela guerra entre a Rússia e a Ucrânia teve implicações significativas nos mercados de ações de vários países, incluindo as próprias nações beligerantes, exacerbando a atual crise global de preços de alimentos que começou em 2021 devido à pandemia de Covid-19 (Mishra, Mishra & Dash, 2023). A recuperação econômica de muitas nações após a pandemia foi interrompida e até revertida devido à guerra – os investidores sofreram perdas imediatas devido à redução nos pontos dos índices de ações, e os efeitos em muitos países variaram de acordo com a proximidade ao campo de batalha e sua situação social, econômica e política (Mishra *et al.*, 2023).

Assim como aconteceu na pandemia da Covid-19, a invasão russa na Ucrânia promoveu reações emocionais dos investidores em relação à incerteza geopolítica, provocando decisões embasadas em ansiedade e medo, o que promoveu reversão de preços no mercado acionário (Zaremba, Cakici, Demir & Long, 2022). Os autores relembram experimentos e pesquisas que evidenciaram que as pessoas não avaliam adequadamente eventos de alto grau de insegurança e imprevisibilidade.

O Índice de Risco Geopolítico (IRG), criado originalmente por Caldara e Iacoviello (2022), reflete a variação de séries temporais no risco geopolítico, estando associado a guerras, terrorismo e tensões entre países, ou seja, eventos que influenciam o curso normal das relações internacionais. O objetivo do IRG é capturar tanto o risco de ocorrência desses eventos quanto aqueles associados aos processos pendentes de escalada. A partir de eventos globais que causam impactos relevantes nos mercados acionários, Arango-Castillo, Orraca e Molina (2023) afirmam que há ampla evidência de que a inflação gerada entre os países está altamente correlacionada; esses autores enfatizam a relevância de fatores globais sobre a inflação doméstica em economias emergentes.

Zaremba *et al.* (2022) afirmam que a frequência percebida de um evento pode ser distorcida por fatores como a cobertura midiática — a exposição a notícias sobre acidentes, crimes violentos, crises etc., aumentam a avaliação subjetiva. A influência de notícias relacionadas a eventos globais sobre as economias e os mercados financeiros instigou a seguinte pergunta de pesquisa para este capítulo: a divulgação de notícias nos primeiros meses da guerra entre Rússia e Ucrânia impactou o mercado acionário, em especificamente os retornos das empresas da B3?

Para responder essa pergunta propôs-se o objetivo de identificar e analisar a relação entre o período inicial do início da guerra na Ucrânia e os retornos das empresas de capital aberto do mercado brasileiro, entre dezembro/2021 e junho/2022. Apesar de o Brasil estar geograficamente distante da zona de guerra, os impactos dos efeitos nocivos sobre a inflação mundial, o câmbio e o comércio internacional podem ter sido expressivos no mercado nacional logo após a invasão. Para alcançar o objetivo proposto, foi formulada a seguinte hipótese de pesquisa:

H1: A guerra na Ucrânia impactou negativamente os retornos das ações das empresas da B3, no período entre janeiro/2022 e julho/2022.

Esta pesquisa justificou-se pelo fato de a guerra causar prejuízos nos sistemas alimentares e nos mercados financeiros de muitos países, especialmente aqueles próximos às nações em conflito (Mishra *et al.*, 2023). É imperativo compreender os impactos da guerra sobre o comportamento das economias globais e dos mercados, permitindo a gestores e governos formularem estratégias e políticas que resguardecam a saúde financeira das empresas e das sociedades.

II.2 Revisão da literatura

II.2.1 Hipótese do mercado eficiente

Markowitz (1952) afirmou que as volatilidades do mercado financeiro ocorrem principalmente conforme informações que lhes são repassadas e representam grandes riscos para os investidores. Fama (1970) considerava que o principal papel do mercado de capitais era atribuir a propriedade do capital social da economia. Para o autor, um mercado ideal seria aquele dentro do qual as empresas poderiam tomar decisões de investimento, e os investidores poderiam escolher entre os títulos que representassem a propriedade da empresa, sob a premissa de os preços dos títulos “refletirem plenamente” toda a informação disponível. Tal mercado

seria chamado de “eficiente”, constituindo a base para a definição da Hipótese do Mercado Eficiente (HME).

Em linhas gerais, a teoria dos mercados eficientes ocupa-se com a possibilidade de os preços das ações refletirem fidedignamente a informação disponível sobre as mesmas. Essa teoria é empírica e tem sido explorada pelo estudo prático de Fama (1970), nas teses de Myron Scholes em 1969, Arnold Moore em 1962, Osborne (1959), Kendall (1953), Mandelbrot (1963), entre outros autores. A literatura empírica relacionada disponível assume que as condições de equilíbrio do mercado podem ser declaradas em termos de rendimentos esperados, constituindo a base dos modelos de mercado eficientes de retorno esperado ou *fair game*³ (Fama, 1970).

Sobre a disponibilidade plena de informações relacionadas ao mercado acionário, Niederhoffer e Osborne (1966) apontaram, em seus estudos, que especialistas em grandes bolsas de valores tinham acesso monopolista a informações sobre ordens limitadas não executadas e as utilizavam para gerar lucros. Esse fato levantou a questão sobre a “criação de mercado” que não implicasse acesso exclusivista à informação, de modo que pessoas de dentro das próprias empresas também tivessem o mesmo acesso privilegiado. Tal situação refletia um aparente paradoxo para a HME, uma vez que as informações disponibilizadas no mercado não correspondiam ao total de informações existentes na prática.

Duas décadas após a definição da HME, revisando seus estudos, Fama (1991) reafirmou a HME com a definição de que os preços dos ativos refletem totalmente todas as informações disponíveis. E reforçou sua veracidade recorrendo ao trabalho de Grossman e Stiglitz (1980) que afirmam que os custos de obtenção dos preços que refletem as informações são sempre zero, não sendo, portanto, obstáculos às inferências sobre a eficiência do mercado. Fama (1991) atestou ainda que a eficiência do mercado em si não é testável diretamente, e sim por meio de modelos de precificação de ativos.

Ao contrário do trabalho realizado em 1970, que se concentrava na previsão de retornos, o novo estudo de Fama (1991) afirmava que os testes para a HME também deveriam considerar o poder de previsão de variáveis como rendimentos de dividendos, taxas de lucro/preço e estrutura de prazos variáveis. Enquanto os trabalhos primordiais se concentraram na previsibilidade de retornos diários, semanais e mensais, os estudos de 1991 examinavam a previsibilidade dos retornos para horizontes de longo prazo. Fama (1991) reconheceu que existiam *insiders* corporativos e agentes individuais que tinham informações privadas sobre

³ No modelo de *fair game*, os retornos anormais dos preços das ações são iguais a zero, uma vez que todas as informações sobre elas estão refletidas em seu preço. Dessa forma, para um grande número de ações, o retorno esperado é igual, em média, ao retorno atual (Fama, 1970).

ações que levavam a retornos anormais, uma vez que não estariam refletidas em seus preços; os trabalhos de Jaffe (1974), Seyhun (1986) e Ippolito (1989) apontam para essa conclusão.

Após dezoito anos da revisão de Eugene Fama sobre a HME, um conceito similar de mercado eficiente foi definido como aquele em que os preços dos títulos, a qualquer momento, refletem rapidamente todas as informações relevantes disponíveis. Dentro desse conceito, os preços refletem os efeitos de eventos passados e todas as expectativas de eventos futuros.

Os conceitos de Fama (1970) e de outros pesquisadores definem-se basicamente três formas de eficiência do mercado, a depender da natureza das informações de interesse: (i) forma fraca (*weak form*) – contém informações relativas apenas ao preço histórico ou sequências de retorno das ações; (ii) forma semiforte (*semi-strong form*) – supõe que o preço da ação reflete totalmente todas as informações obviamente disponíveis publicamente; (iii) forma forte (*strong form*) – preocupa-se se os investidores (individuais ou grupos) têm acesso monopolista a qualquer informação relevante para a formação de preços das ações, além de todas as informações obviamente disponíveis publicamente.

O estudo de Brown (2011) transcende os de Fama ao fazer uma releitura de seus artigos e considerando o contexto de pós-crise de 2008. Brown (2011) critica a HME, afirmando que, ao se analisar o preço de equilíbrio das ações, percebe-se que sua formação reflete o consenso de todos os investidores. O autor relatou que outros autores também questionavam a HME sob a premissa de que, se os mercados são eficientes e as informações disponíveis, pequenos investidores poderiam entender esse conceito como um modo de funcionamento padrão dos mercados, o que, obviamente, não é realista.

Contrariando as ideias de Fama, a teoria das finanças de Shiller (2013) descreve a HME como um grande erro da teoria econômica, pois acredita que a hipótese implica muito além da relação entre informação e valor da ação. Shiller (2013) argumenta que os movimentos regulares nos mercados refletem uma sabedoria que transcende o entendimento dos melhores profissionais, sendo inútil questionar os preços. Os investidores não são os autômatos racionais da HME, e sim estão sujeitos a influências psicológicas que resultam em otimismo ou pessimismo excessivos. O autor afirma ainda que a HME pode criar um efeito de “comboio”, no qual os investidores aglomeram-se em torno de ativos na crença de que seus valores cresçam, ou criam maior volatilidade para os preços do que se fossem estritamente racionais. Se ele estiver correto, é muito provável que o investimento seja desperdiçado em modismos e tendências. Esse debate entre os apoiadores da HME e os behavioristas que acompanham o

pensamento de Shiller não está resolvido, apesar do grande volume de pesquisas realizadas sobre o tema (Costa, 2017).

Chernomas e Hudson (2017) também aprofundaram as análises da HME propondo que, ao se tratar de mercados “eficientes”, deve-se definir inicialmente o que se entende por eficiência. Os autores afirmam que o que Fama queria dizer por “eficiente” pode ser considerado “exato”, ou seja, eficiência seria uma definição bastante restrita de: “um mercado em que os preços sempre ‘refletem plenamente’ a informação disponível” (Fama, 1970, p. 383). Parte do problema em testar essa hipótese é definir o que significa “informação”. Os autores relatam ainda que Fama também pesquisou sobre “estudos de eventos” os quais consistiam em testes de como os preços dos ativos respondiam a novas informações (eventos). Aparentemente, a reação a eventos ocorre tão frequentemente quanto a reação excessiva e a continuidade de retornos anormais (Fama, 1998; Malkiel, 2003). O resultado é que novas informações são rapidamente incorporadas aos preços dos ativos, e os investidores não cometem quaisquer erros sistemáticos e previsíveis ao utilizá-las.

Pode-se dizer que a HME leva a duas implicações importantes. Se a nova informação é rapidamente adotada pelos investidores no preço do ativo, seus preços futuros são essencialmente aleatórios pois refletirão apenas eventos imprevisíveis. Como não existem padrões futuros previsíveis para os preços, é impossível “vencer o mercado”, mesmo para o investidor profissional; a conclusão disso é que pagar por fundos geridos por analistas é um desperdício de dinheiro. A segunda implicação é que, se os mercados forem eficientes e os preços refletirem com precisão a informação disponível, pode-se descartar a possibilidade de o investidor ser conduzido sistematicamente a preços incorretos dos ativos, devido ao excesso de confiança (Chernomas, & Hudson, 2017).

II.2.2 Reações do mercado acionário à guerra Russo-Ucraniana

A busca por investimentos em “portos seguros” geralmente é desencadeada por eventos repentinos e imprevistos (Caballero & Krishnamurthy, 2008), como uma crise financeira ou uma guerra. Baur e Lucey (2010, p. 219) definem “porto seguro” como “um ativo que não está correlacionado ou está negativamente correlacionado com outro ativo ou portfólio em tempos de estresse ou turbulência do mercado”; dessa forma, os investidores são compensados por quaisquer perdas.

Em 24 de fevereiro de 2022, a Rússia deu início ao conflito militar com a Ucrânia, causando uma enorme perda de vidas e uma crise de refugiados, com o crescimento mais rápido

na Europa desde a Segunda Guerra Mundial (Yousaf, Patel, & Yarovaya, 2022). Segundo esses autores, a guerra impactou as relações entre importações e exportações da Rússia e da Ucrânia, e a lucratividade futura das suas empresas, conduzindo a variações nos preços das ações, assim como de outros países, afetados pelas relações comerciais, promovendo efeitos negativos na produção, lucratividade, fluxos de caixa esperados e preços das ações.

Desde a invasão russa na Ucrânia o rublo russo caiu para um nível recorde, e o mercado acionário russo despencou cerca de 33%. Especificamente nesse conflito, os preços do petróleo bruto subiram 8%, com o Brent, atingindo US\$ 105 imediatamente após o ataque, o nível mais alto desde 2014 (Mohamad, 2022). O autor lembra o conceito do fenômeno chamado *flight-to-safety*, definido como uma situação na qual os investidores temem que os ativos nos quais investiram possam repentinamente, apresentar riscos maiores que o habitual, levando-os a 36ando-os em troca de investimentos de menor risco, ou mais seguros; assim, os investidores se esforçam para obter riscos menores, o que pode resultar em lucros menores (Mohamad, 2022).

Adekoya, Oliyide, Yaya e Al-Faryan (2022) identificaram uma maior conexão entre o preço do petróleo e outros mercados financeiros durante o conflito Rússia-Ucrânia. Tosun e Eshraghi (2022) compararam o impacto do conflito sobre as empresas que abandonaram a região do conflito e aquelas que permaneceram, constatando que os portfólios das remanescentes na Rússia tiveram desempenho inferior ao das que evadiram. No estudo de Yousaf *et al.* (2022), investigou-se o impacto da eclosão do conflito sobre o G20 e em outros mercados acionários, por meio de análise de estudo de evento, considerando o dia do evento, a janela pré-evento e os dias pós-evento. Os resultados empíricos dos retornos anormais revelaram que o anúncio da invasão russa teve um impacto significativo e negativo na maioria desses mercados, com o maior impacto na Rússia, e os mercados acionários mundiais reagiram negativamente no dia do evento e nos dias seguintes.

Zaremba *et al.* (2022) investigaram a forma como as notícias sobre incerteza geopolítica afetavam o preço dos ativos em mercados emergentes, usando o Índice de Risco Geopolítico (IRG) para examinar se as mudanças na percepção do risco de guerras e ataques terroristas afetavam a precificação de títulos em mercados emergentes globais. O estudo confirmou que os investidores reagem de forma exagerada às notícias geopolíticas e julgam erroneamente os riscos de conflitos militares.

As teorias financeiras clássicas, a exemplo da HME, pressupõem que os investidores do mercado de ações usam todas as informações disponíveis para avaliar apropriadamente as

probabilidades e efeitos de diferentes eventos. No entanto, Zaremba *et al.* (2022) relatam evidências de comportamentos que muitas vezes violam essa premissa, nas quais agentes de mercado recorrem à heurística ao estimar riscos e probabilidades, tendendo a ponderar excessivamente certos tipos de informações.

A mudança na percepção de risco baseada em notícias afeta a precificação de ativos e, conseqüentemente, os retornos de ações, levando os investidores a transferirem seu capital de mercados mais arriscados para outros mais seguros. Isso provoca um *undershooting* (preço abaixo) em relação ao valor fundamental da ação. Zaremba *et al.* (2022) estudaram dados de 19 grandes mercados emergentes cobertos pelos índices IRG, envolvendo países considerados vulneráveis ao risco geopolítico no período entre 1990 e 2020. O estudo examinou o papel das mudanças no risco geopolítico na previsão de retornos nos mercados emergentes e demonstrou que o impacto do risco geopolítico independia da precificação de ativos.

Pitigala (2022) corroborou esses impactos da guerra na Ucrânia sobre as economias mundiais, relatando interrupções generalizadas que o conflito causou no comércio e nos investimentos, afetando países importadores de alimentos e o fornecimento de energia aos consumidores em todo o mundo, sendo os mais pobres mais vulneráveis a essas interrupções. Por outro lado, o autor contrapôs que exportadores líquidos de produtos agrícolas, como Turquia, Brasil e Índia, e de combustíveis fósseis, como Nigéria e países do Oriente Médio, apresentaram um aumento em suas exportações, atenuando os efeitos adversos da guerra. Pitigala (2022) observou ainda que as ondas de choque econômico moveram-se por meio de cinco canais: mercados de *commodities*, redes de logística, cadeias de suprimentos, investimento estrangeiro direto e setores como o turismo.

Para Pitigala (2022), a guerra ocorreu em um momento difícil para os mercados emergentes, pois a recuperação da recessão induzida pela pandemia já havia desacelerado com o surgimento de novas variantes do coronavírus e com os governos controlando os gastos. O aumento da inflação levou muitos bancos de mercados emergentes a aumentar suas taxas de juros que, associado às interrupções no comércio mundial e nos investimentos, reduziu o crescimento nos países em desenvolvimento e aumentou as pressões sobre os preços (Pitigala, 2022).

Para Yu e Chen (2023), o impacto do conflito na Ucrânia sobre os mercados financeiros foi evidente: o petróleo bruto atingiu seus níveis mais altos desde 2014, enquanto os investidores venderam inúmeras ações em um curto período depois que as tropas russas foram mobilizadas na Ucrânia. O estudo examinou o impacto da guerra nos mercados de ações para

determinar se os setores relacionados às exportações russas — especificamente petróleo bruto Brent, ouro e níquel — foram afetados. O resultado mostrou algum grau de correlação entre a dependência das exportações russas e o impacto do conflito nos mercados de ações. Ademais, a inflação induzida pela guerra teve efeito prolongado no mercado de ações (Yu & Chen, 2023). Como contraponto, os autores declaram que muitos estudos mostram que a maioria dos impactos foi de curta duração.

II.3 Metodologia

II.3.1 Estudo de eventos

O trabalho de Brown e Warner (1985) afirma que o uso de dados diários de ações em estudos de eventos envolve quatro problemas importantes: (i) não normalidade dos retornos e retornos em excesso; (ii) viés nas estimativas de mínimos quadrados ordinários (MQO) dos parâmetros do modelo de mercado na presença de negociações não síncronas; (iii) problemas de estimativa de variância dos retornos, que aumenta nos dias imediatamente próximos aos eventos (exemplo: como anúncios de lucros); (iv) a base para a inferência em estudos de eventos, que apresenta uma limitação que reside no fato de as variáveis não poderem afetar simultaneamente a média e variância estimadas.

Antes de prosseguir com a descrição de alguns trabalhos da literatura que aplicaram a metodologia de estudo de eventos, é importante defini-la. Estudos de eventos investigam o efeito de um anúncio de uma empresa ou de um evento, sistêmico ou não, sobre o preço de uma ação. Esse método verifica se os mercados são eficientes, ou seja, a validade da Hipótese do Mercado Eficiente (HME) em relação aos preços das ações refletirem plenamente toda a informação disponível. Conforme descrito anteriormente, a HME apresenta-se sob três formas: (i) fraca: toda a informação contida nos preços históricos se reflete plenamente nos preços correntes; (ii) semiforte: a informação disponível está plenamente refletida nos preços correntes das ações; e (iii) forte: toda a informação se reflete plenamente nos preços dos ativos (Barbosa Filho, 2023).

Adotando-se a forma semiforte, Barbosa Filho (2023) afirma que o estudo de eventos permite verificar o quão rapidamente a informação divulgada incorpora-se ao preço de uma ação. O autor relata que, na literatura, o estudo de eventos é utilizado para determinar o quão rápido a ação reage a uma informação (ou notícia), bem como a direção de mudança de preço e o impacto provável ocorrido. Para sua aplicação, usualmente faz-se a separação da análise em dois grupos: controle e tratamento, para comparar os efeitos.

O grupo de controle não é submetido a um experimento, enquanto o grupo de tratamento recebe a intervenção. O design de um estudo de eventos fundamenta-se na ideia de que algo muda ao longo do

tempo, de forma que, após o evento, procede-se ao tratamento dos dados para, então, comparar os dados anteriores ao evento com aqueles posteriores, e obter o efeito da análise aplicada (Barbosa Filho, 2023). O autor afirma que para certificar que sejam removidos todos os efeitos do tempo sobre o resultado, exceto por aquele que se deseja investigar, é necessário realizar uma previsão do contrafactual, ou seja, do evento que não aconteceu, mas poderia ter acontecido.

Dessa forma, considerando que o comportamento dos dados antes de um evento específico iria se manter sem uma análise sob a influência do evento, podem-se usar esses dados para prever uma mudança esperada sem essa análise, para então ver como o resultado real se desvia dessa previsão. A extensão da discrepância entre o antes e depois da análise do evento é o seu efeito (Barbosa Filho, 2023). Conforme o autor, a análise pode ser realizada de três modos: comparar os dados antes e após o evento, sem controle algum; prever os valores dos dados após o evento a partir dos dados antes dele; ou comparar os dados pós-evento com algum *benchmark*.

A literatura apresenta vários estudos de eventos para avaliar o impacto de um evento específico sobre os preços de mercados acionários globais, a partir dos eventos da pandemia da Covid-19 e da guerra na Ucrânia. Estudos como o de Bannigidadmath, Narayan, Phan e Gong (2022) determinaram empiricamente o impacto das respostas de políticas (pacotes de estímulo monetário, regulamentações de *lockdown* e proibições de viagens) sobre os retornos anormais de 25 mercados acionários globais à época da pandemia. Os resultados indicaram que, em dois terços dos países, essas respostas influenciaram o mercado acionário, chegando-se à conclusão de que o efeito negativo das políticas superou os positivos sobre os retornos das ações.

Um outro exemplo de aplicação da metodologia de eventos é o trabalho de Boubaker, Goodell, Pandey e Kumari (2022) no qual autores analisaram variações transversais nos preços das ações dos mercados de ações europeu, asiático e pan-americano logo após o evento da guerra entre Rússia e Ucrânia, para determinar se algumas variáveis de cada país impulsionaram o desempenho desses mercados. A “janela” do evento considerou cinco dias antes e cinco dias após o dia do ataque da Rússia (24/02/2022), para evitar outros efeitos temporais sobre os preços das ações. Como “variável de controle”, utilizaram os valores das ações estimados até 145 dias anteriores a 24/02/2022, e os resultados apontaram que a guerra afetou negativamente os retornos no momento analisado.

Outra pesquisa que utilizou estudo de eventos relacionados ao conflito na Ucrânia foi o de Ahmed, Hasan e Kamal (2022), que analisou os preços de ações de 584 empresas europeias. Dessa vez, o “evento” foi identificado como sendo em 21/02/2022, data em que a Rússia reconheceu as regiões de Donetsk e Luhansk da Ucrânia como os chamados estados independentes. Os retornos anormais negativos estatisticamente significativos e os retornos

anormais acumulados foram registrados em uma janela de evento de três 3 dias antes e três dias depois do evento. Em geral, as empresas registraram retornos anormais negativos significativos para o setor de energia, sendo que empresas de pequeno e médio porte foram mais afetadas negativamente do que grandes empresas.

Um último exemplo é a pesquisa de Pretorius (2023) que avaliou os comportamentos dos retornos das ações de onze índices de mercados em continentes diversos, entre eles o brasileiro. Em relação à pandemia da Covid-19, foram consideradas duas datas ou eventos potenciais: a primeira foi 11/03/2020, quando a Organização Mundial da Saúde (OMS) declarou a Covid-19 como uma pandemia global; e a segunda foi antes dessa declaração, quando o mundo já havia tomado conhecimento do vírus e os mercados começavam a reagir.

Para a invasão da Ucrânia, o trabalho de Pretorius (2023) considerou a data da invasão Russa em 24/02/2022 como data do evento. A análise dos dados começa com uma representação gráfica dos onze índices do mercado de ações padronizados e definidos como 100 no dia anterior ao evento. Isso forneceu uma indicação inicial dos movimentos dos índices entre si e ao longo do tempo. Para comparar os movimentos observados, os retornos foram estimados para intervalos de 1, 2 e 3 semanas, e de 30 dias após o evento. Foram, então, realizados testes de igualdade para testar a hipótese nula de que os retornos médios e a volatilidade dos retornos diários calculados antes e depois do evento são iguais.

Os resultados da pesquisa comparando os retornos médios diários do mercado de ações na janela de 30 dias e a variância dos 30 retornos diários antes e depois do evento mostraram que todos os mercados obtiveram retornos médios positivos nos 30 dias anteriores e retornos médios negativos 30 dias posteriores ao evento. Todos os mercados de ações apresentaram ainda um aumento da volatilidade após o evento, evidenciado pelo maior desvio-padrão dos retornos (Pretorius, 2023).

II.3.2 Delimitação da pesquisa, população e amostra

Delimitação da pesquisa

Esta pesquisa teve abordagem descritiva e quantitativa. Aqui também foram analisados dados secundários numéricos, relacionados à volatilidade dos retornos das ações das empresas da B3 no início da guerra entre a Rússia e Ucrânia. A análise quantitativa se deu considerando o período entre 27/12/2021 e 24/07/2022, ou seja, 60, 15 e 5 dias anteriores ao início da guerra, orientado pelos estudos de Boubaker *et al.* (2022) e Ahmed *et al.* (2022); e 5, 15 e 150 dias posteriores à invasão como variável de controle, inspirado nos estudos de Boubaker *et al.* (2022)

e Pretorius (2023), para verificar os comportamento dos retornos decorridos após os primeiros meses da invasão.

Foi definido este prazo de 150 dias após a invasão russa atentando-se para o início da propaganda eleitoral brasileira, afim de evitar eventuais vieses de influência política no mercado acionário. Esse prazo também é justificado pela percepção de uma maior duração de seus efeitos “colaterais” (inflação, câmbio etc.) sobre o mercado.

População e amostra

O desenvolvimento desta pesquisa foi embasado nos dados dos retornos diários das ações das empresas listadas na B3, coletados no site YahooFinance. Foram excluídas empresas pertencentes ao setor de serviços financeiros, por se tratarem de organizações cuja atividade-fim é a regulação/administração do capital financeiro, e portanto, diferindo dos demais setores econômicos em relação à legislação e aos dados publicados.

II.3.3 Coleta dos dados

As empresas da amostra foram categorizadas segundo o setor de atividade, sendo constituída por 222 empresas categorizadas nos 10 setores de atividade conforme o *TRBC Economic Sector Name* (Tabela II.1).

Tabela II.1 – Quantidade de Empresas da B3 Classificadas por Setor

Setor conforme <i>TRBC</i>	Guerra Rússia-Ucrânia
Consumo Cíclico (<i>Consumer Cyclical</i> s)	50
Industrial (<i>Industrials</i>)	30
Demais Serviços (<i>Utilities</i>)	35
Consumo Não-Cíclico (<i>Consumer Non-Cyclical</i> s)	25
Imobiliário (<i>Real Estate</i>)	26
Materiais Básicos (<i>Basic Materials</i>)	26
Tecnologia (<i>Technology</i>)	9
Saúde (<i>Healthcare</i>)	9
Energia (<i>Energy</i>)	8
Serviços Acadêmicos e Educacionais (<i>Academic & Educational Services</i>)	4

Fonte: Elaborado pela autora, a partir das informações do banco de dados Refinitiv.

Nota: A fim de evitar a influência de empresas individuais sobre o resultado da média geral de um setor específico, e garantir que todas possuem dados publicados no Refinitiv, relativos aos períodos propostos por esta pesquisa, serão selecionadas as empresas com situação CVM ativa.

Os dados coletados dos retornos das ações foram aqueles classificados como “ajustados”, considerando alterações corporativas como *splits* e o pagamento de dividendos. Isso gerou resultados mais precisos e permitiu identificar tendências e padrões de mercado, e aumentou a confiabilidade das análises de volatilidade.

II.3.4 Método de análise dos dados

A metodologia de análise usada neste estudo foi suportada pelo *software* de tratamento estatístico R. Os dados dos retornos das ações foram buscados diretamente dentro do R, no site do YahooFinance, por meio de *scripts* desenvolvidos para tal. O teste da hipótese de pesquisa H_1 foi realizado utilizando a metodologia de estudo de eventos. O percurso analítico fundamentou-se nos trabalhos de Brown e Warner (1985), Ahmed *et al.* (2022) e Pretorius (2023).

O dia do evento da guerra entre Rússia e Ucrânia ocorreu em 24/02/2022. O passo seguinte foi definir o período de estudo do evento. Para isso, a quantidade de dias analisados foi distribuída em três cenários, antes e após o dia do conflito: o cenário 3 considerou 210 dias, o cenário 2 envolveu 30 dias, e o cenário 1 abordou 10 dias, sendo -60 dias, -15 dias e -5 dias antes do evento, e +5, +15, +150 e dias após o evento. Essas quantidades de intencionaram refletir as primeiras respostas das ações da B3, sendo o cenário 1 denominado “período de choque inicial”; o cenário 2 (± 15 dias) refletiu as respostas quando os investidores ainda se encontravam inseguros e incertos, e portanto foi denominado “período de expectativa”; e finalmente o cenário 3 denominado período residual (- 60 dias e + 150 dias), quando a ocorrência do conflito ainda não era certa e quando os primeiros impactos sobre a economia brasileira (inflação, câmbio, comércio internacional) já demonstravam certa “acomodação” ao evento (Figura II.1).




Figura II.1 – Cenários para análise do evento da guerra Russo-Ucraniana sobre os retornos das ações da B3.
Fonte: Elaborado pela autora.

II.4 Análise e discussão dos resultados

Foram realizados inicialmente os tratamentos e modelagens das séries temporais dos retornos das ações para todas as empresas da amostra, sem segmentação setorial. Posteriormente, foram feitas análises correspondentes a cada setor, para fins de comparação dos resultados encontrados. Como os processos de tratamento e modelagem foram semelhantes para cada série temporal de todos os setores, os procedimentos foram descritos detalhadamente para

a série temporal total (sem segmentação setorial), enquanto, para os setores, foram descritos os resultados mais relevantes, a fim de evitar descrições repetitivas dos procedimentos.

II.4.1 Retornos na guerra Russo-Ucraniana (sem segmentação setorial)

Os retornos relativos ao período inicial da GR-U foram coletados via Rstudio, do portal YahooFinance e transformados em uma série temporal. A série, avaliada diariamente entre 27/12/2021 e 20/07/2022 (excluídos os finais de semana), ficou constituída por 222 empresas e 144 observações (retornos das ações) para cada empresa, reunindo um total de 32.400 informações. A Figura II.2 apresenta os gráficos da série temporal original para os retornos durante o período analisado para a guerra Russo-Ucraniana (GR-U), sua regressão linear e seu histograma.




Figura II.2^a – Série temporal original para GR-U entre 27/12/2021 e 20/07/2022 (as setas indicam a região temporal).




Figura II.2b – Regressão linear ST GR-U.




Figura II.2c – Histograma ST GR-U.

Figura II.2 – Série temporal para a GR-U original, regressão linear e histograma.
Fonte: dados de pesquisa.

A Figura II.2 mostra o perfil da série temporal sugerindo não estacionariedade, sazonalidade e efeitos aleatórios (ou resíduos), porém sem tendência de crescimento ou decrescimento. O histograma mostra uma distribuição não normal, com os retornos apresentando frequências maiores no início do período avaliado; essa distribuição assimétrica indicou que os retornos não estavam distribuídos uniformemente em torno da média, com poucos retornos altos à direita do pico da curva. Este não coincidiu com o evento da guerra, sugerindo ausência de impacto relevante do conflito sobre os retornos da B3.

A análise da série temporal apontou que, nos dias especificados para avaliação dos retornos antes e após o evento, foram observados dois comportamentos anormais com volatilidades relevantes: o maior pico aparece entre 5 e 15 dias anteriormente à invasão, sendo um comportamento isolado, uma vez que, no restante do período (cinco meses após o evento), as variações da série permaneceram constantes, apenas com um outro pico menor no último mês analisado. Isso sugeriu ausência de impacto relevante do evento da guerra sobre os retornos da B3, uma vez que impactos relevantes seriam esperados no dia da invasão e nos dias posteriores.

Como a série original tinha alguns valores ausentes (“NA”), aplicou-se winsorização a 5% para retirada dos mesmos. A série tratada ficou conforme a Figura II.3. No gráfico da winsorização, as oscilações que ocorreram no entorno do dia do evento não se mostraram particularmente diferenciadas do restante do período de análise, corroborando a ausência de efeitos importantes da guerra sobre o mercado acionário brasileiro nos primeiros cinco meses desde a invasão.




Figura II.3 – Série temporal para GR-U winsorizada a 5% à esquerda e sua regressão linear à direita.
Fonte: dados de pesquisa.

Para visualizar as componentes de sazonalidade e efeitos aleatórios, a série winsorizada foi decomposta pelo modelo aditivo e apresentada na Figura II.4. Nesta ficam evidentes as componentes de sazonalidade e efeitos aleatórios da série winsorizada, porém sem tendência, apesar de se observar alguns picos mais altos e largos na janela do evento. Isso pode indicar maior duração da volatilidade dos retornos nesse momento, porém na mesma intensidade de variação que o restante da série. Nota-se que a componente residual (efeitos aleatórios) apresenta vários *clusters* de volatilidade ao longo do período analisado, acompanhando a tendência em relação às variações nos retornos.

Seguindo o método de estudo de eventos aplicado no estudo de Pretorius (2023), foi feita análise de regressão que estimou os retornos normais da série temporal total para a guerra (sem segmentação setorial) antes e após o evento. Considerando-se as premissas (i) apenas um evento específico levou a diferenças nos preços e retornos das ações; e (ii) não houve efeito do tempo, os resultados antes e depois puderam ser comparados. Essa abordagem é aplicável se for considerado um tempo relativamente curto de análise (Huntington-Klein, 2021), que foi o caso do presente capítulo.

A Tabela II.2 mostra os retornos médios e as variâncias dos mesmos, da B3, nos períodos de 60, 15 e 5 dias antes do início do conflito e 5, 15 e 150 dias após esse evento. Os resultados da Tabela II.2 não indicaram diferenças expressivas entre os retornos médios das ações da B3 nos intervalos de tempo anteriores e posteriores ao evento da guerra, sendo diferença encontrada de 0,73% entre os períodos anterior e posterior ao conflito. O desvio-padrão e a variância para esses retornos apresentaram diferenças respectivamente de -4,9% e de -9,7%. Ademais, todos os retornos médios foram positivos ao longo do período analisado.




Figura II.4 – Decomposição da série temporal para GR-U.
Fonte: dados de pesquisa.

Tabela II.2 – Retornos médios e suas variâncias, antes e após o evento em 24/02/2022

	60 dias antes	15 dias antes	5 dias antes	5 dias após	15 dias após	150 dias após
Retorno médio	64,38	63,85	65,03	64,53	62,85	64,47
Desvio-Padrão	502,79	495,42	518,80	518,47	506,36	569,44
Variância	252.797,32	245.440,25	269.150,69	268.815,66	256.396,64	324.263,74

Fonte: dados de pesquisa.

Para avaliar se houve diferenças estatisticamente significantes entre os retornos médios antes e após a invasão russa, foram utilizados o teste t de Student (ou teste t) e teste t de Satterwaithe-Welch (ou teste t de Welch), conforme feito no estudo de Pretorius (2023). Para as variâncias, foram aplicados os testes F de Fischer (ou de igualdade), Siegel-Tukey, Bartlett e Brown-Forsythe a fim de determinar se o valor médio anterior é igual ao valor médio posterior ao conflito (Tabela II. 3).

Tabela II.3 – Testes de diferenças entre retornos médios e suas variâncias antes e após a GR-U

Testes dos retornos		Testes das variâncias			
t de Student	t de Welch	Siegel-Tukey	F de Fischer	Brown-Forsythe	Bartlett (K^2)
0.017	0,017	355197(a); 397497(d)*	0,90	1,8**	1,7

Fonte: dados de pesquisa.

Notas: 1: p-valor: *** 0,001; ** 0,01; * 0,05.

2: (a) = antes do evento; (d) depois do evento.

O teste t (considera variâncias equivalentes entre os dois grupos) determina se há uma diferença significativa entre as médias de dois grupos independentes, ou seja, não correlacionados. Para os retornos antes e após a guerra, o teste t de 0,017 foi baixo, e o p-valor de 0,98 levou ao aceite da hipótese nula, não havendo diferença significativa entre os retornos médios. O p-valor inferior ao nível de significância (aqui considerado 0,05) leva à rejeição da hipótese nula, implicando uma diferença significativa entre as médias dos retornos antes e após o dia da invasão na Ucrânia, corroborando os resultados da Tabela II.2.

O resultado do teste t de Welch (considera variâncias diferentes entre os dois grupos – heterocedasticidade) foi 0,017 (próximo de zero), indicando que a diferença entre as médias antes e após a guerra foram próximas. O p-valor foi 0,98 confirmando que não houve diferença significativa entre as médias antes e após o evento (não se rejeitou a hipótese nula), com 95% de confiança. Esse resultado também levou à conclusão de que a guerra não impactou os retornos médios das ações da B3.

O teste de Siegel-Tukey é um teste não paramétrico utilizado para comparar a dispersão de duas amostras independentes, que foi usado nesta pesquisa para comparar as variabilidades das variâncias dos retornos médios, assumindo que estes não estão autocorrelacionados. Os resultados do teste mostraram que as variâncias após o evento tiveram maior dispersão que aquelas anteriores a ele, com p-valor de 0,044, indicando que existe uma diferença significativa entre as variâncias dos retornos médios antes e após o conflito. Tal resultado sugeriu que a invasão teve um impacto na volatilidade dos retornos das ações, ou seja, o modo como os retornos variaram mudou após 24/02/2022.

A maior variância após essa data sugeriu que os retornos das ações ficaram mais voláteis, sugerindo um aumento na incerteza ou risco associado em função do conflito. Tais mudanças na volatilidade podem refletir alterações no sentimento do mercado, introduzindo maior incerteza e mudanças na percepção de risco pelos investidores, afetando suas decisões. Mesmo que os retornos médios não tenham se alterado, a mudança na sua variância foi importante, pois indicou uma alta volatilidade e, portanto, risco associado ao investimento.

O teste F de Fischer de variâncias comparou as mesmas antes e após o evento, verificando que não foram significativamente diferentes, uma vez que o p-valor foi 0,18, com um nível de confiança de 95%. Este resultado contraria aquele de Siegel-Tukey; assim, foram feitos outros dois testes diversos sobre as variâncias, para obter uma conclusão mais precisa sobre seu comportamento nos primeiros meses da invasão russa na Ucrânia.

O teste de Brown-Forsythe avaliou a igualdade das variâncias antes e após a invasão, supondo homocedasticidade dos valores quando estes não seguem uma distribuição normal; com p-valor significativo (0,0015), este teste corroborou o teste F de Fischer das variâncias. Por fim, o teste de Bartlett (chamado de k-quadrado de Bartlett), que também avaliou a discrepância das variâncias dos retornos médios, apresentou um valor de 1,7 com p-valor de 0,19. O resultado não significativo implicou homogeneidade das variâncias antes e após 24/02/2022, corroborando os resultados dos testes F e de Brown-Forsythe.

Nesse sentido, concluiu-se que tanto os retornos médios das ações da B3 quanto suas volatilidades no período entre 60 dias antes do início da guerra entre Rússia e Ucrânia até 150 dias depois não foram significativamente impactados, e os retornos mantiveram-se positivos. Este resultado contradisse a hipótese proposta para este capítulo, H_4 , de que a guerra na Ucrânia impactou negativamente os retornos das ações das empresas da B3, no período entre dezembro/2021 e julho/2022. E confirmou a hipótese nula, $H_{0(4)}$, de que o conflito não teve impacto (positivo ou negativo) sobre os retornos das ações das empresas (em conjunto) da B3, no período analisado.

II.4.2 Retornos na guerra Russo-Ucraniana (com segmentação setorial)

A série de retornos da B3 analisada na subseção II.4.1 foi segmentada por setor de atividade, e os números de observações por setor foram dispostos na Tabela II.4. Os retornos relativos a cada setor geraram dez séries temporais com diferentes dimensões, considerando o mesmo período de aquisição dos dados da série “total”.


Tabela II.4 – Setores de Atividades no Período Inicial da GR-U

Setor	Empresas	Observações
Consumo Cíclico	50	7.200
Industrial	30	4.608
Demais Serviços	35	5.184
Consumo Não Cíclico	25	3.600
Imobiliário	26	3.744
Materiais Básicos	26	3.744
Tecnologia	9	1.296
Saúde	9	1.296
Energia	8	1.152
Serviços Acadêmicos e Educacionais	4	576


Fonte: dados de pesquisa.

A Figura II.5 apresenta os gráficos das séries temporais originais dos retornos e seus histogramas de cada setor de atividade da B3, entre 27/12/2021 e 20/07/2022.


Consumo Cíclico




Industrial





Demais Serviços





Consumo Não Cíclico





Imobiliário





Materiais Básicos



Tecnologia



Saúde






Figura II.5 – Séries temporais e histogramas originais dos retornos setoriais, no início da GR-U.
 Fonte: dados de pesquisa. (as setas indicam a região temporal)

A Figura II.5 mostra o perfil das séries de retornos de cada setor, na qual se observou que todas apresentaram características de não estacionariedade, de sazonalidade e de efeitos aleatórios, porém sem tendência de crescimento ou decrescimento. O histograma do consumo cíclico mostrou uma distribuição não normal dos retornos, com maiores frequências e volatilidades em janeiro/2022, seguidas de frequências bem menores no final de fevereiro e ao longo de julho de 2022, porém com valores superiores dos retornos.

Na série do setor de consumo cíclico, houve uma volatilidade anormal dos retornos nos primeiros dias após o início da guerra e um segundo pico menor de volatilidade após aproximadamente 4 meses, o que poderia indicar um efeito do conflito sobre o setor. Algumas possibilidades de impacto seriam as consequências das sanções econômicas impostas à Rússia que afetaram os preços dos combustíveis e energia elétrica no Brasil, levando ao aumento dos custos de produção e transporte, e reduzindo o consumo de bens de consumo cíclico, que são mais sensíveis ao preço (Pinheiro, & Matos, 2022; Yu e Chen, 2023).

O aumento dos preços do combustível e dos alimentos elevou a inflação no Brasil (Pitigala, 2022), o que gerou aumento da taxa de juros pelo BACEN. Isso também afetou o setor de consumo cíclico que depende fortemente de compras a crédito. Ademais, a desvalorização do Real em relação ao Dólar americano tornou mais cara a importação de matéria-prima para produção nacional de produtos de consumo cíclico.

Os histogramas da indústria e do consumo não cíclico mostraram distribuições mais equânimes entre as frequências dos retornos, porém sem normalidade. No caso da indústria, houve maior concentração de retornos mais baixos entre o final de dezembro/2021 e durante janeiro/2022. Seus valores aumentam a partir de fevereiro/2022, porém com frequência menor, e, a partir de abril/2022, ficaram evidentes alguns picos de alta frequência de retornos maiores até o mês de maio, após o qual se iniciou uma queda mais acentuada da frequência de altos retornos. Esses resultados apontam para uma volatilidade mais expressiva do setor no início da GR-U. Para o consumo não cíclico, as volatilidades foram maiores no final de fevereiro e em meados de maio de 2022.

O comportamento das séries temporais original dos setores industrial e de consumo não cíclico reflete as volatilidades dos seus retornos, com alterações mais acentuadas após 24/02/2022 no caso da indústria, e antes e após essa data para o consumo não cíclico. Para a indústria é um indicativo de que a guerra na Ucrânia pode ter afetado o setor de forma relevante. Para testar tal hipótese, foram feitas análises de estatísticas descritivas e testes estatísticos sobre as diferenças entre os retornos e suas variâncias antes e após o evento da invasão, descritos nas Tabelas II.5 e II.6.

A série de retornos do setor de demais serviços apresentou perfil similar àquele do consumo cíclico, porém com volatilidades mais intensas antes e após a invasão, assemelhando-se ao setor energético. Ademais, os retornos do setor de demais serviços expressaram os maiores valores na 1ª semana após 24/02/2022, após a qual houve volatilidades com duração maior que aquelas da indústria, porém com menor intensidade. Os retornos dos setores de energia e de serviços acadêmicos e educacionais apresentaram valores mais elevados entre janeiro e meados de maio de 2022, não destacando valores diferenciados no entorno de 24/02/2024. O histograma do setor de demais serviços mostra que a maioria dos retornos ficou entre valores mínimos e médios em relação a todos os retornos obtidos, sendo a maior concentração no 1º terço dos valores, que também sofreram mais volatilidades no período.

O setor imobiliário não apresentou retornos anormais no entorno da data da invasão na Ucrânia, tendo dois picos consecutivos de volatilidades expressivas, no final de janeiro até

início de fevereiro de 2022, e outro menos intenso, no início de julho/2022. O histograma dessa série mostrou uma alta frequência de retornos baixos no final de dezembro/2021, e, ao longo do período analisado, praticamente não foram observados retornos mais elevados. Esses resultados sugeriram ausência de impacto da guerra sobre os retornos do setor.


Os retornos dos setores de materiais básicos, tecnologia e saúde tiveram comportamentos similares, sem nenhum pico relevante no entorno de 24/02/2022. Para a tecnologia, as volatilidades foram mais amenas entre meados de maio e início do junho de 2022, quando sofreram variações mais intensas, enquanto, para a saúde, os retornos anormais apresentaram-se entre março até meados de abril de 2022. O setor de materiais básicos, por sua vez, apresentou retornos anormais mais expressivos a partir de meados de junho/2022, não sendo identificados (graficamente) impactos do início da guerra sobre os retornos desses três setores. O histograma dos materiais básicos mostrou maior concentração de valores mais baixos durante o período de análise e, comparativamente, poucos valores elevados; já a tecnologia concentrou a maior parte de seus retornos em patamares mais baixos.

Entre os dez setores analisados, os histogramas dos setores de saúde, energia e serviços acadêmicos e educacionais mostraram maior equilíbrio entre as frequências dos valores dos retornos no período analisado, apresentando alguns picos maiores entre final de janeiro e início de fevereiro de 2022, e início de março/2022 para o caso da saúde. O que diferenciou esses histogramas foi a menor presença de picos relevantes nos setores energético e de serviços acadêmicos e educacionais.

Após avaliação das séries originais setoriais, aplicou-se winsorização a 5% para retirar “Nas” em todas elas. As séries setoriais winsorizadas foram, então, decompostas pelo modelo aditivo e apresentadas na Figura II.6, na qual ficaram evidenciadas as componentes de sazonalidade, efeitos aleatórios e, em alguns casos, de tendência de crescimento ou decrescimento continuado dos retornos, como ocorreu para os setores de tecnologia, saúde e energia. A tecnologia e a saúde tiveram uma tendência de crescimento dos retornos a partir de meados de maio/2022, enquanto o setor energético decresceu nesse mesmo momento. Essas decomposições mostram mais claramente os *clusters* de volatilidade dos retornos para cada setor, bem como suas durações no período analisado.

Os setores de consumo cíclico, industrial, demais serviços, consumo não cíclico e materiais básicos passaram por volatilidades constantes com alguns picos já descritos anteriormente. O setor imobiliário destacou-se pelo comportamento contrário, sem volatilidades constantes e apenas dois *clusters* em momentos relativamente distantes do evento,

enquanto os retornos da tecnologia e saúde foram expostos a volatilidades relevantes quando comparadas com as anteriores após aproximadamente 2,5 meses da invasão russa. Para o setor de serviços acadêmicos e educacionais, o R não foi capaz de decompor a série temporal devido à insuficiência de dados.






Figura II.6 – Decomposições das séries temporais setoriais winsorizadas, na GR-U.

Fonte: dados de pesquisa.

Seguindo a mesma metodologia utilizada por Pretorius (2023) na análise da série temporal total dos retornos da B3, foram feitas análises de regressão para estimar os retornos normais das séries setoriais antes e após a invasão russa na Ucrânia. A Tabela II.5 apresenta os retornos médios e as variâncias para cada setor de atividade da B3, nos períodos de 60, 15 e 5 dias antes do início do conflito e 5, 15 e 150 dias após essa data.

Tabela II.5 – Retornos médios setoriais e variâncias, antes e após a invasão em 24/02/2022

Setor	Estatísticas Descritivas	-60 dias antes	-15 dias antes	-5 dias antes	+5 dias após	+15 dias após	+150 dias após
Consumo Cíclico	Retorno médio	19,51	20,12	20,10	18,97	18,36	17,14
	Desvio-Padrão	31,75	35,16	34,55	34,70	34,75	35,86
	Variância	1.008	1.236	1.193	1.204	1.207	1.286
Industrial	Retorno médio	17,56	17,34	17,27	16,62	16,13	14,66
	Desvio-Padrão	15,06	15,00	14,84	14,39	14,04	13,54
	Variância	226,8	225,2	220,2	206,9	197,1	183,3
Demais Serviços	Retorno médio	32,40	31,03	31,07	31,49	30,83	30,77
	Desvio-Padrão	28,70	25,68	24,88	25,33	25,83	26,54
	Variância	823,6	659,6	619,0	641,4	667,1	704,3
Consumo Não Cíclico	Retorno médio	24,71	25,12	25,15	25,33	24,90	23,22
	Desvio-Padrão	19,20	20,00	19,86	19,57	19,50	20,27
	Variância	368,5	398,7	394,5	382,9	379,9	410,8
Imobiliário	Retorno médio	382,7	378,5	388,9	386,2	376,5	403,1
	Desvio-Padrão	1.438	1.417	1.485	1.485	1.450	1.634
	Variância	2.068.407	2.007.167	2.205.860	2.204.388	2.102.699	2.671.491
Materiais Básicos	Retorno médio	27,82	27,02	26,98	27,56	26,91	22,69
	Desvio-Padrão	25,24	24,64	24,88	26,48	25,25	23,26
	Variância	637,0	607,2	619,0	701,3	689,0	540,9
Tecnologia	Retorno médio	16,89	17,14	17,02	16,82	16,78	14,42
	Desvio-Padrão	13,38	13,41	13,38	13,92	14,63	13,09
	Variância	179,1	180,0	178,9	193,8	213,9	171,3
Saúde	Retorno médio	18,27	18,97	18,53	18,21	17,67	16,37
	Desvio-Padrão	7,921	7,464	7,105	7,356	7,342	9,866
	Variância	62,75	55,72	50,48	54,11	53,90	97,34
Energia	Retorno médio	16,20	17,95	18,13	18,95	17,35	15,23
	Desvio-Padrão	7,979	9,115	9,239	9,756	8,731	8,267
	Variância	63,67	83,09	85,38	95,18	76,23	68,34

Serviços	Retorno médio	10,27	11,29	11,18	10,17	8,747	6,6975
Acadêmicos e Educa- cionais	Desvio-Padrão	6,359	7,106	7,543	6,630	5,251	4,382
	Variância	40,45	50,50	56,89	43,96	27,58	19,20

Fonte: dados de pesquisa.

Os resultados da Tabela II.5 indicaram que o consumo cíclico sofreu uma desvalorização média de 9,67% em seus retornos após a invasão e um aumento de 7,02% em suas variâncias (volatilidades). O setor industrial desvalorizou 10,04% em seus retornos, porém teve uma queda de 14,44% em sua variância depois de 24/02/2022. Quanto aos demais serviços, os retornos reduziram em 1,53% após o evento, assim como as variâncias (4,44%). Os retornos do setor de consumo não cíclico também desvalorizaram em média 2,09% após a invasão, e a variância média aumentou 1,01%.

Os setores de materiais básicos, tecnologia, saúde e energético também viram seus retornos sofrerem quedas respectivamente de 6,05%, 6,31%, 6,74% e 1,46% após o início da guerra, com as variâncias aumentando em 3,51%, 7,08%, 17,7% e 3,18%. No sentido contrário dos outros setores, o imobiliário teve uma valorização de 1,35% em seus retornos após a invasão, destacando-se também pelas variâncias mais altas do mercado, que aumentaram 9,99% após 24/02/2022. O destaque entre os retornos e variâncias dos setores ficou para os serviços acadêmicos e educacionais, cujos retornos reduziram 27,8% após a invasão, porém com as variâncias reduzindo 62,9%.

Para verificar se as diferenças encontradas nas estatísticas descritivas dos retornos médios setoriais e de suas variâncias foram significantes, aplicaram-se os mesmos testes usados para a série temporal total, conforme estudo de Pretorius (2023) (Tabela II. 6). Para todos os setores, ambos os testes t de Student (homocedasticidade) e de Welch (heterocedasticidade) não foram significantes (com 95% de confiança), conduzindo à aceitação da hipótese nula de que não houve diferença estatística entre os retornos médios antes e após o início do conflito. Para os testes das variâncias, o teste de Siegel-Tukey (que comparou as dispersões das variâncias antes e após o evento) indicou que todos os setores analisados tiveram dispersões irrelevantes em suas variâncias, sem significância estatística, com confiabilidade de 95%. Estes resultados foram corroborados pelos testes F de Fischer e de Bartlett, os quais ratificaram a ausência de diferenças significantes entre as variâncias nesses setores.

Tabela II.6 – Testes de diferenças entre retornos e variâncias para os setores da B3, antes e após a GR-U

Setor	Testes dos retornos		Testes das variâncias			
	t de Student	t de Welch	Siegel-Tukey	F de Fisher	Brown-Forsythe	Bartlett (K^2)
Consumo Cíclico	0,41	0,41	17285(a); 19693(d)	0,92	2,6e+29***	0,23
Industrial	0,75	0,75	8888(a); 8681(d)	1,1	0,48	0,41
Demais Serviços	0,21	0,16	10603(a); 10403(d)	1,0	3,6e+28***	0,029
Consumo Não Cíclico	0,34	0,35	5563(a); 5561(d)	1,9	1,9e+31***	0,015
Imobiliário	-0,022	-0,022	5031(a); 5659(d)	0,90	--	0,21
Materiais Básicos	0,38	0,38	5359(a); 5542(d)	0,95	3,8e+28***	0,041
Tecnologia	0,27	0,27	729(a); 707(d)	0,92	--	0,041
Saúde	0,53	0,53	729(a); 756(d)	0,82	--	0,26
Energia	0,095	0,095	576(a); 600(d)	0,95	--	0,015
Serviços Acadêmicos e Educacionais	0,87	0,87	144(a); 156(d)	1,5	--	0,48

Fonte: dados de pesquisa.

Notas: 1: p-valor: *** 0,001; ** 0,01; * 0,05.

2: (a) = antes do evento; (d) depois do evento.

Contrariando os resultados acima, o teste de Brown-Forsythe para o consumo cíclico, demais serviços, consumo não cíclico e materiais básicos identificou diferenças significantes entre as variâncias antes e após a invasão, supondo heterocedasticidade dos valores. Considerando que os testes de Fischer e Bartlett são sensíveis à distribuição normal e que os testes não paramétricos de Siegel-Tukey e de Brown-Forsythe são menos sensíveis a ela (em séries temporais financeiras) e mais robustos em desvios de normalidade e contra *outliers*, concluiu-se que os setores de consumo cíclico, demais serviços, consumo não cíclico e materiais básicos sofreram impactos nos retornos de suas ações, no período entre 60 dias antes do início da guerra entre Rússia e Ucrânia até 150 dias após.

Para as variâncias da indústria antes e depois de 24/02/2022, o teste de Brown-Forsythe não sugeriu diferença significativa, opondo-se aos resultados obtidos para os demais setores. Como os outros testes estatísticos corroboraram a ausência de diferença entre as médias dos retornos e de suas variâncias, concluiu-se que a invasão da Ucrânia não impactou os retornos do setor industrial da B3, contrariando a expectativa em função das análises gráficas discutidas previamente.

Não foi possível realizar o teste de Brown-Forsythe para os setores imobiliário, de tecnologia, saúde, energia e serviços acadêmicos e educacionais, uma vez que tal teste utiliza as medianas das variâncias de cada grupo “antes” e “após” o evento para calcular os desvios absolutos de cada variância da amostra em relação àquela do grupo correspondente. De fato, conforme pode ser observado na Figura II.6, as tendências das variações dos retornos (variâncias) foram mais lineares, com um ou dois *clusters* no período analisado, podendo-se

pensar que as diferenças entre as medianas das variâncias dos grupos e cada variância assumiram valores tão baixos que impossibilitaram a estimação de tais diferenças.

II.5 Conclusões

O objetivo deste capítulo foi identificar e analisar a relação entre o período inicial do início da guerra na Ucrânia e os retornos do mercado acionário brasileiro, entre dezembro/2021 e junho/2022. As análises dos retornos e suas variâncias levaram à conclusão de que os setores de consumo cíclico, demais serviços, consumo não cíclico e materiais básicos sofreram impactos nos retornos de suas ações, no período entre 60 dias antes do início da guerra entre Rússia e Ucrânia até 150 dias após. Para os demais setores analisados, não houve impactos estatisticamente significantes.

Dessa forma, a série total e as séries setoriais dos retornos da indústria, dos setores imobiliário, de tecnologia, saúde, energia e educacional, nos primeiros meses da guerra na Ucrânia, contradisseram a hipótese H_1 , de que a guerra na Ucrânia impactou negativamente os retornos das ações, no período entre dezembro/2021 e julho/2022. Isso confirmou a hipótese nula, $H_{0(4)}$, para estes setores, de que o conflito não teve impacto (positivo ou negativo) sobre os retornos das ações das empresas da B3 no período analisado. Entretanto, para os setores de consumo cíclico, demais serviços, consumo não cíclico e materiais básicos, H_4 foi confirmada, sendo que os respectivos retornos pós-invasão foram negativos, ou seja, desvalorizaram nos primeiros meses após o início da GR-U.

Os resultados obtidos para os setores não impactados pela GR-U são coerentes com a situação da crise, uma vez que não estão diretamente correlacionados com guerra, não possuindo relação de dependência direta com os efeitos econômicos do conflito e das sanções impostas pelos EUA e Europa sobre os mercados globais.

Quanto aos setores que foram impactados pela GR-U, os resultados obtidos também fazem sentido. No caso do consumo cíclico, cuja demanda envolve produtos ou serviços, os quais são fortemente influenciados pela economia, o desempenho das empresas relaciona-se diretamente aos indicadores econômicos do país, como taxas de juros e variações cambiais, que sofreram alterações relevantes nos primeiros meses da guerra.

A mesma expectativa foi validada para o setor de materiais básicos, pois a oferta de *commodities* no Brasil, a exemplo do gás natural, petróleo, trigo e milho, passou por expectativas de redução de oferta no mercado. Isso se deveu ao fato de a Rússia, grande

fornecedora mundial de gás natural e petróleo, ter passado por sanções econômicas globalizadas, ainda que estas não afetassem diretamente o fornecimento desses produtos.

O setor de consumo não cíclico, que agrupa empresas cujos produtos ou serviços são essenciais à sobrevivência e, portanto, sua demanda é menos sensível (ou vulnerável) a variações abruptas do ciclo econômico, teve seus retornos desvalorizados. Isso seria esperado frente às expectativas iniciais sobre a queda no fornecimento de algumas matérias-primas importadas principalmente da Rússia pelo Brasil, como os fertilizantes, o que poderia atingir o agronegócio brasileiro, repercutindo na alta dos preços da soja, óleos vegetais e grãos. Tais altas impactaram negativamente os frigoríficos brasileiros, principalmente em aves e suínos, pelo aumento do custo de alimentação dos animais.

A expectativa de alta de preços para alguns produtos do setor de demais serviços também se concretizou na redução dos retornos das ações, uma vez que o preço do petróleo subiu no ambiente internacional, impactando o preço do gás e outros derivados, além de promover a alta inflacionária e cambial.

Referências

- Adekoya, O.B., Oliyide, J.A., Yaya, O.S., Al-Faryan, M.A.S. (2022). Does oil connect differently with prominent assets during war? Analysis of intra-day data during the Russia-Ukraine saga. *Resour. Policy*, 77.
- Ahmed, S., Hasan, M. M., & Kamal, M. R. (2022). Russia-Ukraine crisis: The effects on the European stock market. *European Financial Management*, p. 1-41. DOI: <https://doi.org/10.1111/eufm.12386>.
- Arango-Castillo, L., Orraca, M. F., & Molina, G. S. (2023). The global component of headline and core inflation in emerging market economies and its ability to improve forecasting performance. *Economic Modelling*, 120. DOI: <https://doi.org/10.1016/j.econmod.2022.106121>.
- Bannigidadmath, D., Narayan, P. K., Phan, D. H. B. & Gong, Q. (2022). How stock markets reacted to COVID-19? Evidence from 25 countries. *Finance Research Letters*, 45. DOI: <https://doi.org/10.1016/j.frl.2021.102161>.
- Barbosa Filho, L. H. (2023). Análise Macro. A abordagem do estudo de eventos no mercado financeiro. 24/10/2023. Recuperado de: <https://analisemacro.com.br/mercado-financeiro/a-abordagem-do-estudo-de-eventos-no-mercado-financeiro/>.
- Baur, D. G., Lucey, B. M. (2010). Is gold a hedge or a safe haven? An analysis of stocks, bonds and gold. *Financ. Rev.* 45(2), p. 217-229. DOI: <http://dx.doi.org/10.1111/j.1540-6288.2010.00244.x>.

- Boubaker, S., Goodell, J. W., Pandey, D. K., & Kumari, V. (2022). Heterogeneous impacts of wars on global equity markets: Evidence from the invasion of Ukraine. *Finance Research Letters*, 48.
- Brown, S. J. (2011). The efficient markets hypothesis: The demise of the demon of chance? *Accounting and Finance*, 51, p. 79-95.
- Brown, S. J., & Warner, J. B. (1985). Using daily stock returns: The case of event studies. *Journal of Financial Economics*, 14, p. 3-31.
- Caballero, R.J., Krishnamurthy, A. (2008). Collective risk management in a flight to quality episode. *J. Finance* 63(5), p. 2195-2230. DOI : <http://dx.doi.org/10.1111/j.1540-6261.2008.01394.x>.
- Caldara, D., & Iacoviello, M. (2022). Measuring geopolitical risk. *International Finance Discussion Papers*, 1222. Board Gov. Fed. Reserve Syst. DOI: <https://doi.org/10.17016/IFDP.2018.1222>.
- Chernomas, R., Hudson, e & I. Bursting Bubbles: (2017). *Finance, Crisis and the Efficient Market Hypothesis*. In: The Profit Doctrine: Economists of the Neoliberal Era. Pluto Press.
- Costa, D. M. (2017). Revisitando os clássicos da moderna teoria de finanças: uma análise. *Revista Brasileira de Administração Científica*, 8(2), p. 16-41.
- Fama, E. F. (1970). Efficient Capital Markets: A Review of Theory and Empirical Work. *Journal of Finance*, 25(2), p. 383-417.
- Fama, E. F. (1991). Efficient Capital Markets: II. *Journal of Finance*, 46(5), 1575-1617.
- Fama, E. F. (1998). Market Efficiency, Long-Term Returns, and Behavioral Finance. *Journal of Financial Economics*, 49(3), p. 283-306.
- Grossman, S. J., & Stiglitz, J. E. (1980). On The Impossibility of Informationally Efficient Markets. *The American Economic Review*, 70(3), p. 393-408.
- Huntington-Klein, N. (2021). The effect: An introduction to research design and causality, Chapman and Hall/CRC. 15/06/2022. Recuperado de: <https://theeffectbook.net/ch-EventStudies.html>.
- Ippolito, R. A. (1989). Efficiency with Costly Information: A Study of Mutual Fund Performance, 1965-84, *Quarterly Journal of Economics*, 104, p. 1-23.
- Jaffe, J. F. (1974). Special Information and Insider Trading. *Journal of Business*, 47, p. 410-428.
- Kendall, M. G. (1953). The Analysis of Economic Time0Series, Part I. *Journal of the Royal Statistical Society*, 96, part I, p. 11-25.
- Malkiel, B. G. (2003). The Efficient Market Hypothesis and Its Critics. *Journal of Economic Perspectives*, 17(1), p. 59-82.

- Mandelbrot, B. (1963). The Variation of Certain Speculative Prices. *The Journal of Business*, 36(4), p. 394-419.
- Markowitz, H. (1952). Portfolio Selection. *Journal of Finance*, 7(1), p. 77-91.
- Mishra, A., Mishra, A., & Dash, A. K. (2023). Impact of the Russia-Ukraine crisis on food inflation and stock markets in Asian economies: with reference to India, China, Japan and Thailand. *International Journal of Social Science and Economic Research*, 8(5), p. 1020-1044.
- Mohamad, A. (2022). Safe flight to which haven when Russia invades Ukraine? A 48-hour Story. *Economics Letters*, 216. DOI: <https://doi.org/10.1016/j.econlet.2022.110558>.
- Niederhoffer, V., & Osborne, M. F. M. (1966). Market Making and Reversal on the Stock Exchange. *Journal of the American Statistical Association*, 61, p. 897-916.
- Nonnenberg, M. J. B., & Martins, M. M. V. (2022). *Como a guerra na Ucrânia poderá afetar o comércio exterior? Efeitos sobre o Brasil* (Carta de Conjuntura nº 54 – Nota de Conjuntura 22, 2022), Brasília, DF, Diretoria de Estudos e Relações Econômicas e Políticas Internacionais (Dinte), Ipea.
- Osborne, M. F. M. (1959). Brownian Motion in the Stock Market. *Operations Research*, 7, p. 145-173.
- Pinheiro, A. C., & Matos, S. (2022). *A guerra intensifica o choque inflacionário* (Boletim Macro, nº 129, p. 3-6, 2022), Rio de Janeiro, RJ, Instituto Brasileiro de Economia – FGV IBRE.
- Pitigala, N. (2022). Covid-19 and Russia-Ukraine war: trade impacts on Developing and emerging markets. *Sri Lanka Journal of Economic Research*, 10(1), p. 113-137. DOI: <http://doi.org/10.4038/sljer.v10i1.177>.
- Pretorius, A. (2023). How did advanced emerging stock markets respond to COVID-19 and the Ukraine invasion? *Journal of Economic and Financial Sciences*, 16(1). DOI: <https://doi.org/10.4102/jef.v16i1.820>.
- Senna, J. J. (2022). *Efeitos inflacionários da guerra e a cautela dos bancos centrais* (Boletim Macro, nº 129, p. 23-24, 2022), Rio de Janeiro, RJ, Instituto Brasileiro de Economia – FGV IBRE.
- Seyhun, H. N. (1986). Insiders' Profits, Costs of Trading, and Market Efficiency, *Journal of Financial Economics*, 16, p. 189-212.
- Shiller, R. J. (2013). Reflections on Finance and the Good Society. *American Economic Review*, 103(3), p. 402-405.
- Tosun, O. K., Eshraghi, A. (2022). Corporate decisions in times of war: Evidence from the Russia-Ukraine conflict. *Finance Res. Lett.* 48.

Yousaf, I., Patel, R., & Yarovaya, L. (2022). The reaction of G20+ stock markets to the Russia–Ukraine conflict “black-swan” event: Evidence from event study approach. *Journal of Behavioral and Experimental Finance*, 35. Recuperado de: <https://doi.org/10.1016/j.jbef.2022.100723>.

Yu, J., & Chen, G. (2023). How Does the Russia–Ukraine War Affect the Stock Market? – An Empirical Study. *AEMPS*, 3, p. 755-765. Recuperado de: <https://doi.org/10.54254/2754-1169/3/2022885>.

Zaremba, A., Cakici, N., Demir, E., & Long, H. (2022). When bad news is good news: Geopolitical risk and the cross-section of emerging market stock returns. *Journal of Financial Stability*, 58. DOI: <https://doi.org/10.1016/j.jfs.2021.100964>.

III. VOLATILIDADE DOS PREÇOS DAS AÇÕES BRASILEIRAS NO INÍCIO DA PANDEMIA DA COVID-19

III.1 Introdução

O início da crise pandêmica no Brasil criou um ambiente macroeconômico de muita insegurança, levando os investidores a tomarem decisões sobre seus investimentos de forma irracional, movidos pelo medo e sentimento de risco descontrolado. A bolsa de valores brasileira, B3, acionou a ferramenta *circuit breaker* em março/2020 na tentativa de reduzir a volatilidade dos preços das ações, que estavam em quedas anormais devido às decisões impulsivas e ao medo generalizado. Segundo o site da B3, o *circuit breaker* é um procedimento que interrompe a negociação de ações em bolsa, sendo acionado em momentos atípicos, como forte queda de preços, referenciados pela oscilação do IBOVESPA (B3, 16/03/20).

O procedimento de acionamento do *circuit breaker* consiste em três estágios, obedecendo a percentuais pré-determinados de desvalorização do IBOVESPA, sendo o estágio I relativo à desvalorização de 10% em relação ao valor de fechamento do IBOVESPA do dia anterior, e interrompe as negociações por 30 minutos. O estágio II ocorre após a reabertura destas, considerando uma desvalorização de 15% em relação ao valor de fechamento do dia anterior, novamente interrompendo as negociações por 1 hora. Por fim, o estágio III considera uma desvalorização de 20% em relação ao índice de fechamento do dia anterior, quando a B3 pode determinar o período da suspensão das negociações (Smaniotto & Zani, 2020).

Smaniotto e Zani (2020) relatam que, em decorrência da crise da Covid-19, o *circuit breaker* foi acionado seis vezes em março/2020 pela B3, em ocasiões nas quais o IBOVESPA atingiu os seguintes níveis de desvalorização:

1. 09/03/2020: queda de 10,02% devido principalmente à queda dos preços do petróleo gerada pela briga de preços entre a Arábia Saudita e a Rússia;
2. 11/03/2020: queda de 7,64% em função da declaração de estado de pandemia do coronavírus pela OMS, as ações da Vale, do setor financeiro, siderúrgico, aéreo e dos setores da Petrobras caíram drasticamente, criando um ambiente de instabilidade financeira;
3. 12/03/2020: queda de 10,00% em vista da instabilidade estabelecida, com o dólar atingindo R\$ 5,00 e o aumento da aversão dos investidores ao risco;
4. 12/03/2020: queda de 15,43% após intervalo de 30 minutos, desencadeando o *circuit breaker* pela segunda vez no mesmo dia;

5. 16/03/2020: queda de 12,53% com o volume de negociações até o momento totalizando R\$ 1,39 bilhões;
6. 18/03/2020: queda de 10,26% face ao pânico geral causado pela pandemia, com volume de negociação de 15,4 bilhões de reais.

Os acionamentos dos *circuit breakers*, entretanto, não atestaram sua eficiência no controle da volatilidade dos preços, porém ajudaram a compreender o comportamento do mercado em um momento de alta instabilidade (Smaniotto, & Zani, 2020). Moreira, Nganga e Telles (2020) realizaram um estudo para avaliar os impactos das notícias relacionadas à Covid-19 sobre o retorno das empresas de capital aberto do Brasil, no início da pandemia, e perceberam um comportamento de queda nos retornos do IBOVESPA, começando na data do primeiro caso de Covid-19 no país, em 26/02/2020, seguido pela instabilidade durante todo o mês de março daquele ano. Já nos meses de abril até maio, o cenário aparentou ser menos volátil, com relativa estabilidade.

Era compreensível e esperado que a chegada das primeiras vacinas contra o coronavírus no início de 2021 trouxesse expectativas de retorno à normalidade e estabilidade dentro do mercado financeiro. Nesse contexto, Rouatbi, Demir, Kizys e Zaremb (2021) questionaram a existência da relação entre vacinação em massa e a volatilidade da bolsa de valores. Isso faz sentido considerando que uma amenização da crise econômica induziria maior segurança e confiança nos investidores, traduzidas em maiores retornos, menores riscos e menor volatilidade.

Para testar o efeito da vacinação contra a Covid-19 na volatilidade do mercado acionário, Rouatbi *et al.* (2021) realizaram um estudo empírico utilizando dados de 66 mercados de todo o mundo, no biênio 2020/2021. Usando regressão de painel, os autores analisaram a relação entre as medidas de vacinação adotadas pelos governos e a volatilidade diária desses mercados. Os resultados mostraram que as vacinações em massa coincidiram com uma queda significativa da volatilidade das ações, principalmente em economias de países desenvolvidos. Essa queda foi independente do impacto da pandemia sobre a economia local ou de respostas de políticas governamentais relacionadas.

Chan, Chen, Wen e Xu (2021) analisaram as reações dos mercados acionários de 49 países até o início dos ensaios clínicos das vacinas contra Covid-19 e constataram um aumento de retornos anormais médios no primeiro dia desses testes. Outra constatação foi que as reações diante do desenvolvimento das vacinas foram heterogêneas em países como Estados Unidos e

China, além de ilustrar como as reações do mercado acionário foram substanciais frente ao progresso do desenvolvimento das vacinas.

O trabalho de Hong, Wang e Yang (2021) consistiu na elaboração de um modelo de gestão de risco pandêmico e avaliação de empresa, que, ao ser aplicado ao mercado, permitiu constatar que a avaliação de ativos era altamente sensível às taxas de disponibilização de vacinas, de forma que a sua disponibilização para a população elevava os preços das ações aos mesmos níveis do período pré-pandêmico, apontando para uma relação direta entre a vacinação e a queda da volatilidade das ações.

Outro aspecto da vacinação contra a Covid-19 que pode ter impactado as expectativas dos investidores foi o fato de ela ter avançado de forma mais célere em países desenvolvidos do que nos emergentes. Para Rouatbi *et al.* (2021), essa diferença entre taxas de imunização pode ter influenciado as expectativas dos investidores, uma vez que, em países emergentes, pôde-se enxergar uma probabilidade reduzida do fim das perturbações decorrentes da crise em seus mercados.

Essas quedas na volatilidade aumentaram a disposição dos investidores ao risco e puderam ser traduzidas em um custo de capital inferior, promovendo o crescimento econômico e a suavização intertemporal do consumo doméstico (Rouatbi *et al.*, 2021). Com base nesse cenário, este capítulo teve como objetivo avaliar a volatilidade dos preços das ações de empresas da B3, entre janeiro/2020 e maio/2020, em função da pandemia da Covid-19. Para tal, propôs-se a segunda hipótese dessa pesquisa:

H₂: A pandemia da Covid-19 impactou de forma diferenciada os preços das ações das empresas dos setores da B3.

A justificativa deu-se pela gravidade dos efeitos derivados da crise sobre o bem-estar das pessoas e sobre a sustentabilidade de economias emergentes como o Brasil, que não estavam preparados para lidar com a crise de forma organizada e ágil. A relevância da pesquisa reside no fato de a economia brasileira ter sofrido fortes efeitos da pandemia em função das medidas restritivas para contenção da contaminação da doença na população. Diante do exposto, o objetivo deste capítulo foi avaliar a volatilidade dos preços das ações das empresas da B3, no conjunto geral e setorialmente, entre janeiro/2020 e maio/2020, quando a crise impactou intensamente o mercado brasileiro.

III.2 Revisão da literatura

III.2.1 Teoria Moderna de Seleção de Portfólio

Para Harry Markowitz (1952), a seleção de um portfólio (ou carteira de ativos) consiste em um processo de duas etapas: a primeira inicia com a observação e experiência, e termina com crenças sobre o desempenho futuro dos ativos; e a segunda começa com as crenças sobre desempenhos futuros e termina com a escolha do portfólio. Markowitz (1952) afirmou que o investidor deve selecionar uma carteira que maximize retornos futuros. A incerteza em qualquer investimento existe e deve ser cuidadosamente analisada e avaliada para se construir um portfólio de ativos otimizado, ou seja, que comporte a melhor relação entre o retorno estimado e a incerteza (ou risco) associada. A realidade do mercado “exige” considerar a diversificação de ativos como uma prática comum e razoável para reduzir a incerteza sobre o retorno (Markowitz, 1990).

John Burr Williams, em sua obra *“The Theory of Investment Value”*, propôs que o valor de um ativo deve ser igual ao valor presente do seu fluxo de dividendos futuro. Para Williams, o investidor, preocupado apenas com os valores esperados futuros, acreditava que bastava investir em um ativo com o máximo de retorno esperado, que estaria realizando um bom investimento (Markowitz, 1990). Entretanto, na visão de Markowitz (1990), um ativo avaliado com base apenas no retorno esperado deve ser rejeitado, uma vez que, para cada retorno, há um nível de risco envolvido. Tal visão embasou a moderna Teoria de Seleção de Portfólio de Markowitz.

A ideia da diversificação de investimentos não era novidade na época em que Markowitz realizou seus estudos sobre o tema, porém foi ele quem formalizou a teoria e a aplicou aos instrumentos financeiros, partindo da premissa de que a decisão sobre a composição de uma carteira de investimentos deve estar fundamentada no valor esperado e no desvio-padrão (ou risco) dos retornos dos ativos, sendo tal decisão consequência da minimização do risco. Markowitz ganhou o prêmio Nobel de Economia em 1990 por esse trabalho (Samanez, 2007).

Para Markowitz (1990), o risco consiste na variação ou volatilidade de um ativo, enquanto o retorno é o resultado esperado em relação ao seu valor futuro. Seu modelo de seleção de carteira deve ser abordado como a etapa final da montagem de um portfólio, cuja premissa é trazer para o modelo ativos que foram pré-selecionados por meio de outros critérios. O modelo de seleção de carteiras tem o objetivo de calcular a melhor combinação percentual entre os ativos que resultará no menor risco e maior retorno possível. Markowitz (1990) afirma que o risco é representado pela variância ou desvio-padrão do valor do ativo, e pode ser calculado por

meio de uma série histórica dos preços de fechamento de pregão obtidos durante o período de pelo menos um ano. Já o retorno esperado é a expectativa de valorização desse ativo, ou seja, o quanto se espera que seu preço aumente no período considerado.

O modelo de Markowitz demonstra que o retorno da carteira é a média entre os retornos dos ativos individuais, ponderados por seu peso, conforme equação (III.1) (Debastiani, & Russo, 2008):

$$\text{Retorno da carteira} = \sum_1^n (R_{ativo} \times P_{ativo}) \quad (\text{III.1})$$

em que:

R_{ativo} = retorno esperado do ativo;

P_{ativo} = peso do ativo na composição da carteira.

De acordo com Debastiani e Russo (2008), Markowitz demonstrou que, por meio de um processo de seleção de carteiras, é possível maximizar o retorno ao mesmo tempo que se reduz o risco, uma vez que diferentes ativos não oscilam da mesma forma. A Figura III.1 mostra que a diversificação da carteira reduz significativamente o risco não sistemático ou inerente a uma ação específica. Isso ocorre porque o desvio-padrão da carteira (ou seu grau de oscilação como conjunto de ações) é muito menor que o desvio-padrão de cada ação individual.




Figura III.1: Risco x Quantidade de Ações.
Fonte: Debastiani, & Russo (2008).




Figura III.2: Carteira com Duas Ações.
Fonte: Debastiani, & Russo (2008).

A Figura III.2 exemplifica o risco combinado de duas ações com um grau de retorno maior que o da ação A e menor que o da ação B, em um ponto de risco inferior ao que qualquer um dos dois ativos alcançaria isoladamente. A diversificação não é capaz de eliminar o risco de mercado, que é resultado de variáveis que afetam toda a economia e não influenciam somente um ativo (Debastiani, & Russo, 2008). Ao observar na Figura 4 os retornos das ações, nota-se que aquele referente à carteira combinada é superior ao da ação A e inferior ao da ação B, porém o incremento do retorno de B muitas vezes não compensa o maior risco associado, de forma

que um portfólio otimizado procura associar melhor equilíbrio (uma relação mais eficiente) entre risco e retorno.

O risco de uma carteira depende ainda da covariância entre os ativos que a compõem, isto é, da correlação entre eles. Se uma carteira tem ativos cuja correlação é 1 e suas variações são sempre iguais, isso significa que o risco dessa carteira será o mesmo que o de cada ativo individualmente, uma vez que as variações dos valores acontecem simultaneamente na mesma direção (alta ou queda). Esse fenômeno se reflete no conceito de fronteira eficiente, no qual a avaliação dos riscos e retornos dos ativos gera um conjunto de carteiras (ou portfólios) otimizadas cuja rentabilidade não pode ser incrementada a menos que se aumente o risco associado. Isso significa que existe um equilíbrio “ótimo” na relação risco/retorno entre os ativos de uma carteira, que torna essa relação “ideal” ou mais eficiente quando comparada a outras carteiras.

Essa situação de equilíbrio “ótimo”, definida por Markowitz (1990) como fronteira eficiente, é dinâmica pois se altera ao longo do tempo em função de fatores que impactam o desempenho financeiro dos ativos. Assim, quando ocorre, por exemplo, uma desvalorização das empresas que detêm determinadas ações, ou crises econômicas graves ou uma supervalorização de ações decorrente de eventos internos ou externos à empresa, a fronteira eficiente pode se modificar conforme os valores e riscos associados às ações mudam. Segundo Costa (2017), vários investidores avessos ao risco exigem (ou esperam) um retorno em todos os seus investimentos, e o princípio da fronteira eficiente pode auxiliar na seleção de ativos “ótimos” para comporem portfólios eficientes, por meio de fórmulas econométricas que avaliam seus retornos e riscos associados.

III.2.2 Reações do mercado acionário à crise da Covid-19 e efetividade(?) do *circuit breaker* sobre a volatilidade dos preços de ações

Efeitos diversos da pandemia sobre os mercados acionários foram identificados em estudos internacionais, como no trabalho de Sharif, Aloui e Yarovaya (2020), no qual descrevem uma conexão significativa entre casos confirmados da Covid-19 e medidas de política econômica incertas, risco geopolítico e retorno do mercado acionário nos EUA. Ao comparar a volatilidade das ações durante pandemia da Covid-19 com aquela da crise do *Subprime*, Shehzad, Xiaoxing e Kazouz (2020) concluíram que, na pandemia, as volatilidades dos mercados dos Estados Unidos, Alemanha e Itália foram superiores às aquelas da crise de 2008.

Rizwan, Ahmad e Ashraf (2020) relatam que o risco sistêmico nos setores bancários de países afetados pela pandemia aumentou no início da crise, retornando a níveis mais equilibrados por volta de abril/2020. Um estudo sobre o índice de liberdade econômica da *Freedom House*⁴ de 75 países, conduzido por Erdem (2020), mostrou que os retornos de ações em países mais livres politicamente sofreram quedas menores e, portanto, tiveram volatilidades inferiores àquelas de países mais fechados e rígidos.

Seguindo essa linha de pesquisa, Topcu e Gulal (2020) identificaram que os mercados acionários das economias emergentes asiáticas sofreram perdas superiores àquelas dos mercados emergentes europeus. Isso se deu pelos países asiáticos serem os primeiros que sofreram com a contaminação em massa pelo novo coronavírus, não havendo tempo hábil para os governos tomarem as medidas necessárias de *lockdown* e pacotes de estímulos, como aconteceu na Europa, à exceção da Itália, que também sofreu com uma contaminação inicial descontrolada e em larga escala.

Um fator crítico para restaurar a confiança dos investidores foi compreender o grau de persistência do efeito dos choques provocados pela pandemia da Covid-19 sobre a incerteza e o medo nos mercados financeiros (Oluwasegun, & Johnson, 2022). Essa compreensão justifica a necessidade de novos estudos sobre o “estado da arte” das reações e enfrentamento do mercado à Covid-19, inclusive após o fim do estado de pandemia, na medida em que ela evolui no tempo, bem como medidas de proteção, a exemplo das vacinas.

Com a finalidade de impedir oscilações exageradas nos preços das ações o mercado desenvolveu o mecanismo chamado *circuit breaker*, cuja efetividade encontra divergências na literatura. Isso porque não existe um consenso se esse mecanismo é realmente efetivo, até pelo fato de ser um evento raro de acontecer, com poucos estudos realizados. Sifat e Mohamad (2020) descreveram o *circuit breaker* como um termo guarda-chuva do mercado financeiro, referente a um mecanismo regulatório que impede, interrompe ou suspende totalmente a negociação de um título financeiro (ou de todo o mercado), caso os preços ou volatilidades das ações atingem níveis críticos predefinidos. Segundo esses autores, a suposta intenção é inibir a reação irracional dos investidores, impondo um maior controle para evitar *crashes* e suavizar a volatilidade.

⁴ A *Freedom House* trabalha para defender os direitos humanos e promover mudanças democráticas, com foco nos direitos políticos e nas liberdades civis. A organização classifica o acesso das pessoas aos direitos políticos e liberdades civis em 210 países e territórios através de seu relatório anual *Freedom in the World*. Recuperado de: <https://freedomhouse.org/issues>.

Subrahmanyam (1995) já afirmava no século passado que a hipótese do efeito magnético pressupõe que o *circuit breaker* pode aumentar a volatilidade dos preços quando um preço ou um índice está muito próximo do nível de acionamento desse mecanismo. O efeito magnético é *ex-ante*, de autorrealização, na medida em que os investidores avançam em suas negociações. O estudo de Goldstein e Kavajecz (2004) que investigou empiricamente as estratégias comerciais dos participantes do mercado na Bolsa de Valores de Nova Iorque (NYSE) durante o turbulento período de outubro de 1997 encontrou evidências consistentes com tal efeito em todo o mercado.

O modelo dinâmico de Chen, Petukhov e Wang (2017) corroborou a hipótese de o *circuit breaker* elevar a probabilidade de uma ação acioná-lo novamente quando ultrapassa um determinado limite de preço, provocando o efeito magnético. Jian *et al.* (2020) realizaram um estudo com dados de alta frequência do mercado de ações chinês para examinar o efeito magnético, e os resultados apontaram para um mercado mais volátil e com baixa liquidez. Tais resultados estão suportados na hipótese do efeito magnético, causado pela queda abrupta dos preços, que acionava novamente o *circuit breaker*, exacerbando o problema que ele deveria resolver, gerando um ciclo vicioso de volatilidade crescente. Wong, Kong e Li (2020) também alertaram para o fato de que a presença do efeito magnético no *circuit breaker* implica a possibilidade de haver uma fonte adicional de volatilidade excessiva.

Maciel (2021) afirmou que a pandemia da Covid-19 alterou o estado psicológico de muitos investidores, levando-os a comportamentos de rebanho, tomando decisões irracionais em suas negociações. O autor ilustrou esse comportamento relatando que, em março/2020, os acionamentos do *circuit breaker* pela bolsa de valores brasileira ocorreram quando foram verificadas oscilações de -10% do nível de fechamento do IBOVESPA no dia anterior. Todas as negociações no segmento de ações foram interrompidas por trinta minutos, e, durante esse período, as ordens que não estavam participando do leilão foram canceladas. No mesmo período, a bolsa de valores estadunidense acionou quatro vezes o *circuit breaker* em um intervalo de dez dias, e os preços das ações subiram 20% em três dias (Zhang, & Hamori, 2021).

As evidências apresentadas nos estudos mostraram que muitas vezes o *circuit breaker* exerceu uma função contrária àquela para a qual foi concebido, provocando o efeito magnético de aumento da volatilidade das ações, indicando ausência de efetividade em sua aplicação; ainda assim, como esse mecanismo é muito pouco utilizado pelos mercados, não se pode afirmar que tal efetividade esteja ausente em todos os eventos, sendo necessário um volume maior de estudos para atestar sobre esta questão.

III.2.3 Análise de séries temporais via modelos de Heterocedasticidade Condicional Autorregressiva (modelos ARCH, GARCH e suas variações)

Processos estocásticos estacionários e não estacionários

Um processo estocástico (ou aleatório) define-se como um conjunto de variáveis aleatórias ordenadas no tempo. Propuseram ainda o conceito de processo estocástico estacionário, que, em uma série temporal, relaciona-se ao fato de sua média e variância serem constantes no decorrer do tempo, e o valor da covariância das variáveis aleatórias que compõem a série, entre dois intervalos de tempo, depender apenas da defasagem entre tais intervalos — processo estocástico conhecido como fracamente estacionário.

Por outro lado, uma série temporal não estacionária tem uma média variável com o tempo, assim como a variância. Outro conceito relativo ao processo estocástico puramente aleatório, é o ruído branco, cujas variáveis apresentam média zero, variância constante e o fato de serem serialmente não correlacionadas, ou seja, essas variáveis aleatórias são independentes e identicamente distribuídas entre si.

Em geral, séries temporais de preços dos ativos, como preços das ações ou taxas de câmbio, são processos estocásticos não estacionários, que podem ser subdivididos em dois tipos: (i) sem deslocamento (sem termo constante ou intercepto); (ii) com deslocamento (presença de um termo constante); no tipo sem deslocamento, a série temporal pode ser representada pela equação (III.2):

$$Y_t = Y_{t-1} + u_t \quad (\text{III.2}),$$

em que u_t é o erro aleatório (ou ruído branco) com média zero e variância constante. O valor de Y_t é igual ao seu valor anterior em $(t-1)$, adicionado do erro u_t . Este é um modelo autorregressivo de ordem 1 (ou AR(1)), ou seja, a regressão da série de valores de Y_t no momento t é dada pelo seu valor passado, defasado em um período $(t-1)$ (Conte & Ceretta, 2022).

Reescreve-se a equação (III.2) considerando uma primeira defasagem, ou seja, $t = 1$:

$$Y_1 = Y_0 + u_1 \quad (\text{III.3}),$$

e, generalizando para várias defasagens:

$$Y_t = Y_0 + \sum u_t \quad (\text{III.4}).$$

A equação (4) representa uma série temporal iniciando em $t = 0$ (Y_0) com variância $\text{var}(Y_t) = t\sigma^2$. A média de Y_t é igual ao seu valor inicial Y_0 , e a variância aumenta com t , o que viola a condição de estacionariedade. Dessa forma, o processo estocástico sem deslocamento é

representado por uma série temporal não estacionária. Uma característica desse modelo é a persistência de erros aleatórios ($\sum u_t$). Ao manipular a equação (2) na forma $Y_t - Y_{t-1} = \Delta Y_t = u_t$, observa-se que, apesar de Y_t ser uma série não estacionária, sua primeira diferença ($Y_t - Y_{t-1}$) torna-se estacionária; tal comportamento estende-se às diferenciações superiores da série.

Adicionando-se um deslocamento δ , denominado parâmetro de deslocamento, à equação (2), têm-se $Y_t = \delta + Y_{t-1} + u_t$ e, conseqüentemente, $Y_t - Y_{t-1} = \Delta Y_t = \delta + u_t$, mostrando que esta série também é um modelo AR(1), donde conclui-se que, para o processo estocástico com deslocamento tanto a média quanto a variância aumentam com o tempo, violando as condições de estacionariedade (fraca). Desse modo, tal processo constitui também uma série temporal não estacionária.

Conforme citado anteriormente, nota-se que, na equação (4), os termos u_t são os erros do ruído branco que segue uma distribuição normal ($u_t \sim N(0,1)$). Se $Y_0=0$, então, a equação (4) é um processo estocástico sem deslocamento ($Y_t = \sum u_t$); e se adicionar o deslocamento δ , a equação (4) torna-se um processo estocástico com deslocamento $Y_t = \delta + Y_0 + \sum u_t$.

A distinção entre processos estocásticos ou séries temporais estacionárias e não estacionárias centra-se no aspecto relacionado à tendência da série, ou seja, no seu comportamento conforme sua evolução no decorrer do tempo. Assim, se a tendência da série não for previsível em função do tempo, ela é chamada de tendência estocástica (não é determinística).

Testes de estacionariedade de séries temporais

Existem vários testes e estacionariedade que podem ser aplicados a séries temporais; entretanto, os autores afirmam que a literatura discute mais frequentemente dois tipos: análise gráfica e teste de correlograma. Considerando o interesse da análise deste capítulo da tese, o foco da discussão foi direcionado para testes de estacionariedade fraca.

Análise gráfica

A análise do gráfico da série permite uma primeira análise visual da tendência da série ao longo do tempo (se ela cresce ou decai), bem como se há ou não comportamento sazonal durante o período analisado, ou seja, se a série varia com o tempo, de forma constante ou não. Para uma melhor visibilidade dessas características, o cálculo do logaritmo natural da série e a análise do respectivo gráfico são válidos.

Função de autocorrelação e correlograma

A função de autocorrelação (FAC) com defasagem k , denotada por ρ_k , é definida pela equação (III.5):

$$\rho_k = \frac{Y_k}{Y_0} = \frac{\text{covariância com defasagem } k}{\text{variância}} \quad (\text{III.5}),$$

em que ρ_k é o coeficiente de correlação entre dois valores de uma série temporal, separados por uma defasagem k , e situa-se na faixa entre -1 e +1; o gráfico de ρ_k em função de k é conhecido como correlograma da população. Como na prática utiliza-se amostragem de processos estocásticos, aplica-se a função de correlação amostral, $\widehat{\rho}_k$ dada pela equação (III.6) (Conte & Ceretta, 2022):

$$\widehat{\rho}_k = \frac{\widehat{Y}_k}{\widehat{Y}_0} \quad (\text{III.6}),$$

cujo gráfico é denominado correlograma amostral.

A função de autocorrelação parcial ρ_{kk} (FACP) mede a correlação entre as observações da série temporal que estão separadas por k períodos, depois de verificar as correlações em suas defasagens intermediárias (menores do que k). Dessa forma, a autocorrelação parcial é a correlação entre Y_t e Y_{t-k} após a remoção do efeito dos Y s intermediários.

Os 73andom73grama de FAC e FACP permitem inferir que uma série temporal é estacionária quando se assemelham ao correlograma de uma série temporal de ruído branco. Por outro lado, no correlograma característico de uma série temporal não estacionária, o coeficiente de autocorrelação se inicia com um valor alto e decai muito lentamente (e exponencialmente) à medida que a defasagem aumenta.

A definição da extensão da defasagem é empiricamente avaliada. A significância estatística de qualquer $\widehat{\rho}_k$ pode ser julgada por seu erro padrão. Bartlett (1946) demonstrou que, quando uma série temporal é puramente aleatória, ela apresenta ruído branco que, para grandes amostras, apresenta distribuição normal com média zero e variância 1. De acordo com as propriedades da distribuição normal, o intervalo de confiança de 95% para qualquer população ρ_k é dado por $(\widehat{\rho}_k \pm 1,96\sigma)$, em que σ é o desvio-padrão (raiz quadrada da variância).

A verificação de uma série temporal como sendo um ruído branco pode ser feita utilizando-se a estatística Q de Box-Pierce (1970):

$$Q = n \sum_{k=1}^m \widehat{\rho}_k^2 \quad (\text{III.7}),$$

em que n é o tamanho da amostra e m é a defasagem. Em amostras grandes, Q é aproximadamente distribuída como a distribuição qui-quadrado com m graus de liberdade. Uma variante de Q é a estatística Ljung-Box (1978), definida pela equação (8):

$$LB = n(n+2) \sum_{k=1}^m \frac{\hat{\rho}_k^2}{n-k} \sim \chi^2 m \quad (\text{III.8}),$$

que também segue a distribuição de qui-quadrado com m graus de liberdade, porém tem propriedades melhores (estatisticamente mais poderosas) de amostras pequenas do que a estatística Q .

Outro teste de estacionariedade amplamente popular é o teste de raiz unitária (estocástico) definido por:

$$Y_t = \rho Y_{t-1} + u_t \quad -1 \leq \rho \leq 1 \quad (\text{III.9}),$$

em que u_t é o termo de erro de ruído branco. Se $\rho = 1$ (raiz unitária), a equação (III.9) torna-se um modelo estocástico sem deslocamento, não estacionário. Entretanto, não se pode estimar esta equação pelo Método dos Mínimos Quadrados (ou Mínimos Quadrados Ordinários ou OLS ou MQO) e testar a hipótese de que $\rho = 1$ porque esse teste é viesado no caso de uma raiz unitária.

Manipulando a equação (III.9), chega-se a:

$$\Delta Y_t = \delta Y_{t-1} + u_t \quad (\text{III.10}),$$

em que $\delta = (\rho - 1)$ e Δ é o primeiro operador da diferença. Se $\delta = 0$, então $\rho = 1$, ou seja, tem-se uma raiz unitária indicando que a série temporal é não estacionária; mas se $\delta < 0$, Y_t é estacionária. Para descobrir se δ é zero ou não, Dickey e Fuller (1979) demonstraram que, quando $\delta = 0$, o valor estimado t do coeficiente de Y_{t-1} segue a estatística τ , reconhecida na literatura como teste de Tau ou teste Dickey-Fuller.

Uma última manobra importante para análise de séries temporais não estacionárias é evitar a regressão espúria; para isso, é necessário transformá-las em séries estacionárias, e a maneira mais simples é por meio da regressão no tempo, de forma que os resíduos sejam estacionários.

Modelos de séries temporais

Quando uma série temporal é estacionária, pode-se modelá-la com uma variedade de formas, sendo que as mais aplicadas na literatura são apresentadas a seguir.

Modelo autorregressivo (AR)

Para a série temporal representada pela equação (III.11)

$$(Y_t - \delta) = \alpha_1 (Y_{t-1} - \delta) + u_t \quad (\text{III.11}),$$

em que δ é a média de Y e u_t é um ruído branco, então Y_t segue um processo (ou modelo) autorregressivo estocástico de primeira ordem ou AR(1). Os valores de Y são expressos como desvios com base em um valor médio, de forma que, nesse modelo, o valor previsto de Y no

período t é alguma proporção (α_1) mais um erro aleatório ou perturbação no período t — os valores Y são expressos em torno dos seus valores médios. Generalizando a equação (III.11):

$$(Y_t - \delta) = \alpha_1(Y_{t-1} - \delta) + \alpha_2(Y_{t-2} - \delta) + \cdots \alpha_p(Y_{t-p} - \delta) + u_t, \quad (\text{III.12}),$$

diz-se que Y_t segue um modelo autorregressivo de ordem p ou AR(p). O valor de Y no período t depende do seu valor nos períodos prévios, sendo expressos em torno dos seus valores médios δ . Na modelagem AR, apenas os valores de Y atuais e anteriores estão envolvidos, não existindo outros regressores.

Modelo de média móvel (MA)

Para uma modelagem de série temporal na equação (III.13):

$$Y_t = \mu + \beta_0 u_t + \beta_1 u_{t-1} \quad (\text{III.13})$$

em que μ é uma constante e u é um termo de ruído branco, Y no período t é igual a uma constante mais uma média móvel dos termos de erro atuais e passados. Neste caso, dizemos que Y segue um modelo de média móvel de primeira ordem ou MA(1). Se Y segue a equação genérica (III.14):

$$Y_t = \mu + \beta_0 u_t + \beta_1 u_{t-1} + \beta_2 u_{t-2} + \cdots + \beta_q u_{t-q} \quad (\text{III.14}),$$

diz-se que Y_t segue um modelo MA(q). Dessa forma, um modelo de média móvel é uma combinação linear de termos de erro de ruído branco.

Modelo autorregressivo de médias móveis (ARMA)

A modelagem de uma série temporal pode ter características tanto de AR quanto de MA, configurando um modelo híbrido ARMA, em que há um termo autorregressivo ($\alpha_1 Y_{t-1}$) e um termo de média móvel ($\beta_0 u_t + \beta_1 u_{t-1}$). Dessa forma, a equação (III.15) apresenta Y_t segundo um modelo ARMA(1, 1):

$$Y_t = \theta + \alpha_1 Y_{t-1} + \beta_0 u_t + \beta_1 u_{t-1} \quad (\text{III.15})$$

em que θ representa um termo constante. Em geral, em um modelo ARMA (p, q), haverá p termos autorregressivos e q termos de média móvel.

Modelo autorregressivo integrado de médias móveis (ARIMA)

Os modelos de séries temporais tratadas nesta tese supõem que estas séries são fracamente estacionárias, ou seja, a média e a variância das séries são constantes, e a covariância é invariante no tempo. Entretanto, muitas séries temporais econômicas são não estacionárias, ou seja, integradas; isto quer dizer que, se uma série temporal for integrada de ordem 1 (I1), suas primeiras diferenças (I0) são estacionárias. De forma geral, uma série temporal não estacionária I(d), depois de diferenciada d vezes, torna-se uma série estacionária I(0).

Quando se diferencia uma série temporal d vezes para tornando-la estacionária, e aplica-se o modelo $ARMA(p, q)$, a série temporal original chama-se $ARIMA(p, d, q)$, ou seja, é uma série autorregressiva integrada de médias móveis, em que p denota os números dos termos autorregressivos, d é o número de vezes que a série é diferenciada antes de tornar-se estacionária e q é o número de termos de média móvel. Como exemplo, uma série temporal $ARIMA(2, 1, 2)$ deve ser diferenciada uma vez antes de tornar-se estacionária, e a série temporal estacionária (de primeira diferença) pode ser modelada como um processo $ARMA(2, 2)$, com dois termos AR e dois MA.

Mais alguns exemplos são: (i) se $d = 0$, uma série é estacionária para $ARMA(p, q)$; (ii) um modelo $ARIMA(p, 0, 0)$ significa um processo $AR(p)$ puramente estacionário; (iii) um $ARIMA(0, 0, q)$ significa uma modelagem $MA(q)$ puramente estacionária. Assim, dados os valores de p , d e q , pode-se dizer qual processo está sendo modelado.

Metodologia Box-Jenkins

A metodologia Box-Jenkins (BJ) permite identificar se uma série temporal segue um modelo $AR(p)$, $MA(q)$, $ARMA(p, q)$ ou $ARIMA(p, d, q)$. Os autores lembram que, antes de aplicar o teste BJ, a série precisa ser estacionária (ou ser transformada em uma) (Conte & Ceretta, 2022). A metodologia BJ consiste em tornar inicialmente a série temporal estacionária por meio da diferença logarítmica das séries e, então, identificar os valores de p , e/ou q e/ou d por meio das funções de autocorrelação (FAC) e autocorrelação parcial (FACP) estimadas (Conte & Ceretta, 2022). A Figura III.3 mostra a sistematização BJ em uma sequência de quatro etapas.

Muitas séries temporais exibem comportamento sazonal, e, por meio da metodologia BJ, pode-se remover essa sazonalidade subtraindo da série tal influência e diferenças e escolher o tipo de modelo $ARIMA$ que melhor se ajusta a cada situação. As propriedades de FAC e FACP relacionadas aos modelos autorregressivos descritos anteriormente são apresentadas no Quadro III.1, para fins de referência na avaliação do melhor modelo ajustado para cada série temporal analisada.

IDENTIFICAÇÃO

Identificam-se provisoriamente os valores de p , d e q por meio das funções de autocorrelação (FAC) e autocorrelação parcial (FACP) estimadas para a série temporal.

ESTIMAÇÃO

Estimam-se os parâmetros dos termos autorregressivos e dos termos de média móvel do modelo escolhido a partir de FAC e FACP, o que pode ser feito pelo método dos mínimos quadrados simples ou métodos de estimação não linear (nos parâmetros).

VERIFICAÇÃO

Após a escolha do modelo ARIMA e a estimação de seus parâmetros, ajustam-se os dados para verificar se há outro modelo ARIMA melhor - um teste é verificar se os resíduos estimados constituem ruídos brancos; caso positivo, o ajuste deve ser aceito; caso contrário, devem-se refazer as etapas 1, 2 e 3 iterativamente, até se encontrar o melhor ajuste com testes.

PREVISÃO

Após verificar o modelo com melhor ajuste, é possível prever valores futuros para a série, a partir de seus valores passados. Para isso, o método ARIMA é mais confiável que a modelagem econométrica tradicional, especialmente no curto prazo.

Figura III.3 – Metodologia Box-Jenkins para modelagem de séries temporais.

Quadro III.1 – Padrões de FAC e FACP para modelos AR, MA e ARMA

Modelo	Padrão da FAC	Padrão da FACP
AR(p)	Decaimento exponencial ou padrão senoidal, tendendo ao infinito	Picos significativos até p defasagens
MA(q)	Picos significativos até q defasagens	Decaimento exponencial tendendo ao infinito
ARMA(p, q)	Decaimento exponencial tendendo ao infinito	Decaimento exponencial tendendo ao infinito

Elaborado pela autora.

Mensuração da volatilidade acionária

Séries temporais financeiras, como preços das ações, taxas de câmbio, inflação etc., geralmente apresentam o fenômeno da aglomeração por volatilidade, que ocorre em períodos nos quais os preços sofrem grandes oscilações por um período de tempo, seguido por períodos de “calmaria”. Esse padrão de alternância entre períodos calmos e voláteis de duração substancial é conhecido na literatura como *volatility clustering* (*clusters* de volatilidade ou agrupamentos de volatilidade).

A volatilidade em uma série temporal refere-se, portanto, à sua variância condicionada ao tempo (Engle, 1982; Martins, Bortolon & Maia, 2021). Carvalho, Silva, Lobato e Figueiredo (2022) corroboram e complementam que a volatilidade pode ser observada em séries temporais de menor ou maior variabilidade, e nas respostas assimétricas dos preços das ações a choques positivos e negativos gerados a partir de eventos externos, provocando intensa volatilidade no

mercado de capitais, com elevadas perdas ou ganhos; entretanto, os choques negativos tendem a gerar maior volatilidade que os positivos, fenômeno conhecido como alavancagem.

Séries com tal comportamento, em sua maioria, são não estacionárias; contudo, exibem características de estacionariedade sob a forma da primeira diferença. Sendo assim, para analisar uma série temporal financeira, é recomendado modelar as primeiras diferenças, as quais frequentemente exibem alta volatilidade, sugerindo que a variância muda no decorrer do tempo.

Modelo ARCH

Para modelar a variação da variância condicionada ao passado (variância condicional) de uma série temporal, a literatura frequentemente refere-se à utilização do modelo de heterocedasticidade condicional autorregressiva (ARCH, do inglês *Autoregressive conditional heteroscedasticity*), originalmente desenvolvido por Engle (1982). No modelo ARCH, a variância do erro está relacionada com o termo de erro, elevado ao quadrado, no período anterior. A heterocedasticidade ou variância desigual pode ter uma estrutura autorregressiva na qual a heterocedasticidade ao longo de diferentes períodos pode ser autocorrelacionada (Carvalho *et al.*, 2022).

Os conceitos de estacionariedade e heterocedasticidade condicional podem parecer incompatíveis; entretanto, a fraca estacionariedade de uma série requer que sua média seja constante e sua covariância, entre dois momentos quaisquer, seja finita e idêntica, sempre que as defasagens entre eles forem as mesmas — em particular, a variância é constante para um processo fracamente estacionário.

O modelo ARCH(1) está ilustrado pela equação (III.16), enquanto a equação (III.17) ilustra o modelo generalizado ARCH(p), em que p é o número de termos autorregressivos.

$$X_t^2 = \beta_0 + \beta_1 X_{t-1}^2 + u_t \quad (\text{III.16})$$

$$X_t^2 = \beta_0 + \beta_1 X_{t-1}^2 + \beta_2 X_{t-2}^2 + \cdots + \beta_p X_{t-p}^2 + u_t \quad (\text{III.17}).$$

Para testar o efeito ARCH em um modelo de regressão com dados de uma série temporal, exemplificada pela equação (III.18)

$$Y_t = \beta_1 + \beta_2 X_{2t} + \cdots + \beta_k X_{kt} + u_t \quad (\text{III.18}),$$

considera-se o modelo de regressão linear de variável k, e admite-se o erro u_t como um ruído branco, ou seja, com distribuição normal, média zero e variância seguindo um modelo ARCH(1). A novidade do modelo ARCH é que a variância condicional de u no período t depende do quadrado dos termos de erro quadráticos prévios (t -1), podendo depender não apenas de um, mas de vários termos defasados. Ademais, deve-se aplicar o método dos Mínimos Quadrados Generalizados (MQG) para estimar os parâmetros do modelo.

Modelo GARCH

Bollerslev (1986) introduz um outro modelo autorregressivo que envolve as defasagens da variância condicional (ou volatilidade), além das defasagens dos valores da série temporal. Tal combinação é chamada de heterocedasticidade condicional autorregressiva generalizada (GARCH, do inglês *Generalized Autoregressive conditional heteroskedasticity*), ou modelo GARCH(p, q). Desde a concepção do modelo ARCH, este sofreu variações, e sua generalização (GARCH) passou a ser extensamente utilizada na literatura. O modelo GARCH mais simples é GARCH(1, 1), dado pela equação (III.19):

$$\sigma_t^2 = \alpha_0 + \alpha_1 u_{t-1}^2 + \alpha_2 \sigma_{t-1}^2 \quad (\text{III.19}).$$

Este modelo mostra que a variância condicional de u^2 no período t depende do termo de erro quadrático e de sua variância condicional σ^2 , ambos no período de tempo anterior (t-1). Pode ser generalizado para um modelo GARCH(p, q), com p termos defasados do termo de erro quadrático e q termos das variâncias condicionais defasadas (Bollerslev, 1986); Zakoian, 1994).

O modelo GARCH é compatível com análises de séries de retornos financeiros, apresentando disponibilidade de previsões úteis para a volatilidade (Nelson, 1991; Zakoian, 1994; Reher & Wilfling, 2011). Carvalho *et al.* (2022) acrescentam que a soma dos coeficientes estimados do modelo GARCH determina as dinâmicas de curto prazo da série temporal em função de sua volatilidade. Nesse sentido, os autores esclarecem que, para soma de valor baixo, há indicativo de um choque inicial sobre a volatilidade, com efeitos rápidos sob o comportamento da série; caso o valor da soma seja alto e próximo de 1, o choque sobre a volatilidade demora mais tempo para se dissipar.

Para verificar se um modelo GARCH está corretamente especificado, a suposição da sua normalidade pode ser explorada por meio dos testes de Shapiro-Wilk e de Jarque-Bera, que sugerem também que os resíduos padronizados são normais e próximos de uma distribuição independente e identicamente distribuída — i.i.d.. No estudo de Martins *et al.* (2021), foram feitos testes de estacionariedade das séries da volatilidade estimada pelo modelo GARCH, a partir de dados do IBOVESPA, utilizando os testes de Dickey-Fuller Aumentado, teste de raiz unitária de Phillips-Perron e teste Kwiatkowski-Phillips-Schmidt-Shin (KPSS).

As propriedades de FAC e FACP relacionadas aos modelos ARCH e GARCH são apresentadas no Quadro III.2, para fins de referência na avaliação do melhor modelo ajustado para cada série temporal analisada.

Quadro III.2 – Padrões de FAC e FACP para modelos ARCH e GARCH

Modelo	Padrão da FAC	Padrão da FACP
ARCH(p)	Decaimento exponencial tendendo ao infinito	Picos significativos até p defasagens
GARCH(0, q)	Picos significativos até q defasagens	Decaimento exponencial tendendo ao infinito
GARCH(p, q)	Decaimento exponencial tendendo ao infinito, com corte em p	Decaimento exponencial tendendo ao infinito, com corte em q

Elaborado pela autora.

Os modelos ARCH e GARCH supõem que os impactos de choques aleatórios são simétricos, uma vez que a volatilidade é uma função quadrática desses. Zakoian (1994) afirma que a especificação quadrática usada para a variância condicional tem duas propriedades convenientes: (i) a simplicidade das restrições de parâmetros implícitas na positividade da variância e (ii) o fato de que ela fornece uma representação ARMA, sendo um modelo facilmente controlado.

Entretanto, na prática, os choques no retorno de ações são assimétricos, uma vez que aqueles negativos são seguidos por maiores aumentos na volatilidade do que os positivos. Dessa forma, pesquisadores propuseram outros modelos que captassem essa assimetria dos choques, como EGARCH e TGARCH (Carvalho *et al.*, 2022). Conte e Ceretta (2022) corroboram tal proposta, afirmando que estudos com modelos derivados do GARCH, como EGARCH, TGARCH e o GJR-GARCH consideram assimetrias e choques de volatilidade.

Modelo EGARCH

Nelson (1991) introduziu o modelo EGARCH (*Exponential generalized autoregressive conditional heteroscedastic*), que captura o efeito de alavancagem, em que choques negativos têm um impacto maior na volatilidade do que os positivos de mesma magnitude, sem qualquer restrição paramétrica. No modelo EGARCH, expresso pela equação (III.20), a variância condicionada, σ_t^2 , é uma função assimétrica dos valores passados de μ_{t-i} , ou seja:

$$\ln \sigma_t^2 = \alpha_0 + \sum_{i=1}^p \beta_i \ln \sigma_{t-1}^2 + \sum_{i=1}^p \alpha_i \left(\frac{|\mu_{t-i}|}{\sigma_{t-i}} \right) + \sum_{i=1}^p \gamma_i \left(\frac{|\mu_{t-i}|}{\sigma_{t-i}} \right) \quad (\text{III.20})$$

em que α_0 é constante, $\beta_i, \alpha_i, \gamma_i$ são os parâmetros do modelo, μ_{t-i} é o erro observado em t-i, e σ_{t-i} é o desvio-padrão observado em t-i. O parâmetro γ refere-se à assimetria das volatilidades e tem as seguintes premissas: $\gamma < 0$: um choque negativo aumentaria a volatilidade; $\gamma > 0$: um choque positivo diminuiria a volatilidade; e $\gamma = 0$: um choque positivo teria um efeito semelhante na volatilidade ao de um choque negativo de mesma amplitude (Nelson, 1991).

Dessa forma, o modelo EGARCH garante que a variância será sempre positiva, por ser apresentada em logaritmos, sendo particularmente útil na análise de séries temporais financeiras, em que choques negativos tendem a ter um impacto mais forte na volatilidade. No

entanto, tem a desvantagem de não permitir a estimativa da variância futura esperada para além de um período. Carvalho *et al.* (2022) declaram que o modelo EGARCH apresentou uma outra inovação aos modelos de volatilidade, com a condição de choques na variância terem efeito exponencial, e não quadrático.

Modelo TGARCH

O modelo TGARCH (*Threshold generalized autoregressive conditional heteroscedastic*), proposto por Zakoian (1994), incorpora uma variável limite adicional que afeta a dinâmica da volatilidade, permitindo diferentes comportamentos de volatilidade em diferentes regimes ou condições de mercado. Dessa forma, em períodos de alta incerteza ou instabilidade econômica, esse modelo pode capturar o aumento da volatilidade com mais eficiência, captando o efeito alavancagem, no qual choques positivos e negativos no mercado causam efeitos distintos sobre a volatilidade (Carvalho *et al.*, 2022).

A equação (III.21) ilustra o modelo TGARCH:

$$\sigma_t^2 = \alpha_0 + \sum_{i=1}^p \alpha_i \mu_{t-i}^2 + \sum_{j=1}^p \beta_j \sigma_{t-j}^2 + \sum_{k=1}^r \partial_{t-k} \gamma_k \mu_{t-k}^2 \quad (\text{III.21})$$

em que ∂_{t-k} é uma variável *dummy* assumindo o valor 1 se $\mu_t > 0$ (boa notícia do mercado), e 0 se $\mu_t \leq 0$ (má notícia). Se $\gamma > 0$ for estatisticamente significativo, ocorre o efeito alavancagem (*leverage effect*); se $\gamma \neq 0$ é estatisticamente significativo, a volatilidade é assimétrica; se $\gamma = 0$ é estatisticamente significativo, não há simetria (Carvalho *et al.*, 2022).

Zakoian (1994) aponta algumas diferenças entre EGARCH e TGARCH, como o fato de o modelo TGARCH proporcionar uma modelagem aditiva e tornar a volatilidade uma função das inovações (não normalizadas); ademais, o EGARCH impõe uma estrutura constante em todas as defasagens, enquanto, no TGARCH, diferentes defasagens podem gerar contribuições opostas no que diz respeito à assimetria. A modelagem EGARCH implica uma equação ARMA para o processo $\ln \sigma_t^2$ (eq. 20), facilitando o estudo probabilístico; porém, não fornece nenhuma equação linear em qualquer função de μ_{t-i} (eq. 20). Como consequência, a inferência de mínimos quadrados em duas etapas não é possível no contexto EGARCH exponencial, enquanto o TGARCH preserva essa característica do modelo GARCH clássico (Zakoian, 1994).

III.3 Metodologia

III.3.1 Delimitação da pesquisa, população e amostra

Esta pesquisa tem abordagem descritiva e quantitativa. Assim como a metodologia aplicada na investigação do primeiro objetivo específico no Capítulo II desta tese, aqui também foram analisados dados secundários numéricos, relacionados à volatilidade dos preços das

ações das empresas da B3. A análise quantitativa envolveu o período entre 07/01/2020 a 14/05/2020, abordando (aproximadamente) 60 dias anteriores e 60 dias posteriores a março/2020, quando se deu o início da pandemia da Covid-19.

População e amostra

O desenvolvimento desta pesquisa está embasado nos dados dos preços diários das ações das empresas listadas na B3, coletados no site YahooFinance. Foram excluídas empresas pertencentes ao setor de serviços financeiros, por se tratarem de organizações cuja atividade-fim é a regulação/administração do capital financeiro, portanto, diferindo dos demais setores econômicos em relação à legislação e aos dados publicados.

III.3.2 Coleta dos dados

As empresas da amostra foram categorizadas segundo o setor de atividade, sendo constituída por 221 empresas da B3 analisadas Capítulo II, agrupadas nos mesmos 10 setores de acordo com o *TRBC Economic Sector Name*, contudo, com quantidades diferentes de empresas por setor, em função da redução do tamanho amostral, devido à ausência de alguns dados dos preços diários na base do YahooFinance (Tabela III.1).

Tabela III.1 – N.º de Empresas da B3 por Setor, para Análise de Volatilidade

Setor conforme TRBCR/Refinitiv	Pandemia Covid-19
Consumo Cíclico (<i>Consumer Cyclical</i> s)	49
Industrial (<i>Industrials</i>)	30
Demais Serviços (<i>Utilities</i>)	35
Consumo Não Cíclico (<i>Consumer Non-Cyclical</i> s)	25
Imobiliário (<i>Real Estate</i>)	26
Materiais Básicos (<i>Basic Materials</i>)	26
Tecnologia (<i>Technology</i>)	9
Saúde (<i>Healthcare</i>)	9
Energia (<i>Energy</i>)	8
Serviços Acadêmicos e Educacionais (<i>Academic & Educational Services</i>)	4

Fonte: Dados de pesquisa, a partir das informações do banco de dados do site YahooFinance.

Nota: A fim de evitar a influência de empresas individuais sobre o resultado da média geral de um setor específico, e garantir que todas possuem dados publicados, relativos aos períodos considerados nesta pesquisa, foram selecionadas as empresas com situação CVM ativa.

Notam-se que os dados coletados dos preços das ações foram aqueles classificados como “ajustados”, pois consideram alterações corporativas como *splits* (ou desdobramentos, quando a empresa aumenta o número de ações em circulação e reduz o preço a fim de manter o valor investido) e pagamento de dividendos, evitando distorções; com isso, melhoram a comparação ao longo do tempo, gerando resultados mais precisos, além de permitir a

identificação de tendências e padrões de mercado. Dessa forma, o uso dos preços ajustados aumenta a confiabilidade das análises de volatilidade bem como do retorno das ações.

III.3.3 Análise dos dados

Para testar H_2 , foram realizadas inicialmente análises com modelos autorregressivos da classe TGARCH e verificados os devidos ajustes às séries temporais dos preços de cada setor da B3. Conforme Carvalho *et al.* (2022), nesses períodos nos quais houve grande incerteza e insegurança econômica e financeira, o modelo TGARCH captura o aumento da volatilidade com o efeito alavancagem, gerado pelos choques positivos e negativos no mercado, causando efeitos distintos sobre a volatilidade das ações. Ademais, o TGARCH permite analisar a assimetria da volatilidade (Zakoian, 1994).

A metodologia de análise usada para a pesquisa deste capítulo foi suportada pelo uso do *software* de tratamento estatístico R. Os dados dos preços das ações foram buscados diretamente via Rstudio no site do YahooFinance.

III.4 Análise e discussão dos resultados

Inicialmente, foram realizados os tratamentos e modelagens das séries temporais dos preços das ações para todas as empresas da amostra, sem segmentação setorial. Posteriormente, foram feitas análises correspondentes a cada setor, para fins de comparação dos resultados encontrados. Como os processos de tratamento e modelagem foram semelhantes para cada série temporal de todos os setores, os procedimentos de pesquisa foram descritos detalhadamente para a série temporal total (sem segmentação setorial), enquanto, para os setores, foram descritos os resultados relevantes. Isso foi feito a fim de evitar a repetição descritiva dos procedimentos.

III.4.1 Preços na Covid -19 (sem segmentação setorial)

Os preços relativos ao período inicial da Covid-19 foram coletados via Rstudio do portal YahooFinance e transformados em uma série temporal. A série, avaliada diariamente entre 07/01/2020 e 14/05/2020 (exceto finais de semana), ficou, então, constituída por 220 empresas e 88 observações (preços das ações) para cada empresa, reunindo um total de 19.360 informações.

Em modelagens de séries temporais, as representações gráficas auxiliam fortemente a análise e compreensão dos fenômenos envolvidos na sua evolução. Dessa forma, além dos

resultados numéricos, foram apresentados, ao longo desta seção, os gráficos que ilustram os comportamentos de cada série temporal (ST) original e dos tratamentos nelas aplicados, e as análises correspondentes. Nesse sentido, a Figura III.4 apresenta os gráficos da ST original para a Covid-19, após os tratamentos supracitados, sua regressão linear e seu histograma.




Figura III.4^a – Série temporal original para Covid-19 entre 07/01/2020 e 14/05/2020.




Figura III.4b – Regressão linear ST Covid-19.




Figura III.4c – Histograma ST Covid-19

Figura III.4 – Série temporal para a Covid-19 original, regressão linear e histograma.
Fonte: dados de pesquisa.

A Figura III.4^a mostra um perfil irregular na série temporal sugerindo não estacionariedade, reforçada pela regressão (Figura III.4b) caracterizada pela parte central mais constante (baixa inclinação) e as extremidades explodindo, além do histograma (Figura III.4c) que não segue uma distribuição normal (gaussiana). Tal perfil sugere ainda que a série possui componentes de sazonalidade e efeitos aleatórios (ou resíduos), porém sem tendência (uma vez que não se observa comportamento de crescimento ou decrescimento).

Como a série original tinha alguns valores ausentes (“NA”), aplicou-se winsorização a 5% para retirada dos mesmos, além da exclusão de uma empresa com valores três vezes superiores aos maiores valores subsequentes, considerado um *outlier*. A série tratada ficou conforme a Figura III.5.




Figura III.5 – Série temporal para Covid-19 winsorizada a 5% à esquerda e sua regressão linear à direita.
Fonte: dados de pesquisa.

Para averiguar a presença de sazonalidade e efeitos aleatórios (ou resíduos), a série winsorizada foi decomposta pelo modelo aditivo e apresentada na Figura III.6. As componentes de sazonalidade (*seasonal*) e efeitos aleatórios (*random* ou resíduos) da série winsorizada (*observed*) são evidentes, porém a tendência (*trend*) não é aparente. Para proceder à modelagem autorregressiva, foi necessário tornar essa série estacionária, removendo a tendência e sazonalidade. Para isso, aplicou-se o logaritmo neperiano (natural), a fim de tornar a série mais estável (com menor variância dos preços ao longo do tempo). A Figura III.7 mostra o gráfico da transformação.

A observação da permanência de uma variância na série após a transformação logarítmica conduziu à sua diferenciação de 1^a ordem (ou 1^a diferença), aplicando-se novamente o logaritmo (a partir do 2º valor da série), para suavizar ainda mais a variância. Essa manipulação é conhecida como *log return*. A Figura III.8 apresenta o gráfico da 1^a diferença.




Figura III.6 – Decomposição da série temporal para Covid-19.
Fonte: dados de pesquisa.




Figura III.7 – Logaritmo neperiano da série temporal para Covid-19.
Fonte: dados de pesquisa.




Figura III.8 – 1ª Diferença (*log return*) da série temporal para Covid-19.
Fonte: dados de pesquisa.

Para remover a sazonalidade da série de preços, foi feita uma segunda diferenciação (ou diferenciação de 2ª ordem) sobre a 1ª diferença; nesse momento, a série sofreu um *overfitting*, ou seja, os dados sofreram uma transformação mais intensa, de forma que a estrutura original “se perdeu”, não permitindo generalizações como previsões de dados futuros. Dessa forma, o estágio de tratamento da série considerado para modelagem neste capítulo foi aquele obtido na Figura III.7, denominado “st_precoscovid_diff1”. No histograma da st_precoscovid_diff1, observou-se uma distribuição normal, característica de estacionariedade de uma série temporal (Figura III.9).




Figura III.9 – Histograma da st_precoscovid_diff1.
Fonte: dados de pesquisa.

Um outro aspecto relevante relacionado às séries temporais é a correlação entre uma observação atual e observações passadas da própria série, ou seja, as funções de autocorrelação (FAC) e autocorrelação parcial (PFAC). Os gráficos de ambas as funções foram então gerados, explicitando características de estacionariedade, que, no caso da FAC e PFAC (Figuras III.10ª e III.10c respectivamente), apresentaram média zero, com a maioria dos valores dentro do intervalo de confiança (IC) de 95% e alguns *lags* (período de tempo entre as observações) fora desse intervalo. A Figura III.10b mostra a dispersão da FAC, confirmando sua estacionariedade. Os valores da FAC e PFAC encontram-se nos Apêndices III.A e III.B ao final deste capítulo.




Figura III.10^a – FAC para a série `st_precoscovid_diff1`.
Fonte: dados de pesquisa.




Figura III.10b – Dispersão da FAC para a série `st_precoscovid_diff1`.
Fonte: dados de pesquisa.




Figura III.10c – PFAC para a série `st_precoscovid_diff1`.
Fonte: dados de pesquisa.

Os perfis da FAC e da PFAC da série `st_precoscovid_diff1` apresentam semelhança de comportamento a de um ruído branco. Assim, foi calculado o quadrado de `st_precoscovid_diff1` e avaliadas novamente a FAC e a PFAC, para verificar a viabilidade de aplicação de um processo SARIMA à série. Os gráficos dessas funções são mostrados na Figura III.11, confirmando as características de estacionariedade e inexistência de autocorrelação fora do intervalo de confiança, seguindo um processo SARIMA.




Figura III.11 – FAC (esquerda) e PFAC (direita) para a série `st_precoscovid_diff1` ao quadrado.
Fonte: dados de pesquisa.

Ainda verificando a adequação do modelo SARIMA à `st_precoscovid_diff1`, foram mensurados os erros do ajuste, obtendo um erro médio de previsão de $-7,18 \times 10^{-7}$ próximo de zero, sugerindo que o modelo previu corretamente a série. O erro quadrático médio de 0,092 indicou um bom desempenho do modelo por estar também próximo de zero, e a autocorrelação da primeira defasagem dos resíduos foi de -0,031, considerada baixa.

Foi, por conseguinte, avaliada a ordem do modelo SARIMA (p, q, d) em que p, q e d são os parâmetros referentes, respectivamente, à ordem do modelo ou *lag* (p), ordem de diferenciação da série temporal (q) e ordem da média móvel (d). Para isso, foram identificados os primeiros *lags* mais significativos da PFAC da `st_precoscovid_diff1`, ou seja, aqueles que extrapolavam o intervalo de confiança, mas estavam mais próximos deste.

Esses valores de p podem ser considerados como ordens de defasagem (ou *lag*) para um modelo autorregressivo; foram considerados somente os primeiros *lags* para evitar artefatos que podem aparecer ao longo da função de autocorrelação. Comparando os gráficos da Figura III.12 e o Critério de informação de Akaike (AIC)⁵ gerados nos ajustes, concluiu-se que o processo SARIMA (0,1,0) teve o melhor ajuste por apresentar menor discrepância gráfica com a série e menor AIC (Tabela III.2).

⁵ O Critério de Informação de Akaike (AIC – *Akaike Information Criterion*) mensura a qualidade de um modelo estatístico por meio de uma métrica que compara e seleciona modelos, considerando menores valores de AIC representativos de maior qualidade e simplicidade do ajuste.




Figura III.12 – Sobreposição dos ajustes SARIMA (verde) à série *st_precoscovid_diff1* (azul).
Fonte: dados de pesquisa.

Tabela III.2 – Valores de AIC para os ajustes SARIMA de *st_precoscovid_diff1*

Ajuste	SARIMA (0,1,0)	SARIMA (1,1,0)	SARIMA (2,1,0)	SARIMA (4,1,0)
AIC	-18.983,8	-23.046,85	-24.668,49	-26.093,29

Fonte: dados de pesquisa.

Nota: O valor de AIC é considerado em módulo.

Na sequência, foram analisados os resíduos do processo SARIMA para verificar a qualidade do ajuste. Os resíduos deveriam assemelhar-se a um ruído branco. Assim, foram avaliadas a FAC e PFAC para os resíduos (Figura III.13), e ambas as funções apresentaram características de ruído branco, com poucos *lags* acima do IC na FAC e um decaimento exponencial na PFAC.




Figura III.13 – FAC (esquerda) e PFAC (direita) para os resíduos da série após ajuste SARIMA
Fonte: dados de pesquisa.

A condição de estacionariedade dos resíduos foi também analisada pelo teste de Dickey-Fuller Aumentado (ADF). O resultado teve um p-valor de 0,01, ou seja, menor que 5%, rejeitando-se, portanto, a hipótese nula de não estacionariedade, portanto, confirmando a hipótese alternativa de estacionariedade dos resíduos (Apêndice III.C).

Analisando o gráfico da Figura III.7, verificou-se a evidência de comportamentos oscilantes relativos a *clusters* (agrupamentos) na volatilidade dos preços no período considerado. Observou-se ainda que, em meados de março/2020, houve uma maior intensidade de *cluster*, correspondendo ao período em que a B3 sofreu as maiores volatilidades na pandemia da Covid-19, o que provocou os seis acionamentos consecutivos do *circuit breaker*.

Para verificar se o processo SARIMA foi suficiente para capturar a autocorrelação presente na série, verificou-se se ainda existia autocorrelação nos resíduos. Para isso, aplicou-se o teste de Breusch-Godfrey, considerando as quatro primeiras defasagens. O resultado do teste foi de 0,34 com p-valor de 0,98, indicando que o teste não foi estatisticamente significativo e, portanto, não se pôde rejeitar a hipótese nula de inexistência de autocorrelação serial; assim, não houve evidência de autocorrelação nos resíduos do processo SARIMA, confirmando mais uma vez a adequação desse ajuste à série temporal.

Após o ajuste ao processo SARIMA, a série `st_precoscovid_diff1` passou pela modelagem TGARCH. Uma análise inicial dessa modelagem foi a comparação entre a volatilidade condicional (ou desvio-padrão) da série dos preços com seus retornos absolutos, examinando-se como a variância mudou no tempo em função do ambiente em que o mercado se encontrava. O gráfico da Figura III.14 sugeriu que o modelo TGARCH captura os movimentos bruscos do mercado, com o aumento significativo da volatilidade em resposta à Covid-19. Isso aconteceu porque, caso a volatilidade permanecesse relativamente estável em relação aos retornos absolutos, o gráfico seria mais estável.




Figura III.14 – Volatilidades X Retornos da `st_precoscovid_diff1` no modelo TGARCH.
Fonte: dados de pesquisa.

A Figura III.15 apresenta a FAC e o quadrado da FAC da série modelada pelo TGARCH, mostrando que não existem autocorrelações expressivas fora do intervalo de confiança, bem como os quadrados das observações revelam que a volatilidade exibe um padrão de persistência ao longo do período analisado, mudando em resposta ao evento da Covid-19 no início de 2020.




Figura III.15 – FAC (esquerda) e FAC ao quadrado (direita) para o modelo TGARCH da *st_precoscovid_diff1*.
Fonte: dados de pesquisa.

Na modelagem TGARCH, o gráfico QQ-Plot dos resíduos padronizados (Figura III.16) permitiu comparar a distribuição dos preços da *st_precoscovid_diff1* com uma distribuição teórica, como a normal. Idealmente, se os resíduos padronizados seguem uma distribuição normal, os pontos no QQ-plot seguirão aproximadamente uma linha reta, sugerindo que o modelo captura completamente a estrutura dos dados. Nesse aspecto, o modelo TGARCH também mostrou ser adequado à série *st_precoscovid_diff1*.




Figura III.16 – Resíduos padronizados para o modelo TGARCH da *st_precoscovid_diff1*.
Fonte: dados de pesquisa.

Um outro aspecto analisado no modelo TGARCH para a série de preços das ações da B3 no início da pandemia foi a curva de impacto de notícias (Figura III.17), que representa o

modo como as notícias e informações sobre o evento da Covid-19 impactaram a volatilidade condicional desses preços no período entre janeiro e maio de 2020. O modelo TGARCH incorporou variáveis indicadoras de eventos que influenciam a volatilidade de uma série temporal. Examinando os coeficientes dessas variáveis, é possível quantificar o impacto desses eventos na volatilidade condicional, ajudando a compreender como diferentes eventos afetam a volatilidade do mercado, além de identificar períodos de alta ou baixa volatilidade.




Figura III.17 – Curva de impacto de notícias para o modelo TGARCH da st_precoscovid_diff1.
Fonte: dados de pesquisa.

A Figura III.17 indica que a volatilidade dos preços da B3 variou durante o período analisado, sofrendo uma queda relevante, seguida de um aumento igualmente relevante. Os parâmetros avaliados para o modelo TGARCH estão na Tabela III.3.

Tabela III.3 – Parâmetros do Modelo TGARCH para a série st_precoscovid_diff1

	Média dos Preços	ar1	ômega	alpha1	beta1
	- 0,000064 ¹	- 0,007256 ¹	0,000007 ¹	0,050006 ¹	0,901305 ¹
Desvio-Padrão	0,000000	0,000002	0,000000	0,000014	0,000174
Estatística t	- 3547,04	- 3547,23	38,37	3488,57	5190,90

Fonte: dados de pesquisa.

Nota: ¹p-valor = 0

Na Tabela III.3, os valores das estatísticas t de todos os parâmetros são significativamente diferentes de zero, sendo esta significância mais alta para a média, o ar1, alpha 1 e beta 1. O parâmetro ar1 é o coeficiente de autorregressão de primeira ordem (AR(1)) na equação que modela a volatilidade condicional dos preços a partir de valores passados e indica uma dependência serial da volatilidade condicional, ou seja, que os preços passados poderiam ter influenciado a volatilidade da série considerada.

O parâmetro ω é a constante de ARCH e representa a variância condicional constante; α_1 é o termo autorregressivo condicional à variância que modela a dependência serial na volatilidade condicional dos preços; β_1 representa a persistência GARCH da volatilidade condicional. Por fim, o valor da verossimilhança logarítmica do modelo foi de 6.001,97, sugerindo um ajuste adequado à série temporal analisada. Entretanto, o p-valor zero para todos os parâmetros indicou ausência de significância estatística, e, portanto, não se pode afirmar que a modelagem TGARCH foi adequada à série temporal em análise.

Outra forma de averiguar a adequação do modelo TGARCH foi por meio da aplicação do teste ARCH - LM (*Autoregressive Conditional Heteroskedasticity – Lagrange Multiplier*) aos seus resíduos. A hipótese nula do teste ARCH-LM é a inexistência de autocorrelação nas variâncias dos resíduos do modelo, ou seja, ausência de heterocedasticidade condicional. A Tabela III.4 apresenta os resultados do teste.

Tabela III.4- Teste ARCH-LM para os resíduos do Modelo TGARCH

N.º de observações	Estatística t	Estatística F	Teste ARCH-LM
13.546	9,93***	19,46***	19,44***

Fonte: dados de pesquisa.

Nota: p-valor: *** 0,001; ** 0,01; * 0,05; “.” 0,1.

Na Tabela III.4, nota-se que o teste ARCH – LM foi estatisticamente significativo, não rejeitando, portanto, a hipótese nula. Dessa forma, as variâncias dos resíduos não foram influenciadas por seus valores passados (não estão autocorrelacionadas), e, portanto, o modelo TGARCH não conseguiu capturar o evento da crise da Covid-19. Um último teste realizado foi de convergência do modelo TGARCH à série `st_precoscovid_diff1`, e o resultado foi zero, indicando ausência de convergência. Essas estatísticas do modelo TGARCH justificaram a mudança para outro modelo autorregressivo nas análises pretendidas neste capítulo.

Optou-se pelo uso de um modelo mais simples, o GARCH padrão, para verificar sua adequação à série temporal dos preços da B3 no início da Covid-19. Para tal, foi necessário verificar as estatísticas específicas da modelagem GARCH (Tabela III.5), uma vez que os mesmos testes e, consequentemente, os mesmos resultados para a modelagem TGARCH foram válidos para o modelo GARCH, ambos fundamentados no processo SARIMA. Na Tabela III.5 o parâmetro “Persistência” diz respeito à persistência na volatilidade condicional, cujo valor máximo é 1; o valor de 0,9 indicou uma forte persistência, sugerindo que as mudanças na volatilidade observadas no período tenderam a persistir por um tempo relativamente longo. Se a volatilidade aumentou no início da pandemia, seria mais provável que permanecesse alta nos

períodos subsequentes. A persistência alta pode sugerir ainda que eventos extremos de volatilidade podem ocorrer em *clusters*, o que foi detectado na Figura III.7.

Tabela III.5 – Estatísticas do Modelo GARCH

Ordem do modelo	N.º de observações	Persistência	ômega	alpha1	beta1
GARCH (1,1)	13.551	0,9	0,003***	$1,0 \times 10^{-8}$	0,6***

Fonte: dados de pesquisa.

Nota: p-valor: *** 0,001; ** 0,01; * 0,05; “.” 0,1.

Uma análise inicial da modelagem GARCH pela comparação entre a volatilidade condicional (ou desvio-padrão) da série dos preços com seus retornos absolutos foi feita como no modelo TGARCH, examinando-se a alteração da variância no tempo. A Figura III.18 sugeriu que o modelo GARCH não capturou os movimentos bruscos do mercado em resposta à Covid-19, uma vez que foi observada baixa variabilidade da volatilidade em relação aos retornos absolutos.




Figura III.18 – Volatilidades X Retornos da *st_precoscovid_diff1* no modelo GARCH.

Fonte: dados de pesquisa.

A Figura III.19 apresenta a FAC e o quadrado da FAC da série modelada pelo GARCH, mostrando a inexistência de autocorrelações expressivas fora do intervalo de confiança, assim como acontece com os quadrados das observações.




Figura III.19 – FAC (esquerda) e FAC ao quadrado (direita) para o modelo GARCH da *st_precoscovid_diff1*.

Fonte: dados de pesquisa.

Na modelagem GARCH, o gráfico QQ-Plot dos resíduos padronizados (Figura III.20) sugeriu que o modelo capturou completamente a estrutura dos dados, mostrando-se adequado à série `st_precoscovid_diff1`.




Figura III.20 – Resíduos padronizados para o modelo GARCH da `st_precoscovid_diff1`.
Fonte: dados de pesquisa.

O teste de convergência do modelo GARCH à série `st_precoscovid_diff1` deu como resultado o valor 1, indicando que o ajuste por este modelo convergiu e que as estimativas dos parâmetros foram confiáveis. Entretanto, tal resultado não era suficiente para atestar a qualidade do modelo, sendo necessárias outras análises. Para esse fim, a Tabela III.6 apresenta a verossimilhança e os testes dos resíduos Jarque-Bera, Ljung-Box, ARCH-LM bem como o valor de AIC.

Tabela III.6 – Testes estatísticos para modelo GARCH

Verossimilhança	Jarque-Bera	Ljung-Box, 10 defasagens	ARCH-LM	AIC
14.310,4	17989292	1,6	1,9	-2,1

Fonte: dados de pesquisa.

A verossimilhança do modelo GARCH sugeriu um ajuste adequado à série temporal analisada. Entretanto, o p-valor zero para o teste de Jarque-Bera indicou que os resíduos do modelo não seguem uma distribuição normal. Ademais, o p-valor zero para o teste de Ljung-Box apontou inexistência de autocorrelação significativa nos resíduos até 10 defasagens. Entretanto, o teste ARCH-LM não teve significância estatística, sugerindo que sua hipótese nula pode ser rejeitada, ou seja, pôde-se considerar a existência de heterocedasticidade condicional no modelo GARCH ou de autocorrelação nas variâncias dos seus resíduos. O baixo valor de AIC também sugeriu um ajuste adequado desse modelo à série `st_precoscovid_diff1`.

Tendo em vista que o teste de Ljung-Box é utilizado para avaliar a autocorrelação dos resíduos em várias defasagens, e que o processo SARIMA e o próprio modelo GARCH são mais eficientes para previsões nas defasagens iniciais, o resultado obtido era esperado, conforme avaliado anteriormente no processo SARIMA, no qual defasagens de 3ª e 4ª ordens já demonstravam um ajuste ruim à série. Esse teste pode ser desconsiderado, e considerando os demais resultados obtidos na Tabela III.6, deu-se sequência às análises sob a premissa de que o modelo GARCH teve um melhor ajuste à série *st_precoscovid_diff1* que o modelo TGARCH.

Para analisar o desempenho de previsão do modelo GARCH, foram considerados os preços da *st_precoscovid_diff1* até 08/03/2020 (um dia antes do 1º acionamento do *circuit breaker*), para treinar (calibrar) a série, de forma que os valores dos preços seguintes fossem previstos a partir desse treino. Tal porção de treino da série, denominada a partir de agora de “calibração covid”, passou pelos mesmos tratamentos que a série original até o 1º logaritmo. A Figura III.21 mostra a porção da “calibração covid”.




Figura III.21 – “Calibração covid” em amarelo.

Fonte: dados de pesquisa.

A série “calibração covid” também foi tornada estacionária e seguiu o comportamento de um ruído branco. Estimou-se a previsão da série relativa ao período entre 09/03/2020 e 18/03/2020. A Figura III.22 mostra o gráfico da previsão dos 30% dos valores finais da série.




Figura III.22 – “Previsão-covid” em azul.

Fonte: dados de pesquisa.

Após a diferenciação de 1ª ordem da porção da série “calibração covid” para remoção do efeito sazonal, foram avaliados o perfil normal da curva e as funções de FAC e PFAC, observando-se características de estacionariedade nessa porção transformada. Esta foi, então, ajustada pelo processo SARIMA, e os testes da ordem do ajuste apresentaram melhores resultados para SARIMA (1,1,1). Os resíduos desse ajuste estão mostrados na Figura III.23.




Figura III.23 – Perfil dos resíduos: a) Ajuste SARIMA (1,1,1); b) Qqplot e regressão linear; c) FAC; d) PFAC.
Fonte: dados de pesquisa.

Observa-se na Figura III.23^a) que o processo SARIMA (1,1,1) capturou o período de maior oscilação da volatilidade dos preços da B3 em meados de março/2020 (parte central do gráfico). Após o ajuste, foi feita a previsão dos preços da série temporal pela modelagem GARCH, para a qual foram testados intervalos de tempo entre 1 e 30 dias. Ao final desses testes, previsões entre 7 e 10 dias à frente do último dado da parte de calibração da série apresentaram resultados melhor ajustados ao modelo. A Tabela III.8 mostra os resultados para a previsão de 7 dias; e a Figura III.24, os gráficos para previsões de 4, 7 e 10 dias, para efeitos de comparação. A partir do 15º dia, o modelo não conseguiu fazer previsões.

Os termos “Média Móvel”, “Sazonalidade Autorregressiva” e “Média Móvel Sazonal” representam os coeficientes da regressão do modelo. A média móvel foi considerada baixa, descrevendo uma relação fraca entre um preço atual e um ou mais erros de previsão anteriores. Ela foi inferior (em módulo) à média móvel sazonal, indicando a presença de sazonalidade dos

preços; e a sazonalidade autorregressiva, que captura padrões sazonais entre preços atuais e anteriores, sinalizou influência moderada ou baixa da sazonalidade nos preços, em relação às médias móveis.

Tabela III.7 – Resultados da previsão do Modelo GARCH após o ajuste SARIMA (1,1,1)

Média Móvel	Sazonalidade Autorregressiva	Média Móvel Sazonal	Erro Médio	Erro Médio Quadrático	Autocorrelação
-0,015 ¹	-9 e-4 ¹	-1 ¹	-1,2 e-4	0,17	0,0021

Fonte: dados de pesquisa.

Nota: ¹ = erro padrão $\leq 0,00$.

Ainda assim, o sinal negativo da sazonalidade autorregressiva indica uma relação inversa entre os preços nos períodos sazonais, ou seja, quando um valor é maior do que o esperado no período da Covid-19, seria mais provável que o próximo valor fosse menor do que o esperado, e vice-versa. Dessa forma, houve uma tendência para os preços oscilarem em direções opostas em relação à média no período considerado, sugerindo volatilidades com comportamentos opostos nos preços da B3.




Figura III.24 – Previsões GARCH: a) 7 dias; b) 4 dias; c) 10 dias.

Fonte: dados de pesquisa.

Em relação aos erros apresentados na Tabela III.8, os erros-padrão dos três coeficientes descritos anteriormente apontam para uma boa precisão das suas estimativas. O erro médio é a

média dos erros, em que um erro é a diferença entre o valor previsto e o valor real; o valor encontrado indica que as previsões, em média, estão corretas, porém persistiu um pequeno viés nas mesmas. O Erro Médio Quadrático (< 0) mensura a dispersão dos erros, sugerindo que o modelo de previsão GARCH teve um bom desempenho. Por fim, a autocorrelação da primeira defasagem (*lag*) dos resíduos do modelo, de 0,0021, mostrou que os resíduos ainda tinham alguma estrutura de autocorrelação, porém discreta.

III.4.2 Preços na Covid-19 (por setor de atividade)











Conforme relatado na subseção III.4.1, as análises dos preços das ações da B3 relativas à pandemia por segmentos de atividades foram apresentadas nesta subseção de forma mais sucinta, sendo apontados os principais resultados que permitiram a discussão apropriada ao objetivo deste capítulo. Ademais, foram considerados o mesmo tipo de ajuste SARIMA e a modelagem GARCH para as séries temporais de cada setor, uma vez que constituíram partes da série original, gerando a expectativa de comportamentos similares nesses dois aspectos. Além das análises comparativas dos comportamentos dos preços entre os setores, foram comparados também os resultados da série original da Covid-19 (subseção anterior) com aqueles dos setores.

Os preços relativos a cada setor geraram dez séries temporais com diferentes dimensões, considerando o mesmo período de aquisição dos dados, semelhantes àquele da série “total”. Os números de observações e de empresas por setor são apresentados na Tabela III.8, e os gráficos de cada setor anteriormente aos tratamentos aplicados para o ajuste SARIMA e a modelagem GARCH encontram-se representados na Figura III.25.

Tabela III.8 – Setores de Atividades no Período Inicial da Covid-19

Setor	Empresas	Observações
Consumo Cíclico	49	2.728
Industrial	30	2.640
Demais Serviços	35	3.080
Consumo Não Cíclico	25	2.200
Imobiliário	26	2.200
Materiais Básicos	26	2.289
Tecnologia	9	791
Saúde	9	792
Energia	8	704
Serviços Acadêmicos e Educacionais	4	352

Fonte: dados de pesquisa.






Figura III.25 – Séries temporais Covid-19 (esquerda) e seus Histogramas (direita).
Fonte: dados de pesquisa.

A partir da Figura III.25 e das decomposições das séries setoriais no Apêndice III.D, observam-se que os preços das empresas do setor de consumo cíclico apresentaram uma tendência de maior alta em meados de março/2020, coincidindo com as maiores quedas de preços na B3, enquanto os preços dos setores industrial e de demais serviços sofreram uma das maiores quedas no período analisado. O setor de consumo não cíclico apresentou variações menos heterogêneas dos preços de suas ações, desde o início de fevereiro/2020 até meados de maio/2020.

Para o setor imobiliário, a série temporal dos preços no início da Covid-19 demonstrou alta relevante em janeiro/2020 seguida de queda acentuada no final de fevereiro/2020, com aumento discreto no início de março/2020, mantendo o patamar de valores mais baixos a partir de então, pelo menos até 14/05/2020 quando se encerrou o período de análise (ver Figura III.25 e Apêndice III.D). O setor de materiais básicos apresentou a segunda maior baixa no período de análise, coincidindo com o período de acionamento dos *circuit breakers*.

Os preços do setor de tecnologia tiveram valores menores até meados de março/2020 quando começaram a subir, mantendo-se em patamares superiores àqueles anteriores (a partir de janeiro/2020). Mesmo com a tendência crescente durante o período analisado (Apêndice III.D), houve oscilações até maio/2020 que podem ter sido impactadas pela pandemia da Covid-19, quando a crise ainda causava temor e incertezas na economia e no mercado financeiro. Esse crescimento indicou que o setor, ao contrário dos demais, conseguiu ampliar positivamente seus preços no auge da pandemia, por meio do *e-commerce*, impulsionado pelos *lockdowns* que restringiram a mobilidade das pessoas, que fizeram uso massivo do comércio on-line logo nos primeiros meses da pandemia.

O setor de saúde, que envolve empresas fabricantes de produtos (insumos) e de serviços (clínicas), encontrava-se numa fase de queda de preços desde janeiro/2020 até março/2020 e, em abril/2020, teve uma alta expressiva, sofrendo novamente uma queda em maio/2020, porém em um patamar superior àquele do início do ano. Esse comportamento pode ter refletido o impacto da pandemia após sua declaração pela OMS, que levou ao aumento da demanda por produtos de proteção pessoal pela população e pelos serviços de saúde como hospitais, postos de saúde e clínicas. O mercado de energia teve seus maiores preços em fevereiro e março de 2020, sendo que, em meados de março, os preços ficaram no 3º maior patamar do período de estudo. O R não foi capaz de processar a decomposição da série, pois não foi observada sazonalidade.

O setor de serviços acadêmicos e educacionais apresentou uma alta de preços relevante em fevereiro/2020, seguida de queda até meados de março/2020 quando teve uma nova alta, superior a fevereiro, que se manteve até meados de abril/2020, quando entrou em queda novamente até meados de maio do mesmo ano. Esse comportamento demonstrou que a educação sofreu volatilidades “dentro e fora do pico” do início da pandemia, quando os *lockdowns* foram decretados pelas prefeituras brasileiras. Em virtude da crise econômica que começava a afetar a vida dos brasileiros assalariados e autônomos de baixa renda, muitos alunos abandonaram seus cursos por não conseguirem continuar pagando por sua educação. O R também não foi capaz de processar a decomposição dessa série pela ausência de sazonalidade.

Os histogramas da Figura III.25 indicam as frequências dos preços das ações entre janeiro e maio de 2020, apresentando comportamentos diversos entre os setores analisados. Dessa forma, para os setores de consumo cíclico e imobiliário, os preços permaneceram mais baixos no período de análise, com baixa frequência de valores mais altos, o que era esperado para estes setores em ambientes de crise econômica. Já os setores de consumo não cíclico e industrial tiveram uma distribuição de preços em uma faixa maior de valores, quando comparados com aqueles do consumo cíclico e imobiliário, com alguns picos de preços mais elevados (principalmente no setor de consumo não cíclico), sugerindo que a pandemia não teve impactos relevantes sobre esses mercados.

O setor de demais serviços também teve a maior concentração de preços mais baixos, demonstrando que esse mercado já estava em baixa antes da pandemia. Para os materiais básicos, o histograma indicou maior concentração de preços mais baixos, e uma frequência menor e mais equilibrada de valores mais altos ao longo do período analisado, incluindo poucos picos de preços mais elevados. Isso pode ser interpretado como uma reação menos intensa desse setor em relação à pandemia, ou seja, com baixa variabilidade dos preços no período crítico da crise (Apêndice III.D).


O histograma da tecnologia foi mais equilibrado que o de materiais básicos, com menos picos e preços distribuídos de modo mais uniforme, sugerindo um efeito positivo da pandemia sobre o mercado da tecnologia, uma vez que, enquanto outros setores sofriam quedas dos preços ou os mantiveram no mesmo patamar, o setor de tecnologia conseguiu manter seus preços no período, sem quedas relevantes. O setor de saúde teve a maioria de seus preços em níveis mais baixos, com alguns picos de valores mais altos, indicando que esse mercado teve algumas sinalizações de alta, em função do começo da crise quando ainda não se tinha clara a

necessidade do uso de produtos de proteção da saúde e da (ainda) baixa procura por serviços médicos.

No setor de energia, os preços das ações mantiveram-se em níveis variados de forma mais equilibrada, ou seja, os valores oscilaram de modo suave, sem variações abruptas. Esse perfil apontou uma maior estabilidade desse mercado durante os primeiros meses da pandemia, não se destacando efeitos relevantes dessa crise sobre seus preços. O mercado da educação teve comportamento mais similar ao da saúde, porém com preços mais equilibrados que aqueles da saúde, ou seja, mais distribuídos ao longo da faixa de valores atingidos entre o mínimo e o máximo.

Essa heterogeneidade das distribuições dos preços pode ter refletido o comportamento dos investidores frente às suas incertezas e inseguranças, às informações divulgadas sobre a pandemia e à natureza dinâmica dos mercados financeiros quando enfrentam um cenário de crise. Os gráficos na Figura III.25 mostram ainda que as séries setoriais não apresentaram estacionariedade e nem distribuição normal (ou gaussiana), necessitando tratamentos prévios às modelagens GARCH. Procedeu-se a estes (semelhantes à série total na subseção III.4.1), verificando os componentes de sazonalidade, tendência e dos resíduos.

Após tornar todas as séries setoriais estacionárias e transformadas até a 1ª diferença (1ª ordem) (Figura III.26), foram avaliadas as funções de autocorrelação (FAC) e autocorrelação parcial (PFAC) para cada setor. Ambas as funções apresentaram média zero, com a maioria dos valores dentro do intervalo de confiança (IC) de 95% e alguns *lags* fora do IC, para todos os setores estudados.






Figura III.26 – 1ª diferença das séries temporais setoriais da Covid-19.

Fonte: dados de pesquisa.

Na Figura III.26, observou-se que, nos setores de consumo cíclico, demais serviços e imobiliário, houve menor oscilação dos preços na metade do período analisado, coincidindo com meados de março/2020, quando a B3 sofreu as maiores volatilidades na pandemia. Isso sugere, juntamente ao gráfico da Figura III.25, que esses setores não sofreram impactos tão intensos no período quanto o conjunto das empresas analisadas na subseção III.4.1. Já o setor industrial sofreu as maiores oscilações em meados de março/2020, refletindo a maior volatilidade do período para a B3.

O setor de consumo não cíclico manteve variações durante os primeiros meses da pandemia, sendo mais intensas entre os meses de fevereiro e abril de 2020, sugerindo que não sofreram impactos específicos nos dias de maiores quedas da B3 em março/2020. O setor de materiais básicos foi um dos que teve menos picos de volatilidade no período analisado, porém demonstrou um pequeno *cluster* coincidindo com os acionamentos do *circuit breaker* pela B3 em março/2020; isso sugeriu o impacto da Covid-19 sobre os preços das ações desse setor.


As oscilações de volatilidade foram menos frequentes no setor de tecnologia, porém ocorreram maior número de *clusters* a partir do final de fevereiro até meados de março de 2020, desde quando os casos de Covid-19 estavam aumentando na China até a declaração da pandemia pela OMS. Após esse período, as oscilações dos preços reduziram de forma relevante, conforme observado no gráfico da Figura III.26. No mercado de saúde, os preços sofreram variações aproximadamente constantes até meados de março/2020, apresentando dois picos mais relevantes; a partir de então, os preços ficaram mais voláteis, entremeados com mais picos e vales relevantes e períodos com variações pouco relevantes em comparação com os comportamentos da vizinhança.

O gráfico do setor de energia na Figura III.26 evidenciou *clusters* de volatilidade dos preços durante todo o período da pesquisa; entretanto, observou-se que os menores *clusters* ocorreram na metade desse período, entre o final do mês de fevereiro e meados de março de 2020. Isso corrobora os resultados indicados nos gráficos da série na Figura III.25, em que o mercado de energia não sofreu quedas ou altas expressivas das ações no período mais crítico da bolsa, no início da pandemia, quando a B3 acionou seis vezes o *circuit breaker* na expectativa de controlar a volatilidade excessiva, entre a 1ª e a 2ª semana de março/2020.


O setor educacional apresentou quatro *clusters* de volatilidade mais expressivos, sendo um entre o final de janeiro e início de fevereiro de 2020, outro do início até meados de março/2020, um em abril/2020 e outro em maio/2020. Os dois primeiros *clusters* apresentaram, cada um, picos de alta de preços, e o terceiro evidenciou uma queda relevante, corroborando os resultados encontrados no gráfico da Figura III.25.

Os perfis da FAC e da PFAC dos setores apresentaram semelhança de comportamento a de um ruído branco. Foram, então, calculados os quadrados das séries e avaliadas novamente as funções FAC e a PFAC, para verificar a viabilidade do ajuste SARIMA a cada uma das séries. Os gráficos das FACs e PFACs são mostrados na Figura III.27, confirmando as características de estacionariedade e inexistência de autocorrelação fora do intervalo de confiança, seguindo um processo SARIMA. A exceção foi o setor de tecnologia para o qual tanto a FAC quanto a PFAC apresentaram dois *lags* (cada uma) fora do IC, porém, como se tratam de defasagens mais distantes do início da série, não impactariam, a princípio, as premissas para o ajuste SARIMA.


Consumo Cíclico




Industrial




Demais Serviços




Consumo Não Cíclico




Imobiliário




Materiais Básicos



Tecnologia



Saúde






Figura III.27 – FAC e PFAC dos quadrados das séries setoriais para Covid-19

Fonte: dados de pesquisa.

Para confirmar a adequação do ajuste SARIMA, foram mensurados os erros dos respectivos processos, obtendo-se os resultados apresentados na Tabela III.9.


Tabela III.9 – Erros dos ajustes SARIMA para os setores

Setor	Erro médio de previsão	Erro quadrático médio	Autocorrelação da 1ª defasagem (lag)
Consumo Cíclico	0,004	0,05	-0,002
Industrial	0,01	0,2	-0,003
Demais Serviços	0,003	0,04	-0,005
Consumo Não Cíclico	0,003	0,04	-0,005
Imobiliário	0,005	0,08	-0,004
Materiais Básicos	0,01	0,2	0,002
Tecnologia	0,03	0,4	0,02
Saúde	0,0009	0,01	-0,005
Energia	0,004	0,03	0,006
Serviços Acadêmicos e Educacionais	0,002	0,02	-0,008

Fonte: dados de pesquisa.

Para todos os setores, o erro médio de previsão foi próximo de zero, sugerindo que os respectivos ajustes previram corretamente as séries; esses resultados foram reforçados pelo erro quadrático médio, que também indicou um bom desempenho do processo SARIMA para todos os setores. As autocorrelações negativa ou positiva da primeira defasagem dos resíduos também foram consideradas irrelevantes para todos os setores.

As ordens dos ajustes SARIMA (p, q, d) para cada setor, identificando os primeiros *lags* (defasagens) mais significativos da PFAC das séries, foram obtidas pelas análises dos gráficos da Figura III.28 e os valores de AIC dos ajustes (Tabela III.10).






Figura III.28 – Sobreposição dos processos SARIMA (verde) às séries setoriais (azul).
Fonte: dados de pesquisa.

Tabela III.10 – Ordens dos processos SARIMA de cada setor, no início da Covid-19

Setor	Ordem SARIMA
Consumo Cíclico	SARIMA (1,1,0)
Industrial	SARIMA (1,1,0)
Demais Serviços	SARIMA (0,1,0)
Consumo Não Cíclico	SARIMA (0,1,0)
Imobiliário	SARIMA (1,1,0)
Materiais Básicos	SARIMA (1,1,1)
Tecnologia	SARIMA (8,1,0)
Saúde	SARIMA (0,1,0)
Energia	SARIMA (1,1,0)
Serviços Acadêmicos e Educacionais	SARIMA (0,1,0)

Fonte: dados de pesquisa.

Foram analisados posteriormente os resíduos dos processos SARIMA para verificar a qualidade dos ajustes, que é considerada adequada quando os resíduos se assemelham ao ruído branco. Para isso, foram avaliadas a FAC e PFAC para os resíduos de cada setor, com ambas as funções apresentando características de ruído branco para o consumo cíclico, industrial, imobiliário e de tecnologia com um ou poucos *lags* fora do IC na FAC, e um decaimento exponencial na PFAC (nota-se que, para o setor de tecnologia, o melhor ajuste foi para o *lag* 8).

Para os setores de demais serviços, consumo não cíclico, materiais básicos, saúde e educação, não foram identificadas defasagens significativas, implicando que nenhum dos valores das respectivas PFACs excedeu o limiar de significância. A ausência de defasagens significativas sugere que os resíduos ao quadrado são aleatórios e não evidenciam padrões de autocorrelação parcial. Isso pode ser interpretado como a série temporal tendo uma volatilidade pouco relevante ou mesmo inexistente, a ponto de a modelagem autorregressiva não se adaptar a ela. A condição de estacionariedade dos resíduos das séries setoriais foi também analisada pelo teste de Dickey-Fuller Aumentado (ADF), com os resultados mostrados na Tabela III.11.

Tabela III.11– Teste de Dickey-Fuller: estacionariedade setorial, no início da Covid-19

Setor	Teste de Dickey-Fuller
Consumo Cíclico	-14**
Industrial	-14**
Demais Serviços	-15**
Consumo Não Cíclico	-13**
Imobiliário	-13**
Materiais Básicos	-13**
Tecnologia	-7,4**
Saúde	-9,1**
Energia	-9,0**
Serviços Acadêmicos e Educacionais	-6,7**

Fonte: dados de pesquisa.

Nota: p-valor: *** 0,001; ** 0,01; * 0,05.

Para todos os setores os testes de Dickey-Fuller Aumentado foram estatisticamente significantes ao nível de 1%, rejeitando-se a hipótese nula de não estacionariedade, e, portanto, confirmando a estacionariedade dos resíduos (hipótese alternativa) para estas séries temporais ajustadas. Observou-se que, para os setores de tecnologia, saúde, energia e educação, os testes foram aproximadamente a metade dos valores dos demais setores, indicando que, nestas séries, os preços retornaram ao equilíbrio (convergiram para seus valores “rotineiros”) mais rapidamente que nos outros setores. Os valores negativos do teste de Dickey-Fuller para todos os setores evidenciaram uma cointegração entre essas séries temporais, ou seja, uma relação de equilíbrio no longo prazo, de forma que todos retornaram à estabilidade de mercado após o período crítico inicial da crise pandêmica.

Para verificar se o processo SARIMA foi suficiente para capturar a autocorrelação presente nas séries, investigou-se a presença de autocorrelação nos resíduos para cada setor. Para tanto, aplicou-se o teste de Breusch-Godfrey, considerando as quatro primeiras defasagens. Os resultados encontram-se na Tabela III.12. Os resultados do teste de Breusch-Godfrey para todos os setores não foram estatisticamente significantes, aceitando-se, por conseguinte, a hipótese nula de inexistência de autocorrelação serial nos resíduos das séries. Esses resultados apontaram para processos SARIMA sem correlações seriais, atendendo a premissas de independência dos erros e confirmando a adequação desses processos às séries temporais.

Para os setores de demais serviços, imobiliário e materiais básicos, o R não conseguiu calcular o teste. Neste último caso, considerou-se a possibilidade de multicolinearidade nos preços, indicando que alguns valores estavam altamente autocorrelacionados, prejudicando a previsibilidade da série. Isso pode ocasionar instabilidade dos coeficientes estimados para os respectivos modelos, e reduzir a precisão de suas estimativas, tornando-os pouco confiáveis.

Tabela III.12 – Teste de Breusch-Godfrey: autocorrelação setorial nos resíduos

Setor	Teste de Breusch-Godfrey
Consumo Cíclico	0,34
Industrial	0,48
Demais Serviços	-
Consumo Não Cíclico	6,9e-5
Imobiliário	-
Materiais Básicos	-
Tecnologia	1,8
Saúde	3,4
Energia	5,2
Serviços Acadêmicos e Educacionais	3,7e-6

Fonte: dados de pesquisa.

Nota: p-valor: *** 0,001; ** 0,01; * 0,05.

Para contornar a situação, seria indicado analisar estas séries via metodologia de análise exploratória para avaliar as correlações entre os preços e seus padrões, ou remover os preços que causaram correlação, ou utilizar técnicas de regularização, como Ridge (L2) ou LASSO (L1), ou transformar os preços via logaritmos, para reduzir a multicolinearidade. Nesta pesquisa, nenhum desses tratamentos foi aplicado, pois dispersariam o foco das análises.

As séries temporais setoriais foram modeladas utilizando-se o modelo GARCH, com as estatísticas estimadas para cada um dos modelos mostrados na Tabela III.13, e os testes dos resíduos (padronizados) na Tabela III.14. É importante lembrar que os resultados estimados para os setores imobiliário e de materiais básicos foram pouco confiáveis, conforme explanação anterior do teste de Breusch-Godfrey.

A modelagem GARCH mostrou-se adequada para as séries de preços dos setores de consumo cíclico, tecnologia e educação, comprovado pelos coeficientes ω , α_1 (para tecnologia) e β_1 estatisticamente significantes. Os demais setores não tiveram assegurada a confiabilidade dos modelos GARCH às respectivas séries de preços. A persistência de 0,9 sugeriu a existência de *clusters* de volatilidade, identificados na Figura III.26 para todos os setores; entretanto, para os setores de demais serviços e materiais básicos, suas persistências não foram consideradas confiáveis, uma vez que as modelagens não foram adequadas.

O teste de convergência das modelagens com valor 1 indicou que a estimação dos modelos convergiu, ou seja, os ajustes foram adequados, mesmo sem confiabilidade estatística em alguns. Para os setores de demais serviços, imobiliário e materiais básicos, as modelagens não foram capazes de mensurar as convergências, corroborando os resultados precedentes para esses setores.

Tabela III.13 – Estatísticas do Modelo GARCH para os setores de atividades

Setor	Ordem do modelo	Convergência	Persis-tência	ômega	alpha1	beta1
Consumo Cíclico	GARCH (1,1)	1	0,9	0,003***	1e-8	0,6***
Industrial	GARCH (1,1)	1	0,9	0,003	0,1	0,8
Demais Serviços	GARCH (0,1)	-	0,9	0,0002	0,1	0,8
Consumo Não Cíclico	GARCH (1,1)	1	0,9	0,0007	1e-8	0,5
Imobiliário	GARCH (1,1)	-	0,9	0,0006	0,1	0,8
Materiais Básicos	GARCH (1,1)	-	0,9	-2,1	-5e+106	-2e+107
Tecnologia	GARCH (8,1)	1	0,9	0,007***	1***	0,8***
Saúde	GARCH (1,1)	1	0,9	0,0001	1e-8	1e-8
Energia	GARCH (1,1)	1	0,9	0,0005	1e-8	0,3
Serviços Acadêmicos e Educacionais	GARCH (1,1)	1	0,9	2e-5***	1e-8	0,9***

Fonte: dados de pesquisa.

Nota: p-valor: *** 0,001; ** 0,01; * 0,05.

Tabela III.14 – Testes dos resíduos dos modelos GARCH, no início da Covid-19

Setor	Jarque-Bera	Ljung-Box (R^2 , 10 defasagens)	ARCH LM
Consumo Cíclico	179899292	20	2726
Industrial	-	-	36***
Demais Serviços	-	-	0,01
Consumo Não Cíclico	-	-	0,02
Imobiliário	-	-	0,3
Materiais Básicos	-	-	0,002
Tecnologia	3927673	1,6	0,3
Saúde	7424954	0,035	0,003
Energia	3175951	0,061	0,08
Serviços Acadêmicos e Educacionais	943208	0,055	0,07

Fonte: dados de pesquisa.


Nota: p-valor: *** 0,001; ** 0,01; * 0,05.

Na Tabela III.14, os testes dos resíduos de Jarque-Bera, de Ljung-Box e de ARCH LM para os setores de consumo cíclico, tecnologia, saúde, energia e educação não foram estatisticamente significantes, implicando que estas séries foram modeladas apropriadamente, na medida em que foi rejeitada a hipótese nula de não normalidade da distribuição dos preços (Jarque-Bera), de presença de autocorrelação serial (Ljung-Box) e da ausência de heterocedasticidade condicional nos resíduos da série (ARCH LM, em que a variância dos erros se mantém constante ao longo do tempo).

Para os setores industrial, de demais serviços, consumo não cíclico, imobiliário e de materiais básicos, o R não conseguiu avaliar os testes de Jarque-Bera e Ljung-Box. O resultado significativo do teste ARCH LM para o setor industrial sugeriu que seus preços possuíam heterocedasticidade nos resíduos da série, ou seja, a variância dos erros alterava-se ao longo do tempo. Quanto aos testes ARCH LM para os setores de demais serviços, consumo não cíclico,

imobiliário e de materiais básicos, não houve significância estatística, indicando inexistência de heterocedasticidade condicional nos resíduos das respectivas séries.

Para analisar as previsões dos modelos GARCH para cada setor de atividade no início da pandemia, foram considerados os preços até 08/03/2020 para treinar (calibrar) a série, assim como foi feito para a série “total” na subseção III.4.1. Para cada setor, essa porção de treino foi denominada “calibração covid”, sendo especificado o setor ao longo da discussão a seguir. As séries “calibração covid” também foram tornadas estacionárias, seguindo o comportamento de ruído branco. Procedeu-se também às suas previsões da série, denominadas “previsão covid”, e ambos os gráficos para cada setor são apresentados na Figura III.29.






Figura III.29 – “Calibração covid” (amarelo) e “previsão covid” (azul).

Fonte: dados de pesquisa.

Após a diferenciação de 1ª ordem da porção “calibração covid” para remoção do efeito sazonal, foram avaliados o perfil normal da curva e as funções de FAC e PFAC, observando-se características de estacionariedade. Com simulações de previsão de preços entre 1 e 30 dias à frente do último valor utilizado na parte de calibração, as previsões para cada setor foram identificadas a partir dos menores valores de AIC para cada ajuste. A Tabela III.15 apresenta os resultados para previsões de cada setor, e a Figura III.30 mostra os gráficos para previsões melhor ajustadas.

O modelo do setor de consumo cíclico apresentou uma previsão melhor ajustada para 15 dias, enquanto, para a indústria e consumo não cíclico, a previsão de 30 dias foi mais adequada, apesar de, no caso do consumo não cíclico, o modelo não ter conseguido mensurar as médias móvel (MM), a média móvel sazonal (MMS) nem a sazonalidade autorregressiva (SR). Para o setor de demais serviços, a previsão não foi estimada pelo fato de o modelo GARCH não ter sido adequado, o mesmo ocorrendo com a saúde e educação. Para o setor imobiliário, foi ajustada a previsão para 20 dias, lembrando que esta não pode ser considerada confiável devido à autocorrelação serial entre os preços da série.

Tabela III.15 – Previsões dos Modelos GARCH após os ajustes SARIMA, para os setores

Setor	Previsão	MM		SR	MMS	Erro Médio	Erro Médio Quadrático	Autocorrelação
Consumo Cíclico	15 dias	-0,1 ¹		0,006 ¹	-1 ¹	0,0004	0,1	0,02
Industrial	30 dias	-0,6 ¹		0,001 ¹	-1 ¹	0,0002	0,2	-0,02
Demais Serviços	-	-		-	-	-	-	-
Consumo Não Cíclico	30 dias	-		-	-	-	-	-
Imobiliário	20 dias	0,02 ¹		-0,5 ¹	-	-4e-5	0,2	0,005
Materiais Básicos	8 dias	-0,001 ¹		0,02 ¹	-1 ¹	0,002	0,1	-7e-5
Tecnologia	15 dias	-0,05 ¹	-0,1 ¹	-0,9 ¹	-0,8 ¹	-1 ¹	-0,0006	0,2
		-0,003 ¹	-0,03 ¹	-0,7 ¹	-0,6 ¹			
		-0,07 ¹	-0,07 ¹	-0,5 ¹	-0,4 ¹			
		-0,05 ¹	0,1 ¹	-0,2 ¹	-0,1 ¹			
Saúde	23 dias	-		-	-	-	-	-
Energia	23 dias	0,03 ¹		-0,5 ¹	-	-0,0005	0,1	-0,04
Serviços Acadêmicos e Educacionais	30 dias	-		-	-	-	-	-

Fonte: dados de pesquisa.

Nota: ¹ = erro padrão $\leq 0,00$.

O setor de materiais básicos ficou melhor ajustado para uma previsão de 8 dias, com a menor MM e menor autocorrelação serial entre os setores analisados. A MM foi baixa também para os setores de consumo cíclico e industrial, descrevendo uma relação fraca entre um preço atual e um ou mais erros de previsão anteriores. A MM do setor de consumo cíclico foi bem inferior (em módulo) à sua MMS, indicando a presença de sazonalidade dos preços; a SR, por sua vez, sinalizou uma influência inexpressiva nos preços do setor em relação às MM, podendo-se, dessa forma, concluir que a crise da Covid-19 teve pouco ou nenhum impacto sobre o mercado do consumo cíclico. A autocorrelação da primeira defasagem (*lag*) dos resíduos do modelo mostrou que eles tinham uma fraca correlação.

Sobre o setor industrial, houve maior proximidade entre a MM a MMS sugerindo uma sazonalidade mais evidente, enquanto a SR foi irrelevante, implicando baixa volatilidade condicional dos preços, ou seja, os valores passados não modelam os valores atuais. Isso pode ser observado no baixo valor da autocorrelação para o setor. Para os demais serviços, não foram feitas previsões em função da inadequação da modelagem para a série temporal, e, para o setor de consumo não cíclico, obteve-se uma previsão ruim em função do ajuste fraco.


Mesmo com a presença de autocorrelação entre os preços do setor imobiliário, sua MM foi mensurada sendo entre dez e trinta vezes inferior àquelas dos setores de consumo cíclico e industrial, indicando menor variabilidade dos preços em relação a esses setores, resultado

compatível com o encontrado na Figura III.26; por outro lado, a SR foi até dez vezes superior aos mesmos setores, também compatível com a Figura III.26, evidenciando *clusters* de volatilidade, sendo um indicativo de sazonalidade.

No setor de tecnologia, a melhor previsão foi de 15 dias, apresentando oito MMs e oito SRs condizentes com a ordem do seu modelo GARCH (8,1). As MMs foram bem inferiores (em módulo) à MMS, indicando sazonalidade dos preços da série; esse resultado foi corroborado pelas SRs que, em sua maioria, eram dez vezes superiores às MMs, sinalizando um impacto nos preços no período analisado, podendo-se concluir que a pandemia teve efeito sobre o setor da tecnologia. A autocorrelação da primeira defasagem (*lag*) dos resíduos apresentou fraca correlação entre os preços no período de análise.

No mercado de energia, a melhor previsão foi para 23 dias, tendo exibido uma MM baixa, evidenciando relação fraca entre um preço atual e preços anteriores. A SR indicou influência inexpressiva nos preços do setor, concluindo-se que a crise da Covid-19 teve pouco ou nenhum impacto sobre o setor energético. A autocorrelação da primeira defasagem (*lag*) dos resíduos do modelo confirmou sua fraca correlação.

Os erros padrão dos coeficientes da previsão estimados foram considerados desprezíveis, indicando boa precisão das estimativas para os respectivos setores. O valor do erro médio indicou que as previsões, em média, estavam corretas, e o erro quadrático médio sugeriu que modelo de previsão GARCH teve bom desempenho.






Figura III.30 – Previsões GARCH (azul).

Fonte: dados de pesquisa.

Os gráficos da Figura III.30 para as séries dos setores de consumo cíclico, industrial, imobiliário, materiais básicos, tecnologia e energia mostram previsões melhor ajustadas às séries, conforme apresentado na Tabela III.15. Para o setor de demais serviços, não houve previsão, e o gráfico correspondente na Figura III.30 mostrou coerência, com o traço linear, sem oscilações relacionadas à volatilidade dos preços. Para os mercados do consumo não cíclico, saúde e educação, as previsões não foram confiáveis.

III.5 Conclusões

Relembrando o objetivo deste capítulo, a saber, avaliar a volatilidade dos preços das ações das empresas da B3, em conjunto e por setor, nos primeiros meses da pandemia da Covid-19, a primeira conclusão foi que a série temporal original da Covid-19 (sem segmentação setorial) apresentou características de sazonalidade dos preços das ações, com vários *clusters*

ao longo do período analisado. Foi observado também que tais *clusters* se intensificaram em torno da metade do mês de março/2020, quando a B3 experienciou altas volatilidades, acionando o *circuit breaker*.

O processo SARIMA mostrou-se adequado à série temporal original da Covid-19, assim como a modelagem GARCH, ficando comprovado que a série não apresentou autocorrelação significativa entre seus preços. Isso sugeriu um grau de independência entre eles, reforçando a hipótese do efeito da pandemia sobre os mesmos, evidenciado pelos resultados obtidos. O estudo também mostrou que, ao contrário do esperado de acordo a literatura, o modelo TGARCH, teoricamente mais adequado a séries temporais submetidas a eventos anormais e que impactam temporariamente seu comportamento, mostrou-se, neste caso, menos adequado que o GARCH.

Os estudos de sazonalidade na série total da Covid-19 demonstraram que houve volatilidades em sentidos opostos na B3 no período considerado, evidenciando comportamentos anormais dos preços mediante o cenário de crise dentro do qual se encontrava. A partir desse comportamento, prosseguiu-se com a investigação setorial desses preços, a fim de averiguar se os impactos percebidos até esse ponto eram refletidos de modo homogêneo ou heterogêneo entre os setores da B3 (exceto financeiro).

Em meados de março/2020 quando a B3 passou pelas maiores volatilidades da pandemia em um curto intervalo de tempo, os setores de consumo cíclico apresentaram alta nos preços de suas ações, enquanto os setores industrial, de demais serviços e de materiais básicos atingiram os níveis mais baixos do período, acompanhando o comportamento da série total da Covid-19 (sem segmentação). O setor de consumo não cíclico indicou variações mais homogêneas em seus preços, com altas e baixas intercaladas, contrastando com o setor imobiliário que apresentou o comportamento mais estável entre todos os setores, expressando apenas alta relevante no mês de janeiro/2020.

Os mercados de tecnologia e saúde estavam em baixa até meados de março/2020, quando passaram a ter suas ações valorizadas, com os preços passando por altas expressivas até final de abril/2020, momento a partir do qual sofreram quedas importantes. Os setores de energia e educação também tiveram comportamentos similares, passando por elevações com pico mais largos, intercaladas com baixas desde janeiro/2020 até final de março/2020, quando tenderam à queda dos preços.

Todos os setores apresentaram *clusters* de volatilidade no período de análise, contudo, nos setores de tecnologia e saúde, esses *clusters* foram mais “espaçados”, e com maior

intensidade em meados de março/2020, quando apareceram os maiores picos e vales nos respectivos gráficos da 1ª diferença das séries. Isso sugeriu que eles sofreram impactos mais importantes da crise da Covid-19, apontando uma “sazonalidade” específica no pior momento da crise para a B3. Dessa forma, a hipótese de que a pandemia impactou de forma diferenciada os preços das ações das empresas dos setores da B3 foi confirmada, sendo os setores de tecnologia e saúde aqueles que evidenciaram efeitos mais expressivos.

Quanto à efetividade do *circuit breaker* como mecanismo de controle da volatilidade dos preços, não se pode concluir se ela aconteceu ou não, uma vez que as volatilidades dos setores foram diversificadas, não havendo identificação dos acionamentos com quedas das variações dos preços.

As principais limitações deste estudo foram a quantidade de dados para alguns setores como saúde e educação que restringiram algumas análises das respectivas séries temporais; a dificuldade de utilizar um mesmo modelo para ajustar séries temporais com comportamentos diferenciados, sendo necessário um volume elevado de análises para averiguar quais modelos da família ARCH seriam mais adequados para cada uma que não se adaptou ao modelo GARCH; e, por outro lado, o alto volume de dados de alguns setores que impediram a realização de testes estatísticos sobre as modelagens, os quais têm limite de dados que podem ser inseridos como *inputs* nos cálculos.

As contribuições dessa pesquisa centram-se no entendimento do comportamento dos preços do mercado acionário mediante uma crise que impactou todos os aspectos das sociedades (biológico, social, econômico etc.), e como a insegurança e a incerteza dos investidores podem impactar esse mercado de modo imprevisível, promovendo efeitos negativos ou positivos, a depender do setor de atividade envolvido. Teoricamente, houve uma contribuição “prática” para a comprovação da Teoria do Portfolio de Markowitz, ao se demonstrar que, mesmo em meio a uma crise impactante, é possível criar carteiras de ativos eficientes compreendendo-se as respostas das empresas aos desafios apresentados pela crise.

Em estudos futuros, será interessante investigar modelos que se ajustam melhor a cada setor e realizar análises comparativas para aprofundar a compreensão do comportamento do mercado acionário em ambientes de crise, principalmente no Brasil, onde estudos nesse sentido são ainda escassos.

Referências

- Ackert, L., Church, B., & Jayaraman, N. (2001). An Experimental Study of Circuit Breakers: The Effects of Mandated Market Closures and Temporary Halts on Market Behavior. *Journal of Financial Markets*, 4, p. 185-208.
- Ackert, L., Hao, J., & Hunter, W. (1997). The Effect of Circuit Breakers on Expected Volatility: Tests Using Implied Volatilities. *American Economic Journal*, 25(2), p. 117-127.
- Agência Brasil. Wellton Máximo. (2020). Copom reduz Selic para 3% ao ano para conter impacto de pandemia. Cortes nos EUA e queda da inflação abriram espaço para novo corte. Recuperado de: <https://agenciabrasil.ebc.com.br/economia/noticia/2020-05/copom-reduz-selic-para-325-ao-ano-para-conter-impacto-de-pandemia>.
- B3. B3 Aciona Circuit Breaker. 16/03/2020. Recuperado de: https://www.b3.com.br/pt_br/noticias/circuit-breaker.htm.
- Bartlett, M. S. (1946). On the theoretical specification of sampling properties of autocorrelated time series. *Journal of the Royal Statistical Society, SB*, 27, p. 27-41.
- Bollerslev, T. (1986). Generalized autoregressive conditional heteroskedasticity. *Journal of Econometrics*, 31, p. 307-327.
- Box, G. E. P., Pierce, D. A. (1970). Distribution of residual autocorrelations in autoregressive integrated moving Average time series models. *Journal of the American Statistical Association*, 65, p. 1509-1526.
- Carvalho, B. N., Silva, A. K. S., Lobato, T. C., & Figueiredo, A. M. (2022). Análise de volatilidade nos retornos dos preços spot e futuro do café arábica no período de 2007 a 2017. *Revista de Economia*, 43(81), p. 295-312. DOI: 10.5380/re.v43i81.76292.
- Carvalho, F., Vieira, L. V., Ribeiro, F. S., Cristina, K., & Wemerson, G. B. (2017). Os efeitos da alavancagem e feedback na volatilidade do mercado acionário brasileiro. *Enfoque: Reflexão Contábil*, 36(2), p. 19-37. Recuperado de: <https://www.redalyc.org/articulo.oa?id=307150906003>.
- Chan, K. F., Chen, Z., Wen, Y., & Xu, T. (2021). COVID-19 Vaccines: Saving Lives and the Global Stock Markets. *SSRN Journal*. DOI: 10.2139/ssrn.3785533.
- Chen, H., Petukhov, A., & Wang, J. (2017). The Dark Side of Circuit Breakers. *Working Paper*. Cambridge, MA: Massachusetts Institute of Technology.
- Conte, B. P., & Ceretta, P. S. (2022). Análise dinâmica de volatilidade para os setores do mercado acionário brasileiro: uma aplicação do modelo MRS-GARCH. *Revista de Administração, Contabilidade e Economia / RACE*, 21(1), p. 101-120. DOI: <https://doi.org/10.18593/race.20975>.
- Costa, D. M. (2017). Revisitando os clássicos da moderna teoria de finanças: uma análise. *Revista Brasileira de Administração Científica*, 8(2), p. 16-41.

Debastiani, C. A., & Russo, F. A. (2008). *Avaliando Empresas, Investindo em Ações: A Aplicação Prática da Análise Fundamentalista na Avaliação e Empresas*. Ed. Novatec.

Dickey, D. A.; Fuller, W. A. (1979). Distribution of the estimators for autoregressive time series with a unit root. *Journal of the American Statistical Association*, 74, p. 427-431.

Erdem, O. (2020). Freedom and Stock Market Performance During Covid-19 Outbreak. *Finance Research Letters*, 36:101671. DOI:10.1016/j.frl.2020.101671.

Engle, R. F. (1982). Autoregressive conditional heteroscedasticity with estimates of the variance of U.K. inflation. *Econometrica*, 50, p. 987-1007.

Goldstein, M. A., & Kavajecz, K. A. (2004). Trading Strategies During Circuit Breakers and Extreme Market Movements. *Journal of Financial Markets*, 7(3), p. 301-333.

Hong, H., Wang, N., & Yang, J. (2021). Implications of Stochastic Transmission Rates for Managing Pandemic Risks. *Review of Financial Studies*, 0(0), p. 1-42. Doi: 10.1093/rfs/hhaa132.

Jansen, W. J., & Nahujs, N. J. (2003). The Stock Market and Consumer Confidence: European evidence. *Economics Letters*, 79(1), 89-98.

Jian, Z., Zhu, Z., Zhou, J., & Wuc, S. (2020). Intraday Price Jumps, Market Liquidity, and the Magnet Effect of Circuit Breakers. *International Review of Economics and Finance*, 70, p. 168-186.

Keane, M., & Neal, T. (2021). Consumer Panic in the COVID-19 Pandemic. *Journal of Econometrics*, 220(1), p. 86-105.

Kim, Y., Yague, J., & Yang, J. (2004). Trading Halts or Price Limits: Which is Better? Recuperado de: <https://www.researchgate.net/publication/228916395>.

Kumari, J., & Mahakud, J. (2015). Does Investor Sentiment Predict the Asset Volatility? Evidence from Emerging Stock Market India. *Journal of Behavioral and Experimental Finance*, 8, 25-39.

Lera, S. C., Sornette, D., & Ulmann, F. (2019). Price Dynamics with Circuit Breakers. SSRN 3413247.

Ljung, G. M., Box, G. E. P. (1978). On a measure of lack of fit in time series models. *Biometrika*, 66, p. 66-72.

Maciel, L. (2021). A New Approach to Portfolio Management in the Brazilian Equity Market: Does Assets Efficiency Level Improve Performance? *The Quarterly Review of Economics and Finance*, 81, p. 38-56.

Markowitz, H. (1952). Portfolio Selection. *Journal of Finance*, 7(1), p. 77-91.

Markowitz, H. M. (1990). Foundations of Portfolio Theory. Baruch College, The City University of New York. New York. Nobel Lecture. P.279-287.

Martins, A. F. F., Bortolon, P. M., & Maia, V. M. (2021). Relação entre índice de volatilidade implícita e índice de retorno de ações. *Revista Contemporânea de Contabilidade*, 18(49), p. 73-91. DOI: <https://doi.org/10.5007/2175-8069.2021.e77707>.

Moreira, J. C. C., Nganga, C. S. N., & Telles, S. V. (2020). *Impacto da COVID-19 no Retorno das Ações do Mercado Brasileiro*. Anais XX USP International Conference in Accounting. São Paulo/SP.

Nelson, D. B. (1991). Conditional heteroskedasticity in asset returns: a new approach. *Econometrica*, 59(2), p. 347-370.

Oluwasegun, B. A., & Johnson A. O. (2022). Commodity and Financial Markets' Fear Before and During COVID-19 Pandemic: Persistence and Causality Analyses. *Resources Policy*, 76:102598. DOI: 10.1016/j.resourpol.2022.102598.

Otoo, M. W. (1999). Consumer Sentiment and the Stock Market. Recuperado de: <https://ssrn.com/abstract=205028> ou <http://dx.doi.org/10.2139/ssrn.205028>.

Reher, G., & Wilfing, B. (2011). Markov-Switching GARCH models in finance: a unifying framework with an application to the German stock market. [Masters dissertation, University of Münster, WWU, Germany].

Rizwan, M. S., Ahmad, G., & Ashraf, D. (2020). Systemic Risk: The Impact of COVID-19. *Finance Research Letters*, 36: 101682. DOI: 10.1016/j.frl.2020.101682.

Rouatbi, W., Demir, E., Kizys, R., & Zaremb, A. (2021). Immunizing Markets Against the Pandemic: COVID-19 Vaccinations and Stock Volatility Around the World. *International Review of Financial Analysis*, 77.

Salisu, A.A., & Vo, X.V. (2020). Predicting Stock Returns in the Presence of COVID-19 Pandemic: The Role of Health News. *International Review of Financial Analysis*, 71: 101546. Recuperado de: <https://doi.org/10.1016/j.irfa.2020.101546>.

Samanez, C. P. (2007). *Gestão de Investimentos e Geração de Valor*. Pearson Prentice Hall.

Santoni, G., & Liu, T. (1993). Circuit Breakers and Stock Market Volatility. *Journal of Futures Markets*, 13(3), p. 261-277.

Sharif, A., Aloui, C., & Yarovaya, L. (2020). COVID-19 Pandemic, Oil Prices, Stock Market, Geopolitical Risk and Policy Uncertainty Nexus in the US Economy: Fresh Evidence from the Wavelet-Based Approach. *International Review of Financial Analysis*, 70:101496. DOI: 10.1016/j.irfa.2020.101496.

Shehzad, K., Xiaoxing, L., & Kazouz, H. (2020). COVID-19's Disasters are More Perilous than Global Financial Crisis: A Rumor or Fact? *Finance Research Letters*, 36:101669. DOI: 10.1016/j.frl.2020.101669.

Sifat, I. M., & Mohamad, A. (2020). A Survey on the Magnet Effect of Circuit Breakers in Financial Markets. *International Review of Economics and Finance*, 69, p. 138-151.

Smaniotto, E. N., & Zani, J. (2020). Circuit Breakers and Volatility: Evidence from High Frequency Data on Brazilian Stock Exchange. Preprint. *Elsevier*.

Subrahmanyam, A. (1995). Circuit Breakers and Market Volatility: A Theoretical Perspective. *The Journal of Finance*, 49(1), p. 237-254.

Topcu, M., & Gulal, O. S. (2020). The Impact of COVID-19 on Emerging Stock Markets. *Finance Research Letters*, 36: 101691. Recuperado de: <https://doi.org/10.1016/j.frl.2020.101691>.

Wang, Y. H., Keswani, A., & Taylor, S. J. (2006). The Relationships Between Sentiment, Returns and Volatility. *International Journal of Forecasting*, 22(1), 109-123.

Wong, K. M., Kong, X. W., & Li, M. (2020). The Magnet Effect of Circuit Breakers and its Interactions with Price Limits. *Pacific-Basin Finance Journal*, Elsevier, v. 61©. DOI: 10.1016/j.pacfin.2020.101325.

Zakoian, J. M. (1994). Threshold Heteroskedasticity Models. *Journal of Economic Dynamics and Control*, 18(5), p. 931-955.

Zhang, W., & Hamori S. (2021). Crude Oil Market and Stock Markets During the Covid-19 Pandemic: Evidence from the US, Japan, and Germany. *International Review of Financial Analysis*, 74. Recuperado de: <https://doi.org/10.1016/j.irfa.2021.101702>.

Apêndices

APÊNDICE IIIA – Valores de FAC para a série *st_precoscovid_diff1*

Autocorrelação para <i>st_precoscovid_diff1</i>								
1.000	0.004	-0.007	-0.015	-0.004	0.001	0	-0.002	-0.008
-0.013	0.006	0.02	-0.02	-0.006	0.013	0.006	0.013	-0.028
0.002	0.005	0.022	0.002	-0.008	-0.012	-0.004	0	-0.004
-0.006	-0.009	0.011	0.015	0.002	0.01	0.003	0	-0.02
-0.01	-0.013	-0.013	-0.014	0.002	0.012	0.008	-0.005	-0.008
0.004	0.006	-0.001	0.004	0.003	0.003	0	0.002	-0.01
-0.029	0.002	0.004	-0.004	-0.005	0.01	-0.008	-0.012	-0.009
0.011	-0.001	-0.041	0.005	-0.003	-0.001	-0.002	0.002	-0.019
0.003	0.007	-0.012	-0.005	0.002	-0.288	0.004	-0.002	-0.006
-0.004	0.009	-0.027	-0.004	-0.005	-0.002	0	0.006	-0.019
-0.001	0.012	0.003	-0.011	-0.015	0.014	-0.001	0.007	0.001
0.007	-0.007	-0.026	-0.001	0.002	-0.002	-0.003	0.009	0.009
-0.001	-0.008	-0.014	-0.003	0.006	0.003	-0.001	-0.01	
0.006	-0.01	-0.005	-0.002	0.009	0.001	0.003	0.01	
-0.017	-0.005	-0.018	0.009	-0.006	-0.011	-0.005	0.006	
-0.004	-0.008	-0.029	0.014	0.002	0.017	-0.004	-0.029	

Fonte: dados de pesquisa.

APÊNDICE III.B – Valores de PFAC para a série st_precoscovid_diff1

Autocorrelação Parcial para st_precoscovid_diff1								
-0.013	-0.029	0.008	0.004	0.006	0.011	-0.008	-0.013	-0.027
0.002	0.01	-0.002	0.007	0.003	-0.005	-0.007	-0.002	0.001
-0.006	0.004	0.006	0.004	-0.001	-0.009	0.018	0.005	
-0.011	-0.004	-0.017	-0.008	0.006	-0.01	0.022	-0.04	
0.004	-0.002	-0.004	-0.014	0.009	-0.004	0.011	-0.012	

Fonte: dados de pesquisa.

APÊNDICE III.C – Teste de Dickey-Fuller Aumentado para os resíduos da série temporal ajustada

Augmented Dickey-Fuller Test


data: st_precoscovid_diff1


Dickey-Fuller = -23.627, Lag order = 23, p-value = 0.01

alternative hypothesis: stationary

Fonte: dados de pesquisa.

APÊNDICE III.D – Decomposição das séries temporais setoriais, na Covid-19





Fonte: dados de pesquisa.

IV. DESEMPENHO FINANCEIRO DAS EMPRESAS DA B3 NAS CRISES DA COVID-19 E DA GUERRA RUSSO-UCRANIANA

IV.1 Introdução

Em meio à transmissão comunitária da Covid-19 no território brasileiro, diversos estudos fizeram referência ao dilema da pandemia vivenciada no país (Caponi, 2020), que o Observatório Covid-19 da Fiocruz resumiu como salvar vidas ou salvar a economia, em um cenário de restrições de mobilidade impostas por meio de *lockdowns*, necessários para o controle do alastramento da doença (Fiocruz, 2020). Essa restrição ocasionou a queda das receitas das empresas no Brasil e no ambiente corporativo internacional, com dados coletados em mais de 100.000 empresas mundiais mostrando que, em geral, 70% fecharam as portas no pico dessa primeira onda pandêmica (Fiocruz, 2020). A Figura II.1 mostra como a queda nas vendas se manteve até meados de 2020, quando a receita média das empresas ficou mais de 40% inferior àquela no mesmo período no ano anterior (*World Bank, 2022*).




Figura IV.1 – Impacto da Covid-19 sobre as vendas nas empresas em todo o mundo em meados de 2020.
Fonte: *World Bank, 2022*.

Ainda de acordo com o Banco Mundial, os fechamentos das empresas e o declínio acentuado e persistente da receita sobre as vendas traduziram-se no aumento do desemprego, com 57% das empresas pesquisadas cancelando os contratos de trabalho. O impacto da crise variou entre países e setores, sendo o de turismo, varejo e partes do setor de serviços os mais severamente afetados (*World Bank, 2022*).

No Brasil, esse cenário se confirmou, e, devido à ausência de um programa de política pública estruturante do governo federal no combate à Covid-19, as prefeituras impuseram sucessivos *lockdowns* em todo o país, na proporção em que cada medida de flexibilização anunciada pela União incentivava o retorno da população às ruas, resultando em novas ondas de contaminação em massa e precariedade do atendimento médico à grande parte da população brasileira que adoecia todos os dias. O alastramento da pandemia em nível nacional promoveu em pouco tempo a geração de novas mutações do novo coronavírus, cujos potenciais de contágio superavam aqueles das variantes precedentes, acelerando a transmissão, adoecendo e levando a um número alarmante de óbitos, de forma descontrolada.

Analizando o contexto econômico no primeiro ano da pandemia no Brasil, Costa (2020) relata que ela impactou mais intensamente a população que vivia na informalidade, residente de áreas precárias, com rendimentos baixos e irregulares, e sem acesso a água potável, moradia digna, sistemas privados de saúde ou de proteção social. Além da crise sanitária, uma das consequências dessa pandemia no país foi o aumento do desemprego e da informalização do trabalho, de trabalhadores em tempo parcial e do subproletariado. Diante desse cenário, o governo criou o Programa Emergencial de Manutenção do Emprego e da Renda, por meio da Medida Provisória n.º 936, de 2020, que regularizava a redução da jornada de trabalho e, proporcionalmente, do salário, com duração máxima de 90 dias (Costa, 2020).

Entretanto, esse programa, direcionado apenas aos trabalhadores do setor privado, teve impacto negativo sobre a maioria dos salários pagos. A medida provocou ainda outros prejuízos como a redução das garantias relativas ao salário, férias, isonomia salarial e proteção às mulheres lactantes; e incluiu medidas que facilitaram a demissão e reduziram a possibilidade de o trabalhador reclamar seus direitos trabalhistas (Costa, 2020). O autor relata que, mesmo sem conhecimento aprofundado sobre a fisiologia da Covid-19, o Banco Central do Brasil (BACEN) estimou inicialmente que os efeitos econômicos iriam paralisar várias atividades, com retorno à normalidade do consumo e do trabalho no segundo trimestre de 2020, quando se presumia rápida recuperação da indústria e normalização das entregas das cadeias globais.

Contrariando essa expectativa, a pandemia avançou de forma rápida e agressiva pela China e Ásia Oriental, com reflexos nos indicadores do Produto Interno Bruto (PIB) que começaram a sinalizar impactos severos sobre as atividades econômicas desses países (BACEN, junho/2020). Os dados do Instituto Brasileiro de Geografia e Estatística (IBGE) apontaram que o PIB do Brasil caiu 1,5% no primeiro trimestre de 2020; esse recuo na economia foi motivado pela queda de 1,6% nos serviços (que representava 74% do PIB), pelo

encolhimento da indústria em 1,4% e queda de 2% no consumo das famílias (65% do PIB) (Lima Neto, Martins, Nagatsuka, Ráo, & Rodrigues Júnior, 2022).

Segundo o BACEN, a percepção dos setores mais sensíveis aos efeitos da crise da Covid-19 recaiu sobre o fabril, eletroeletrônico, serviços (sobretudo transporte aéreo, turismo, recreação e lazer) e comércio de bens duráveis (BACEN, junho/2020). Nesse contexto, a instituição decidiu realizar dois exercícios subsidiários à projeção do PIB doméstico: no primeiro, estimaram-se regressões trimestrais do crescimento da economia brasileira contra o crescimento da economia da China e do mundo exceto China, com a finalidade de compreender como as rápidas alterações no cenário internacional impactariam o crescimento brasileiro. Os resultados mostraram que o PIB brasileiro foi mais sensível ao PIB chinês do que ao do restante do mundo. No segundo exercício, foram estimadas regressões do crescimento do PIB contra variáveis financeiras como taxa de câmbio, índices de bolsa de valores e preços de *commodities*; a análise, feita com valores observados até a primeira metade de março/2020, auxiliou o entendimento do quanto as expectativas sobre a atividade econômica futura, embutidas nos preços das ações, já haviam mudado (BACEN, junho/2020).

Entre as estratégias de enfrentamento da pandemia adotadas em vários países, os *lockdowns* impediram o retorno pleno às atividades profissionais, educacionais e outras nos anos de 2020 e mesmo em 2021, impactando economias desenvolvidas e, principalmente, as emergentes e pouco desenvolvidas. O impacto econômico foi a redução do consumo e da renda, além do aumento do desemprego, o que refletiu negativamente nos resultados financeiros das empresas (BACEN, maio/2020).

Em fevereiro de 2022, quando o Brasil e o mundo ainda lutavam contra a pandemia, porém com melhores perspectivas em função da vacinação em massa global em andamento, a Rússia invade a Ucrânia no dia 24. Esse conflito teve origem em 2014, quando os russos tomaram a Crimeia (território da Ucrânia), e, desde então, foi intensificado, até que a Ucrânia expressou sua intenção de se unir à Organização do Tratado do Atlântico Norte (OTAN), o que foi interpretado pela Rússia como uma ameaça econômica e política, uma vez que a Ucrânia está localizada estrategicamente em uma rota comercial marítima de interesse russo (Dellagnezze, 2022).

A nível global, Alam, Mosab, Tabash, Billah, Kumar e Anagreh (2022) afirmam que o conflito entre Rússia e Ucrânia teve consequências econômicas negativas, como a estimativa de redução de 1% do PIB mundial ao longo do ano de 2023 (World Bank, 2022), representando uma queda aproximada de US\$ 1 trilhão de dólares. Para os autores, o fato de Ucrânia e Rússia

serem grandes fornecedores de mercadorias, como trigo, titânio, milho etc. No cenário global, pode gerar mais complexidades econômicas em relação a essas *commodities*. O conflito pode prejudicar também o fornecimento de *smartphones*, aeronaves e outros produtos semelhantes, promovendo a elevação dos preços (Alam *et al.*, 2022).

A guerra entre a Ucrânia e a Rússia intensificou a política monetária, prejudicando a confiança dos empresários e a demanda geral dos consumidores, que já estava em seu nível mais baixo devido aos aumentos de preços provocados pela Covid-19 (Alam *et al.*, 2022). Os autores esperam que esse conflito aumente, no futuro, os danos econômicos de ambos os lados, devido à interrupção dos fluxos comerciais, provocando escassez na cadeia de valor dos alimentos (produção, processamento, embalagem, armazenamento, transporte, vendas no varejo e custos logísticos).

Um artigo do Boletim FINDE (do Grupo de Pesquisa em Financeirização e Desenvolvimento) relata que, desde o início da invasão das tropas russas no território ucraniano, o Presidente dos Estados Unidos, Joe Biden, liderou sanções que tiveram impactos econômicos não só na Rússia, mas em toda a economia global (Leal & de Paula, 2022). Entre as sanções estão o congelamento de parte das reservas cambiais (cerca de US\$ 300 bilhões dos US\$ 630 bilhões das reservas do país) e a exclusão dos bancos russos do sistema de pagamentos entre instituições financeiras SWIFT (*Society for Worldwide Interbank Financial Telecommunication*), coordenados pelos bancos centrais das dez maiores economias do mundo. A Organização para a Cooperação e Desenvolvimento Econômico (OCDE) também encerrou o processo de adesão da Rússia e manteve as sanções internacionais (Lo *et al.*, 2022).

Outro artigo do Boletim FINDE (Feijo & Sampaio, 2022) relata que, em 2022, quando a pandemia parecia controlada no Brasil, havia ainda a necessidade de administrar suas consequências econômicas, sociais e sanitárias. A cobertura vacinal ampliada, não só nacionalmente, como nos países pobres, a reorganização das cadeias de suprimento e o combate à inflação (que atingiu os maiores níveis dos últimos 40 anos nas economias desenvolvidas) eram atividades que também demandariam atenção. Dessa forma, no momento de retomada do crescimento econômico, a invasão da Ucrânia agravou esses problemas e gerou outros (Feijo & Sampaio, 2022).

Diante desses cenários de choques sobre as economias globais, o objetivo deste capítulo refere-se ao terceiro objetivo específico da presente tese, que consistiu em analisar o desempenho financeiro das empresas listadas na B3, face aos efeitos das crises da Covid-19 e

da Guerra Russo-Ucraniana, no período entre janeiro/2020 e março/2023. Para este objetivo foram propostas duas hipóteses de pesquisa:

H3: A crise econômica da pandemia da Covid-19 afetou significativamente o desempenho financeiro das empresas listadas na B3, no período entre janeiro/2019 e dezembro/2021.

H4: A guerra entre Rússia e Ucrânia não afetou significativamente o desempenho financeiro das empresas da B3, no período entre janeiro/2022 e março/2023.

O teste de hipóteses permite averiguar a veracidade de suposições (ou hipóteses) sobre a amostra de uma pesquisa, por meio de técnicas estatísticas. A literatura científica relacionada a impactos de crises econômicas sobre empresas confirma o efeito daquelas sobre o desempenho financeiro das empresas, com alterações observadas em indicadores como endividamento, liquidez, atividade e rentabilidade (Ang, Leong, & Kotler, 2000; Ellaboudy, 2010; Hall *et al.*, 2013; Zeitun, & Saleh, 2015). A queda expressiva das vendas reduz a rentabilidade, a lucratividade e a liquidez, uma vez que os custos operacionais não diminuem na mesma proporção (Avelar *et al.*, 2021).

IV.2 Revisão da literatura

IV.2.1 Desempenho financeiro

A dificuldade de definir o conceito de desempenho deve-se à sua concepção multidimensional (Prahalathan, & Ranjany, 2011), que integra aspectos relacionados à gestão, a finanças, contabilidade, governança corporativa, microeconomia, entre outros. Considerando a dificuldade na definição de tal conceito e a falta de consenso na literatura da área, Tudose e Avasilcai (2020) assumem que o desempenho pode ser considerado um artefato com base no qual o sucesso de uma organização é promovido, ou seja, o desempenho financeiro é avaliado por meio dos resultados obtidos pela empresa em determinado período. Dessa forma, as autoras reforçam que, para admitir que uma empresa é financeiramente bem-sucedida, seus resultados monetários devem ser mais altos do que as despesas relacionadas. As definições mais recentes de desempenho financeiro integram também a eficiência e eficácia de uma empresa no uso de recursos (Egbunike, & Okerekeoti, 2018; Mahrani, & Soewarno, 2018) e na consecução de seus objetivos (Suhadak, Kurniaty, Handayani, & Rahayu, 2019). Portanto, o desempenho financeiro reflete a capacidade de uma empresa de criar valor econômico (Orozco, Vargas, & Galindo-Dorado, 2018), atraindo e gerando retornos para os investidores (Al-As'eed, 2018).

Os indicadores econômico-financeiros evidenciam as diversas dimensões do desempenho econômico-financeiro das organizações, a partir de suas operações, e possibilitam a análise simultânea de fatores internos e externos às mesmas. Dessa forma, um indicador ligado ao endividamento da empresa pode explicitar tanto o nível de risco assumido por gestores em busca de melhores retornos (fator interno) quanto o custo do capital de terceiros (fator externo). A análise das demonstrações financeiras possibilita avaliar o desempenho da organização para diagnosticar a situação atual e gerar resultados úteis para prever tendências futuras. Para os autores, a utilização desses índices representa o procedimento mais usualmente empregado. Porém, enfatizam que um indicador isolado pode não conter informações significantes, sendo mais adequado o uso de um conjunto de índices comparados temporal e setorialmente.

Para Andrade, Oliveira, Santos, Oliveira e Silva (2020), a análise de indicadores econômico-financeiros possibilitam diagnosticar o desempenho da empresa, fundamentando as tomadas de decisões. Em sua pesquisa, os autores consideraram as três maiores empresas de capital aberto do segmento de Incorporações listadas na B3 em dois períodos (2009 a 2013 e 2014 a 2018). Eles utilizaram como indicadores na avaliação do desempenho econômico-financeiro dessas empresas a liquidez, endividamento, lucratividade e rentabilidade. A comparação temporal e interempresarial desses indicadores, contextualizados com o desempenho da economia, oportunizou uma análise mais eficiente (Andrade *et al.*, 2020).

Diante da expectativa dos investidores por melhores retornos sobre o capital investido, Alsmady (2022) reforça o papel e a importância da análise do desempenho financeiro das empresas como um indicador do sucesso comercial, bem como o de fornecer informações sobre sua saúde geral, retratando especificamente sua saúde econômica e seu desempenho gerencial. Nesse contexto, o autor relata que o desempenho financeiro consiste em uma variável instrumental essencial relacionada aos retornos futuros, que podem ser previstos por meio dos lucros. Dessa forma, empresas lucrativas terão um efeito sobre seu desempenho (Müller, 2013; Herawaty, & Solihah, 2019).

O estudo de Alsmady (2022) teve como foco todas as empresas listadas no Conselho de Cooperação do Golfo (*Gulf Cooperation Council – GCC*), à exceção dos bancos, que foram omitidos devido às diferentes legislações e normas de divulgação aplicadas nesse setor. Empresas que declararam falência nas bolsas de valores também não foram incluídas na pesquisa. A amostra foi constituída pelos seis países árabes: Arábia Saudita, Bahrein, Omã, Qatar, Kuwait e Emirados Árabes Unidos. Com dados coletados dos bancos de dados *Gulfbase* e *Thomas Reuters*, além dos sites das empresas, e antes da Covid-19, a pesquisa se estendeu

por sete anos desde 2011 até 2017. Foram analisadas 191 empresas num total de 1.337 observações de dados anuais para investigar o desempenho financeiro via modelagem de regressão. A metodologia do estudo se deu por meio do desenvolvimento de modelos de regressão (dados em painel), de acordo com as equações (1), (2) e (3).

$$Performance_{i,t} = \beta_0 + \beta_1 AuditQ_{i,t} + \beta_2 InforQ_{i,t} + \beta_3 Epowr_{i,t} + \beta_4 \Delta ROA_{i,t-1} + \beta_5 \Delta ROA_{i,t-2} + \beta_6 Leve_{i,t} + \beta_7 Log(ASS)_{i,t} + \beta_8 SD_{i,t} + \beta_9 AG_{i,t} + \beta_{10} Lag(ROE)_{i,t} + \beta_{11} MV - equity_{i,t} + \varepsilon_{i,t} \dots \quad (1)$$

$$Performance (Tobin's Q/EPS)_{i,t} = \beta_0 + \beta_1 AuditQ_{i,t} + \beta_2 InforQ_{i,t} + \beta_3 Epowr_{i,t} + \beta_4 \Delta ROA_{i,t-1} + \beta_5 \Delta ROA_{i,t-2} + \beta_6 Leve_{i,t} + \beta_7 Log(ASS)_{i,t} + \beta_8 SD_{i,t} + \beta_9 AG_{i,t} + \beta_{10} Lag(ROE)_{i,t} + \beta_{11} MV - equity_{i,t} + \varepsilon_{i,t} \dots \quad (2)$$

$$Performance (ROE/MB)_{i,t} = \beta_0 + \beta_1 AuditQ_{i,t} + \beta_2 InforQ_{i,t} + \beta_3 Epowr_{i,t} + \beta_4 \Delta ROA_{i,t-1} + \beta_5 \Delta ROA_{i,t-2} + \beta_6 Leve_{i,t} + \beta_7 Log(ASS)_{i,t} + \beta_8 SD_{i,t} + \beta_9 AG_{i,t} + \beta_{10} Lag(ROE)_{i,t} + \beta_{11} MV - equity_{i,t} + \varepsilon_{i,t} \dots \quad (3)$$

A equação (1) mede o desempenho financeiro (*Performance*) em função dos parâmetros de intercepto (β_0), dos coeficientes correspondentes a cada variável explicativa do modelo ($\beta_{1,i,t}$ a $\beta_{11,i,t}$) e das variáveis: qualidade da auditoria (*AuditQ*), qualidade da informação contábil (*InforQ*), poder de ganho (*Epowr*), retorno sobre ativo (*ROA*), alavancagem (*Leve*), ativos totais (*LogASS*), desvio-padrão da receita (*SD*), idade da firma (*AG*), retorno sobre o patrimônio líquido (*ROE*), valor de mercado (*MV*), patrimônio líquido (*equity*), e considera os erros idiossincráticos ($\varepsilon_{i,t}$). A equação (2) foi testada primeiro, para comparar o Q de Tobin com outra medida contábil, lucro por ação (*EPS – earnings per share*). Essa análise de regressão avaliou os efeitos da qualidade das informações contábeis, a qualidade da auditoria e o poder de ganho sobre os desempenhos das empresas do GCC. A análise de dados do painel foi apropriada em função do volume de dados e sua variabilidade. Além disso, essa técnica permite realizar inferências mais precisas sobre os parâmetros do modelo, minimizando o efeito dos dados ausentes. A equação 3 verificou o desempenho das empresas usando ROE como uma medida contábil e *Market Capitalization/Book Value* (M/B) como uma medida de mercado para as empresas do estudo (Alsmady, 2022).

Nos mercados de capitais são utilizados indicadores financeiros mensurados por meio de *proxies*, para medir a eficiência do desempenho das empresas. O Índice de Desempenho Financeiro é uma medida da forma como uma empresa utiliza os seus ativos a partir do seu modelo de negócio principal e gera receitas. Esse termo é também utilizado como uma medida geral da saúde financeira das empresas ao longo de um determinado período de tempo; ele pode ser utilizado para comparar o desempenho de empresas de um mesmo setor de atividade

(Prajapati, 2019; Schwab, Gold, & Reiner, 2019). Em termos econômicos, os principais indicadores de desempenho financeiro das empresas são utilizados para determinar sua eficiência e prever seu comportamento futuro. Os indicadores-chave representam fatores pelos quais o desempenho da empresa pode ser medido de forma eficaz, impactando a saúde financeira por meio de decisões de investimentos tomadas com menor risco (Edan, Hraiga, & Farhan, 2022).

Os investidores tomam as suas decisões de investimento com base nas suas opiniões racionais, experiência e informação disponível. Devido à incerteza, é provável que eles sofram perdas financeiras. Nesse sentido, essa incerteza pode ser reduzida quando se têm informações sobre o desempenho da empresa, permitindo escolher a melhor alternativa de investimento. Na visão de Edan, Hraiga e Farhan (2022), investidores bem informados lidam com o risco de forma mais eficiente porque reduzem a incerteza associada ao investimento.

IV.2.2 Mensuração do desempenho financeiro

Segundo Farasi (2022), os indicadores financeiros são muito importantes para analisar a condição financeira de uma empresa. O uso de indicadores financeiros para medir o desempenho financeiro de um negócio varia conforme o aspecto do desempenho a ser avaliado. Dessa forma, cada indicador financeiro tem um propósito, benefício e significado específicos. Na prática atual, existem cinco tipos de indicadores financeiros que são frequentemente usados para avaliar a condição financeira e o desempenho financeiro de uma empresa, e entre eles estão a lucratividade, a rentabilidade e a liquidez (Farasi, 2022).

Lucratividade

A margem de lucro reflete a capacidade de uma empresa de gerar lucro com base nas vendas, sendo um indicador considerado importante porque uma diminuição significativa nas vendas e, portanto, nas receitas pode gerar o risco de falência (Husna, & Desiyanti, 2016). Imhanzenobe (2020) mostrou que a margem de lucro é um indicador de desempenho a curto prazo (refletindo a receita líquida da empresa por unidade de vendas). Tudose, Rusu e Avasilcai (2022) reconhecem que a gestão da margem de lucro pode evitar ou antecipar o declínio dos lucros, com um efeito futuro positivo sobre a empresa (controlando a competitividade e minimizando o risco de falência).

Ao analisarem a dinâmica da taxa de crescimento do lucro, Endri, Sari, Budiasih, Yuliantini, & Kasmir (2020) mostraram que um aumento nos lucros das empresas pode ser obtido se funcionarem eficientemente (aumento de receitas e margens de lucro). Associada à

administração da liquidez, pode incentivar um maior crescimento das vendas. A avaliação do desempenho com base na taxa de aumento do lucro marcou a transição desde a medição estática até a medição dinâmica do desempenho financeiro. A taxa de crescimento do lucro foi associada à taxa de crescimento da empresa (aumento das vendas) (Tudose, Rusu, & Avasilcai, 2022).

Uma *proxy* de lucratividade utilizada na mensuração do desempenho financeiro empresarial é a Margem EBITDA, descrita no estudo de Andrade *et al.* (2020) como sendo a porcentagem de lucro líquido, sem incidência de deduções relativas aos juros, impostos, depreciações e amortizações. A Margem EBTIDA é relevante para analistas evidenciarem a lucratividade e comparações interempresariais (Ritta, Jacomossi, Fabris, & Klann, 2017). O índice de lucratividade é a relação que representa a capacidade da empresa de manifestar lucros. A lucratividade é comumente usada para avaliar a capacidade de uma empresa de obter lucros dentro de um determinado período de tempo, estando intimamente relacionada ao seu desenvolvimento (Farasi, 2022).

Rentabilidade

Para Venkatraman e Ramanujam (1987), o desempenho financeiro apresenta duas dimensões bem definidas: rentabilidade e crescimento. A rentabilidade pode ser operacionalizada por *proxies* como retorno sobre ativos totais (ROA), retorno sobre patrimônio líquido (ROE) e retorno sobre investimentos (ROI). Krauter (2012) avaliou a existência de relação entre remuneração de executivos e desempenho financeiro em uma amostra de 79 empresas, de diversos setores. Nesse estudo, as *proxies* utilizadas foram ROE, ROA e crescimento das vendas, e a autora não constatou uma relação entre as variáveis analisadas.

Halkos e Tzeremes (2012) também relatam que o desempenho financeiro das empresas pode ser expresso pelo seu nível de ROA e ROE. Andrade *et al.* (2020) afirmam que o retorno sobre o patrimônio líquido (ROE) evidencia a agregação de valor da empresa com base nos investimentos realizados, e é considerado uma *proxy* clássica para mensurar a rentabilidade, além de relevante para os gestores (Souza, Peters, Silva, & Antunes, 2018). Vieira, Santos, Lagioia, Vieira, & Santos (2014) corroboram tal relevância, afirmando que o ROE é uma das *proxies* mais importantes de acordo com os acionistas. Entre as medidas para determinar a eficiência econômica e o desempenho financeiro de uma empresa, Hassan (2019) cita os ganhos por ação (EPS), ROA, ROE e o retorno sobre o capital investido (ROIC).

Tudose, Rusu e Avasilcai (2022) afirmam também que as taxas de retorno mais utilizadas nos estudos de finanças são o ROA e o ROE. Essas duas medidas de desempenho indicam a eficiência de uma empresa no uso de seus recursos e fundos. As autoras ainda

incluem, nessa categoria, o ROI, que equilibra o lucro líquido e o valor total do investimento, utilizado para avaliar o nível de eficiência da empresa como um todo (Siahaan, Sadalia, & Silalahi, 2021). Edan, Hraiga e Farhan (2022) corroboram a importância dessas taxas de retorno na avaliação do desempenho financeiro empresarial, justificando que os mesmos determinam a eficiência do desempenho operacional e a eficácia da gestão. Nesse sentido, níveis sustentáveis de rentabilidade constituem uma barreira contra a erosão do capital durante condições econômicas difíceis, proporcionando proteção para acionistas.

Estrutura de capital

A contribuição da estrutura de capital para o equilíbrio econômico e financeiro da empresa é de extrema importância, principalmente ao se considerar a escassez de recursos e o elevado custo dos financiamentos (Vieira, Velasquez, Losekann, & Ceretta, 2011). Dessa forma, a distribuição justa dos valores investidos pelos sócios (recursos próprios) e dos financiamentos obtidos externamente (recursos de terceiros) demonstra a eficácia na aplicação dos recursos. Vieira *et al.* (2011) pontuam também que a avaliação do desempenho organizacional considera, além da escolha da melhor estrutura de capital, a obtenção de melhor retorno sobre os investimentos feitos e a melhor lucratividade das vendas. Os autores declaram que as decisões envolvendo tais fatores devem ser tomadas de maneira integrada, considerando que, muitas vezes, o volume dos investimentos realizados depende das condições de financiamento disponíveis.

A captação de recursos de terceiros possibilita à empresa realizar investimentos em melhorias de infraestrutura, processos, fatores de produção, elevação do capital de giro etc. (Andrade *et al.*, 2020). Nesse sentido, o Índice de Endividamento em Curto Prazo é uma *proxy* da estrutura de capital útil para evidenciar a representatividade das obrigações em curto prazo, em relação ao total de exigíveis. Nessa mesma linha, a *proxy* de Participação de Capital de Terceiros mostra a proporção de capital de terceiros em relação ao capital próprio, revelando a estratégia de financiamento de ativos totais da empresa, além de mensurar sua capacidade de cumprir com compromissos no longo prazo (Wang, Dennis, & Tu, 2007).

No estudo de Andrade *et al.* (2020), para avaliar o endividamento, os autores consideraram o Índice de Endividamento em Curto Prazo, uma vez que a concentração da dívida em curto prazo exige estratégias dos gestores para não faltar liquidez. Já o Índice de Participação de Capital de Terceiros foi útil para evidenciar as estratégias de financiamento das empresas analisadas (Bandeira, & Britto, 2020).

Edan, Hraiga, & Farhan (2022) relatam que os indicadores de endividamento medem a capacidade da empresa para satisfazer as suas dívidas e obrigações a longo prazo. O financiamento de dívidas tem sido uma espada de dois gumes, pelo menos nos mercados emergentes. Para os autores, em muitos casos, o financiamento da dívida constitui um instrumento eficaz para o crescimento das empresas, permitindo-lhes expandir as suas atividades por meio de investimentos com retornos que compensam o custo de oportunidade. Porém, existem outros casos cujo financiamento da dívida foi responsável pela falência de empresas, como resultado dos altos riscos inerentes ao reembolso da dívida, a exemplo de situações de investimentos não rentáveis ou de exposição a uma crise econômica (fator externo) ou financeira (fator interno).

Liquidez

O índice de liquidez geral $((\text{ativo circulante} + \text{realizável em longo prazo})/(\text{passivo circulante} + \text{exigível em longo prazo}))$ é um indicativo da solidez financeira de uma empresa a longo prazo. Quanto menor a liquidez geral, maior a capacidade da empresa de cumprir com suas obrigações correntes. A análise de Luz (2013) contribui ao descrever o índice de liquidez imediata (disponível/passivo circulante), o qual identifica a disponibilidade imediata da empresa para quitar suas obrigações (Edan, Hraiga, & Farhan, 2022; Prajapati, 2019; Sajid, Mahmood, & Sabir, 2016). Silva, Ramos, Kroenke e Hein (2019) reforçam que os indicadores tradicionalmente utilizados na mensuração do desempenho financeiro das empresas são a liquidez corrente, liquidez seca, liquidez imediata e liquidez geral.

Silva *et al.* (2019) analisaram estudos sobre a importância da liquidez na avaliação do desempenho financeiro das empresas e encontraram relatos de que esses indicadores são capazes de prever, no curto prazo, a condição de solvência ou de dificuldades financeiras da empresa. Eles servem como fonte de informação aos *stakeholders*, indicando a capacidade de liquidação dos compromissos financeiros nos prazos contratados. Os autores informam que as duas medidas fundamentais de liquidez são a corrente, calculada pela razão entre o ativo circulante e o passivo circulante, e que mede a capacidade de a empresa pagar suas obrigações de curto prazo; e a seca, avaliada pela razão entre o ativo circulante subtraindo os estoques e o passivo circulante, que se assemelha à corrente, exceto que aqui se excluem os estoques.

Andrade *et al.* (2020) utilizaram em seu estudo os indicadores de liquidez corrente, que é considerada a mais empregada em pesquisas empíricas (Bandeira, & Britto, 2020), e de liquidez imediata devido à influência negativa da crise econômica da época, sobre o disponível das empresas (Nunes, & Sales, 2019). De acordo com o estudo de Sajid *et al.* (2016), quando a

liquidez é elevada, a empresa tem maior capacidade de pagar as suas obrigações a curto prazo. Se for baixa, a empresa é incapaz de pagar as suas obrigações de curto prazo, enfraquecendo financeiramente a empresa. Contudo, uma liquidez elevada não é um fator atraente para os investidores, uma vez que isso pode indicar um baixo nível de atividade e, portanto, de desempenho (Edan, Hraiga, & Farhan, 2022; Sajid *et al.*, 2016).

Valor de mercado da empresa

King e Lenox (2001) utilizaram ROA, ROE, ROI, e o Q de Tobin para determinar a avaliação de mercado de uma empresa sobre o valor de substituição dos seus bens. Iwata e Okada (2011) utilizaram em seu estudo ROE, ROA, ROI, ROIC e a devolução de vendas (ROS), além do Q de Tobin e seu logaritmo natural, para esclarecerem como o desempenho financeiro é influenciado por diferentes questões ambientais.

Afza e Sajid Nazir (2014), ao investigarem os mecanismos de governança corporativa que poderiam afetar o desempenho das empresas no Paquistão, encontraram uma associação positiva entre a qualidade de auditoria e o desempenho financeiro, este último medido pelo ROA e pelo Q de Tobin. Sayyar (2015), em seu estudo que avaliou o impacto da qualidade da auditoria contábil sobre o desempenho das empresas malaias listadas, entre 2003 a 2012, utilizou o indicador de mercado Q de Tobin para avaliar tal desempenho. Dewi e Monalisa (2016) empregaram auditoria da qualidade como variável moderadora para o relacionamento entre as empresas com Responsabilidade Social e desempenho financeiro positivo, medido pelo ROA, ROE, e *Price to Book Value (PBV)*. O estudo descobriu que a qualidade da auditoria afetou diretamente o desempenho financeiro das empresas.

Dopierała, Mosionek-Schweda, Laskowicz e Ilczuk (2022) pesquisaram sobre a avaliação do desempenho financeiro dos produtores de energias renováveis, em comparação com os produtores de energia convencional na região do Mar Báltico. A investigação também determinou como o desempenho era influenciado por fatores específicos das empresas e dos países. Entre os fatores específicos das empresas que afetam os resultados financeiros dos produtores de fontes de energia renováveis estão a dimensão da empresa, o crescimento do ativo e das vendas, o volume de negócios, a liquidez e alavancagem, bem como o número de anos nos quais a empresa esteve envolvida na atividade-fim, entre outros fatores. King e Lenox (2001) incluíram, em seu estudo, a dimensão da empresa, seu crescimento anual (calculado como a variação percentual em venda) e a alavancagem (calculada como a razão da sua dívida pelo ativo).

IV.2.3 Desempenho financeiro em ambiente de crise

Eventos econômicos turbulentos como crises e recessões econômicas impactam fortemente os desempenhos financeiros das empresas. Muitos estudos nesse cenário já foram conduzidos com o intuito de compreender os efeitos das crises no desempenho das empresas. A crise do *subprime* de 2008 pode, nesse aspecto, ser considerada como a primeira grande crise econômica mundial do século XXI que provocou grandes prejuízos aos mercados acionários em decorrência dos impactos sofridos no desempenho financeiro das empresas. As combinações resultantes de créditos de financiamento reduzidos, redução da demanda, queda nas exportações e redução dos gastos dos consumidores contribuíram para fluxos de caixa apertados, posições de caixa em declínio, queda da rentabilidade e perdas, levando, em muitos casos, à insolvência e falência.

Ang, Leong e Kotler (2000) afirmam que existe uma relação direta entre o desempenho financeiro empresarial e crise econômica, em cujo contexto as respostas das empresas e da política pública devem ser consideradas em conjunto (Agarwal, Barney, Foss, & Klein, 2009), uma vez que ações de ambas as instituições influenciam o sucesso (ou fracasso) do enfrentamento da crise. Os impactos da crise de 2008 foram sentidos intensamente pela bolsa de valores brasileira conforme mostram os estudos de Costa, Ramos, Eufrásio, Estevão e Azevedo (2010), cujas análises dos desempenhos das empresas listadas na B3 de 15 setores diferentes identificaram um maior impacto na geração de resultados, com redução significativa nos índices de rentabilidade (80% no retorno sobre ativos – ROA e 40% no retorno sobre patrimônio líquido – ROE).

Hall, Beck e Toledo Filho (2013) também realizaram um trabalho sobre o impacto da crise do *subprime* no desempenho de empresas brasileiras, especificamente no setor do agronegócio listadas na B3, e os resultados apontaram para um forte impacto nos indicadores de endividamento, liquidez, atividade e rentabilidade no ano de 2008. Alguns desses efeitos também foram relatados no estudo de Yap, Mohamed e Chong (2014) no qual apresentam que as empresas mais severamente afetadas durante uma crise econômica poderiam ser forçadas a liquidar e fechar seus negócios, enquanto outras menos afetadas poderiam ter que interromper suas operações ou retrai-las para permanecerem no mercado.

Segundo o estudo de Zeitun e Saleh (2015), a crise financeira de 2008 afetou negativamente a liquidez global que, por sua vez, atingiu os bancos e outras instituições financeiras, dificultando a oferta de crédito. Assim, o custo do empréstimo aumentou excessivamente à medida que a acessibilidade da liquidez diminuía e os bancos criavam um

crédito mais limitado. Tais políticas afetaram negativamente o desempenho das empresas (Ellaboudy, 2010). Os resultados empíricos do trabalho de Zeitun e Saleh (2015) indicaram que a alavancagem financeira foi a determinante mais importante do desempenho das empresas após a crise, até o ano de 2012, afetando o desempenho das empresas de forma significativa e negativa, antes e depois dos períodos de crise.

O aumento do financiamento da dívida durante os períodos de crise torna as empresas mais suscetíveis ao refinanciamento, acarretando riscos e empréstimos a custos mais elevados que, por sua vez, diminuem seu desempenho financeiro. Nesse sentido, Oliveira, Hall, Viana, & Silva (2018) pesquisaram o impacto da crise do *subprime* em dez empresas do setor siderúrgico e metalúrgico listadas na B3 e identificaram que seis delas foram impactadas negativamente, atingindo um desempenho financeiro inferior no período.

Avelar *et al.* (2021) destacam que os efeitos da crise pandêmica da Covid-19 nos negócios, assim como as medidas tomadas pelas organizações e governos para restringir as contaminações, podem ser observados a partir das informações constantes nas demonstrações financeiras das empresas. Os autores consideram que tais efeitos podem ser analisados sob óticas diferentes — entre as principais técnicas está o uso de indicadores econômico-financeiros. Dessa forma, durante a pandemia, é esperada uma menor disponibilidade de recursos advindos das operações das empresas devido à vigência de medidas de isolamento social e à incerteza dos agentes econômicos, impactando diretamente o desempenho financeiro.

IV.2.4 Efeitos da crise da Covid-19 nos mercados financeiros

O aumento de incerteza em mercados financeiros torna seus investidores mais sensíveis às perdas que aos ganhos (Giot, 2005), e, como consequência, o desempenho das economias é impactado negativamente, agravando a incerteza e gerando medo, desencadeando mais riscos num ciclo vicioso. A incerteza é seguida de comportamentos emocionais ou sentimentais imprevisíveis dos investidores (Economou, Panagopoulos, & Tsouma, 2018), prejudicando suas decisões de investimento (Chen, & Chiang, 2020). Oluwasegun e Johnson (2022) corroboram essa ideia, relatando que, em períodos de crises econômicas, pandemias, desordens políticas e outros eventos conflituosos e/ou catastróficos a nível global, afloram os sentimentos dos investidores pelas incertezas geradas.

O impacto das incertezas geradas pela crise pandêmica no desempenho no mercado financeiro, evidenciado por Caldas, Silva, Júnior e Cruz (2021), apontou perdas financeiras devido ao aumento do volume de ordens de vendas que derrubou os preços dos papéis. Para os

autores, os riscos do mercado financeiro global associam-se fortemente à evolução da crise pandêmica, com sua gravidade em cada país, e, conseqüentemente, os preços das ações acompanham o ritmo de propagação da doença, descolando-se do seu comportamento histórico. Esse fato dificulta a estimativa de valores futuros e os riscos das ações, bem como a formação de portfólios eficientes, que combinem ações com correlações mais equilibradas entre risco e retorno.

No cenário de crise sanitária e econômica desencadeada pela pandemia da Covid-19, a maioria dos investidores (muitos detentores de pequenos investimentos) liquidaram seus ativos, incluindo ações das bolsas de valores, para obterem os recursos necessários à sua sobrevivência. Isso afetou os preços e a volatilidade das ações. O fato de os mercados acionários estarem interligados por todo o planeta fez com que os choques globais impactassem de formas diversas os diferentes mercados (Okorie, & Lin, 2020; Okorie, & Lin, 2022).

Entre as muitas crises relatadas historicamente, a pandemia da Covid-19 parece ser a de maior impacto sobre o sistema financeiro global, em função do amplo fechamento das indústrias domésticas e fronteiras dos países, com restrição imposta ao comércio internacional, entre outras políticas. Salisu e Vo (2020) relatam que os investidores começaram a vender suas ações apressadamente, seguindo a queda acentuada nos preços globais do petróleo bruto. Os autores citam que o relatório preliminar da Organização para a Cooperação e Desenvolvimento Econômico (OCDE) também revelou que os preços das ações caíram, registrando os valores mais baixos nos últimos 10 anos. A queda do preço do petróleo deveu-se à interrupção das negociações sobre produção de petróleo entre a Arábia Saudita e a Rússia no final de dezembro de 2019, quando a Covid-19 surgiu na China, e a Arábia Saudita começou, então, sua produção em grande escala, ocasionando uma queda acentuada nos preços globais do petróleo (Guo, Zhao, Yu, & Zhang, 2021).

Essa queda do preço do petróleo e o declínio da economia global provocaram um acúmulo dos efeitos negativos das economias regionais. Como resultado, os mercados financeiros reagiram rapidamente, e os índices de ações globais caíram intensamente, a exemplo das ações europeias que, no geral, haviam caído mais de 7% no início de março/2020 (Guo *et al.*, 2021). Na Europa, os países que mais sofreram com essas quedas foram a Grécia e a Itália, com quedas de 13% e 11%, respectivamente. Nos Estados Unidos, a situação foi pior, com o mercado passando por uma crise de liquidez única no século, chegando a acionar o mecanismo de *circuit-breaker* quatro vezes durante o mês de março de 2020. Os mercados da Austrália,

China, Canadá, Brasil e alguns outros países também sofreram colapsos nesse período (Guo *et al.*, 2021).

Brada, Gajewski e Kutan (2021) afirmam que muitos estudos examinaram a associação entre a pandemia e mercados financeiros sob a premissa de que estes últimos reagem rapidamente às notícias da evolução pandêmica, operando como um sistema de alerta precoce em relação aos efeitos econômicos da Covid-19. Devido à rápida disseminação do novo coronavírus, o mercado chinês foi inicialmente fechado, sendo tal ação seguida posteriormente por outros países, com o objetivo de isolar pessoas infectadas daquelas não infectadas. O surto originado na China e disseminado para outros países fez com que as pessoas infectadas permanecessem em quarentena (ou *lockdown*), enquanto aquelas não infectadas retornassem gradativamente aos negócios e ao mercado de trabalho. Essas ações provocaram, entre outras tantas, pânico generalizado, uma vez que as empresas e as operações seriam afetadas, e as famílias precisariam de recursos para seu sustento durante os períodos de *lockdown* (Okorie, & Lin, 2021).

Com o temor pairando sobre os mercados globais, tomar as melhores decisões de investimento requereu o máximo cuidado e muita esperança dos investidores. Sejam eles avessos ao risco ou maximizadores de retorno, todos precisaram de informações suficientes para restabelecerem sua confiança no mercado (Salisu, & Vo, 2020). Entretanto, essa confiança continuou sendo abalada frente às notícias diárias de novos casos de contaminações e óbitos em números alarmantes em todo o mundo. Como consequência, estudos empíricos relatam que a pandemia facilitou consideravelmente a transmissão de riscos entre os mercados (Adekoya, & Oliyide, 2021; Umar, Adekoya, Oliyide, & Gubareva, 2021). Oluwasegun e Johnson (2022) afirmam que um dos fatores mais críticos para restaurar a confiança dos investidores é a compreensão do grau de persistência do efeito dos choques provocados pela pandemia sobre a incerteza e o medo nos mercados financeiros.

Nesse sentido, o estudo de Oluwasegun e Johnson (2022) explora empiricamente a dinâmica do tempo de sete índices de medo do mercado antes e durante a pandemia da Covid-19, considerando duas abordagens: a determinação exata do grau de persistência dos efeitos da crise sobre os mercados e a possibilidade de ocorrência de volatilidade do mercado de ações com base em doenças infecciosas e o índice de medo do mercado global. Os autores chegaram à conclusão de que o impacto dos choques gerados pela pandemia era transitório.

Vários estudos exploraram a influência da pandemia em diferentes classes de ativos como petróleo (Sharif, Aloui, & Yarovaya, 2020; Wu, Wang, Wang, & Zeng, 2021), ouro

(Gharib, Mefteh-Wali, & Jabeur, 2021; Mensi, Sensoy, Vo, & Kang, 2020), criptomoedas (Conlon, & McGee, 2020; Demir, Bilgin, Karabulut, & Doker, 2020), taxas de câmbio (Njindan, 2020), imóveis (Ling, Wang, & Zhou, 2020; Milcheva, 2021) e títulos (Falato, Goldstein, & Hortaçsu, 2021). Mnif, Jarboui e Mouakhar (2020) relatam que o mercado de criptomoedas se tornou mais eficiente após o início da pandemia, provavelmente devido ao aumento do volume de comércio desses ativos. Ji, Dayong e Zhao (2020) examinaram vários ativos do tipo *safe-heaven*⁶ durante a pandemia e afirmam que o ouro e a soja se mantiveram como ativos seguros, enquanto bitcoin, moedas estrangeiras e petróleo bruto tornaram-se ativos *safe-heaven* mais fracos.

O efeito da pandemia no mercado foi observado como sendo heterogêneo entre as indústrias (Baek, Mohanty, & Glambsky, 2020; Goodell, & Huynh, 2020; Li, Zhou, Chen, & Liu, 2021), na liquidez (Haroon, & Rizvi, 2020; Zaremba, Kizys, & Tzouvanas, 2021) e na volatilidade das ações (Albulescu, 2021; Baek *et al.*, 2020; Bai, Wei, Wei, Li, & Zhang, 2021; Engelhardt, Krause, Neukirchen, & Posch, 2021; Onali, 2020; Zaremba, Kizys, Aharon, & Demir, 2020).

Algumas pesquisas empíricas investigaram fatores específicos das empresas que teriam auxiliado a mitigação dos impactos da pandemia por elas. Os achados mostraram que as condições financeiras das empresas no período pré-pandêmico, como dívidas baixas, alta rentabilidade e maior flexibilidade financeira, contribuíram para lidarem com a Covid-19 de forma mais efetiva (Ding, Levine, Lin, & Xie, 2021; Fahlenbrach, Rageth, & Stulz, 2020; Ramelli, & Wagner, 2020).

Avelar *et al.* (2021) atestam que diferentes empresas apresentaram perdas distintas em seus valores de mercado, pois não foram afetadas da mesma forma pela pandemia e pelas medidas para lidar com o avanço da doença. Nesse sentido, os autores recorrem à HME ao afirmarem que as informações públicas sobre as operações das empresas e sobre os efeitos da crise seriam o principal agente influenciador na precificação dos ativos de forma individualizada.

IV.2.5 Vestígios da pandemia e impactos da guerra na Ucrânia nos mercados acionários

Desde o surto do novo coronavírus, a economia global, já pressionada pela queda dos mercados financeiros, sofreu novamente com a guerra, que impactou de forma relevante a

⁶ Um ativo tipo *safe-heaven* é um tipo de investimento do qual se espera que retenha ou aumente seu valor durante períodos de turbulência do mercado. Esse ativo pode variar dependendo da natureza do mercado em queda. Recuperado de: <https://www.investopedia.com/terms/s/safe-heaven.asp>.

volatilidade dos mercados financeiros (Beraich, Amzile, Laamire, Zirari, & Fadali, 2022). As sanções econômicas e a inflação foram as principais formas pelas quais a guerra afetou os mercados financeiros globais, uma vez que Rússia e Ucrânia estão entre os principais exportadores de várias *commodities* e produtos alimentícios. Como exemplos, têm-se o petróleo e o gás russos que são usados para aquecer residências, abastecer empresas e encher os tanques de gasolina em muitos países europeus; a inflação global aumentou com o preço do petróleo, gás natural e de outras *commodities* (Cohen, 2022).

Para Beraich *et al.* (2022), as repercussões mundiais da guerra nos principais mercados de *commodities* (petróleo, gás, platina, ouro e prata) implicaram mudanças significativas na oferta e nos preços. Ao analisarem a evolução dos índices dos mercados acionários da China, Estados Unidos e Europa antes e durante o período da guerra, os autores observam que os Estados Unidos e a Europa, antes e durante essa crise bélica, tiveram os preços de suas ações afetados pelos efeitos do conflito Rússia-Ucrânia, com tendência de queda durante os primeiros meses de 2022. Ademais, os autores mediram a volatilidade dos retornos durante os subperíodos pré-crise e durante a crise para os ativos dos três índices dos mercados de ações americano, europeu e chinês, de 1º de janeiro de 2019 a 1º de junho de 2022. Os índices revelam um nível mais baixo de conectividade antes da guerra do que durante a guerra. Determinar a magnitude dos choques de volatilidade transmitidos entre os mercados financeiros permite antecipar o início de uma crise ou de um período caótico, já demonstrada pela crise do *Subprime*, originada de uma crise bancária nos Estados Unidos, e que afetou os principais mercados de ações do mundo por meio de um efeito de contágio (Beraich *et al.*, 2022).

Os impactos da GR-U sobre os mercados acionários internacionais são amplamente pesquisados, a exemplo do estudo de Bounboua e Yatié (2022), que analisa os efeitos dessa guerra sobre os mercados acionários de 94 países, entre 22/01/2022 a 24/03/2022, sob quatro perspectivas: (i) o impacto da guerra nos retornos do mercado acionário; (ii) a evolução das respostas desse mercado desde a invasão e várias semanas após; (iii) divergência de efeitos de acordo com a proximidade geográfica da Ucrânia e da Rússia; e (iv) divergência das respostas do mercado acionário entre países neutros e aqueles que condenaram a invasão. Os resultados indicaram relação negativa e estatisticamente significativa entre a guerra e o desempenho dos índices do mercado acionário mundial. Para investigar a evolução dos retornos antes e após a invasão na Ucrânia, os autores organizaram a amostra de empresas em dois subconjuntos, por período: (i) 22/01/2022 a 23/02/2022 (pré-invasão) e (ii) 24/02/2022 a 24/03/2022 (pós-

invasão); os resultados apontaram uma relação negativa entre a guerra e os índices do mercado acionário global, com impacto significativamente maior a partir do momento da invasão.

Para compreender a dinâmica da propagação de choques globais sobre as ações das empresas, Bounbou e Yatié (2022) analisaram como os índices do mercado acionário internacional ajustaram suas respostas à medida que a guerra persistia e constataram que o impacto foi mais forte no início da guerra (especialmente duas semanas após a invasão), tornando-se mais fraco três a quatro semanas depois. Quanto à avaliação sobre a intensidade do impacto em países geograficamente próximos à Ucrânia e à Rússia, os autores constataram que os índices do mercado de ações desses países foram mais afetados pela guerra. Por fim, eles observaram uma reação negativa do mercado acionário, tanto para os países que condenaram a invasão quanto para aqueles que permaneceram neutros.

É esperado, nos mercados mundiais, que a guerra tenha efeitos sobre a economia global e especificamente sobre a inflação, devido ao aumento da incerteza e dos riscos de resultados adversos graves (Dario, Conlisk, Iacoviello, & Penn, 2022). Na prática, alguns desses efeitos se materializaram, como a contração das economias russa e ucraniana, resultante das sanções impostas à Rússia. Os mercados de *commodities* estão em turbulência e os financeiros sofrem altas volatilidades desde o início do conflito. Para Dario *et al.* (2022), os efeitos adversos dos riscos geopolíticos sugerem que o impacto nas economias europeias provavelmente será maior, especialmente nos setores de produção de bens. Na visão desses autores, os efeitos econômicos do conflito provavelmente irão variar por tipo de setor e parecer mais concentrados nos setores de produção de bens, que já vinham enfrentando gargalos antes da invasão. Enquanto isso, os setores menos afetados por interrupções no fornecimento (como o de serviços) expressam menor preocupação com a guerra.

A agência britânica Reuters (Reuters, agosto/2022) corrobora que tais recessões atingiram *commodities* críticas como os preços do gás, essenciais nas residências e indústrias europeias, que mais que triplicaram desde junho/2022, e possivelmente levarão ao racionamento futuro de energia. Nesse cenário, o Banco Central Europeu, o Banco da Inglaterra e outros bancos centrais tentam baixar a inflação elevada pelos altos custos de energia, mesmo provocando taxas de juros mais altas (Reuters, agosto/2022). O aumento nos preços da energia e dos alimentos, associado às tensões da cadeia de suprimentos pós-pandemia, já havia elevado as taxas de inflação em todo o mundo a níveis vistos pela última vez na década de 1970. Isso impulsionou os custos de empréstimos e as preocupações com a inadimplência, conduzindo à

queda expressiva do euro em 2022, superior a qualquer período desde sua introdução em 1999 (Reuters, agosto/2022).

Também segundo a Reuters (Reuters, agosto/2022), os mercados acionários europeus da Alemanha e Itália tiveram os piores desempenhos em 2022, assim como a Polônia e a Hungria. Os indicadores de volatilidade dos mercados, desde ações e títulos até o petróleo e a taxa de câmbio euro-dólar, dispararam após a invasão da Ucrânia; porém, voltaram a subir à medida que as preocupações com energia e recessão aumentaram novamente (Reuters, agosto/2022). A Ucrânia ficou inadimplente com a destruição da sua economia e finanças, e as sanções levaram a Rússia à sua primeira inadimplência de dívida soberana em décadas, com mais de US\$ 25 bilhões da dívida corporativa (Reuters, agosto/2022).

Em relação ao impacto da crise na Rússia sobre outras economias, o trabalho de Lo *et al.* (2022) analisou o impacto da GR-U em 73 países, cujas economias estão condicionadas à dependência das *commodities* russas, e os resultados mostram que os mercados financeiros reagiram à guerra, diminuindo os retornos de ativos e aumentando a volatilidade. Nesse contexto, os autores declaram que os mercados financeiros percebem a dependência das *commodities* russas como um fator de risco para o declínio dos retornos e aumento da sua instabilidade. Três fatores originários da guerra que exercem efeito sobre os mercados financeiros foram identificados por Lo *et al.* (2022): (i) a inter-relação do mercado de petróleo entre União Europeia (EU) e Rússia; (ii) a dependência das economias em relação às *commodities* russas; e (iii) as interrupções na cadeia de suprimentos global, uma vez que Rússia e Ucrânia são os principais produtores mundiais de metais empregados em setores como o de níquel e paládio.

O relatório da OCDE (OECD, 2022) reafirma o impacto da GR-U sobre a queda do crescimento econômico e seus efeitos negativos sobre os mercados e as instituições financeiras. A entidade baseou sua análise na demanda e nas interrupções na cadeia de suprimentos no ambiente pós-Covid-19, antes da invasão da Rússia na Ucrânia, concluindo que elas contribuíram para aumentos substanciais nos preços das *commodities* e dos custos dos insumos; e posteriormente, o aumento das pressões inflacionárias fez com que vários bancos centrais comesçassem a aumentar suas taxas de juros. Desde o final de fevereiro de 2022, as condições dos mercados de crédito corporativo e soberano se deterioraram substancialmente além do mercado russo, principalmente em países emergentes na Europa e na Ásia.

A combinação de incerteza geopolítica, preços mais altos de *commodities*, sanções e interrupções nos negócios regionais contribuíram para o aumento da volatilidade e da aversão

ao risco. A volatilidade aumentou substancialmente nos mercados de ações e do Tesouro dos EUA, com os investidores preocupados com o aumento nos preços globais das *commodities* e os aumentos das taxas da política monetária para lidar com a inflação elevada (OECD, 2022). Depois de uma deterioração inicial do apetite pelo risco após a invasão russa na Ucrânia, o desempenho dos mercados acionários globais e as condições do mercado de crédito melhoraram desde meados de março/2022, quando os investidores reavaliaram sua perspectiva para os ativos de risco e se tornaram menos avessos a ele. No entanto, os preços elevados das *commodities* correram o risco de alimentarem ainda mais a alta inflacionária em todo o mundo, corroendo o poder de compra e os lucros das empresas, aumentando os riscos financeiros (OECD, 2022).

O impacto da invasão da Ucrânia, sobre as perspectivas econômicas e de inflação, está sendo transmitido para o cenário de crédito global, por meio dos seguintes eventos relacionados no Quadro IV.1.

Quadro IV.1 – GR-U: Perspectivas Econômicas sobre o Crédito Global

Evento	Motivo
Níveis elevados de dívida soberana e altas necessidades de refinanciamento	As pressões inflacionárias e o aperto das condições monetárias aumentaram os riscos de refinanciamento em muitas economias da OCDE.
Dívida elevada das empresas combinada com a deterioração da qualidade do crédito	O enfraquecimento das perspectivas econômicas e o aumento dos custos de refinanciamento com taxas de juros mais altas resultariam em inadimplências que podem minar a resistência dos intermediários financeiros e dos produtos financeiros estruturados.
Aumento do risco para os bancos devido à deterioração da qualidade do crédito e às sanções	Níveis elevados de endividamento do setor privado e o risco de deterioração da qualidade de crédito em meio ao enfraquecimento das economias, exacerbados pelo aumento dos preços das <i>commodities</i> após a invasão na Ucrânia, poderiam levar a um aumento substancial dos NPLs (<i>non-performing loans</i>) e aumentar o risco de crédito de contraparte de suas exposições a instituições financeiras não bancárias.
Aumento do risco de refinanciamento das economias de mercados emergentes (EMEs)	As preocupações com a sustentabilidade da dívida estão aumentando o risco de refinanciamento para emissores soberanos e corporativos altamente endividados; as EMEs com vínculos diretos com a Rússia e a Ucrânia seriam particularmente vulneráveis a interrupções na cadeia de suprimentos de <i>commodities</i> e a relações comerciais expressivas que poderiam contribuir para enfraquecer o crescimento econômico e estimular ainda mais a inflação.
Crescentes fragilidades do mercado e preocupações com a integridade em mercados financeiros alternativos	A emissão de <i>stablecoin</i> cresceu substancialmente nos últimos anos, mas é vulnerável a mudanças repentinas no sentimento de risco dos investidores; seus resgates em massa poderiam causar vendas forçadas de ativos de reserva subjacentes e repercussões negativas nos mercados financeiros tradicionais. Além disso, a guerra na Ucrânia levanta implicações para oportunidades e abordagens de investimento sustentável, como a classificação ESG.

Fonte: Elaborado pela autora (OECD, 2022).

IV.3 Metodologia

IV.3.1 Delimitação da pesquisa, população e amostra

Delimitação da pesquisa

Esta pesquisa tem abordagem descritiva e quantitativa. Descritiva porque descreve as características de uma população com o objetivo de identificar relações possíveis entre as variáveis analisadas. E quantitativa uma vez que foram analisados dados numéricos secundários, relacionados ao desempenho financeiros das empresas da B3 e aos preços de suas ações, analisados por meio de técnicas estatísticas. Com relação aos objetivos, este estudo é descritivo uma vez que descreveu uma população para fins de análise das relações existentes entre variáveis relativas a ela. Creswell (2007) definiu uma técnica quantitativa como aquela na qual o pesquisador utiliza alegações pós-positivistas para desenvolver um conhecimento ou empregar estratégias de investigação.

A abordagem quantitativa foi aplicada neste estudo para mensurar o desempenho financeiro das empresas listadas na B3 em conjunto, sendo o período de análise entre janeiro/2019 até dezembro/2021, abordando a pré-pandemia da Covid-19 até o quarto trimestre de 2021, quando a vacinação da pandemia no Brasil estava encerrando o ciclo da 2ª dose. O primeiro trimestre de 2022 até o 1º trimestre de 2023 envolve a guerra entre Rússia e Ucrânia, que, apesar de ainda estar em curso, tem provocado efeitos relevantes nas economias mundiais e no Brasil, conforme evidenciado nos estudos da seção anterior de Revisão da Literatura.

População e amostra

O desenvolvimento desta pesquisa foi embasado em dados financeiros trimestrais da população de empresas listadas na B3, coletados no banco de dados Refinitiv e nos documentos publicados pelo setor de Relações com Investidores dos sites das empresas pesquisadas. Para a amostra, foram selecionadas as empresas participantes da B3 no período entre 1T2019 e 1T2023, exceto aquelas pertencentes ao setor de serviços financeiros, por se tratarem de organizações cuja atividade-fim é a regulação/administração do capital financeiro, e portanto, diferindo dos demais setores econômicos em relação à legislação e aos dados publicados.

IV.3.2 Definição de indicadores e *proxies* para mensurar o desempenho financeiro

A análise das demonstrações financeiras possibilita a avaliação do desempenho geral da organização, permitindo diagnosticar a situação presente e prever tendências futuras. A utilização de indicadores representa o procedimento mais usualmente empregado; porém, um

indicador isolado pode não conter informações significantes, sendo importante mensurar o desempenho por meio de um conjunto de indicadores comparados temporal e setorialmente.

Flach e Mattos (2020) analisaram alguns trabalhos referentes ao estudo do desempenho financeiro de empresas de capital aberto, e sua relação com os retornos das respectivas ações. Nos trabalhos analisados, os autores identificaram indicadores e *proxies* comumente utilizados na análise do desempenho financeiro, quais sejam:

- indicadores de Liquidez – *proxies*: liquidez seca, corrente, geral, absoluta e capital de giro;
- indicadores de Prazos Médios e de Giro – *proxies*: Prazo Médio de Recebimento de Vendas, Giro das Duplicatas a Receber, Prazo Médio de Pagamento de Compras, Giro das Contas a Pagar, Prazo Médio de Renovação de Estoques, Giro dos Estoques, de Ativo Permanente, de Ativo Total, de Patrimônio Líquido e de Ativo Operacional;
- indicadores de Endividamento – *proxies*: Endividamento Geral, Exigível a Longo Prazo/Patrimônio Líquido, Capitalização a Longo Prazo, Participação de Capitais de Terceiros, Composição do Endividamento, Imobilização do Capital Próprio, Imobilização do Patrimônio Líquido, Imobilização dos Recursos Não Correntes, Fluxo de Caixa/Passivo Exigível Total, Fluxo de Caixa/Financiamentos a Longo Prazo e Garantia de Capital de Terceiros;
- indicadores de Rentabilidade – *proxies*: Retorno sobre o Ativo Total, Retorno sobre o Patrimônio Líquido, Retorno sobre o Capital Social Realizado e Retorno sobre o Investimento Operacional;
- indicadores de Lucratividade – *proxies*: Margem Bruta, Margem Operacional, Margem Não Operacional, Margem Líquida, Lucro por Ação (LPA) e Índice Preço/Lucro (P/L).

Considerando a literatura, para esta pesquisa, foram selecionados os indicadores e suas respectivas *proxies*, apresentados no Quadro II.2. Observam-se que as *proxies* ROA, ROE, Margem EBITDA, Margem EBIT, P/L e *Price to Book Value* foram disponibilizadas no Refinitiv e nos relatórios das empresas, enquanto as *proxies* ROIC, Índice de Endividamento, Índice de Cobertura, Liquidez Geral, Liquidez Corrente, Liquidez Seca e Q de Tobin foram calculadas utilizando as fórmulas correspondentes no Quadro II.2, a partir de índices fornecidos pelo Refinitiv e pelos relatórios das empresas.

Quadro IV.2 – Indicadores e Proxies para Avaliação do Desempenho Financeiro das Empresas

<i>Proxy</i>	<i>Definição da Proxy</i>	<i>Fórmula</i>
RENTABILIDADE		
Retorno sobre o Ativo Total (ROA)	Mede a eficácia da administração na geração de lucros a partir dos ativos disponíveis.	$ROA = \frac{\text{Lucro Líquido}}{\text{Ativos Circulante} + \text{Não Circulante}}$
Retorno sobre o Capital Próprio (ROE)	Mede o retorno sobre o investimento, ou lucro/patrimônio líquido.	$ROE = \frac{\text{Lucro Líquido}}{\text{Patrimônio Líquido}}$
Retorno sobre o Capital Investido (ROIC)	Mede a eficiência de uma empresa em gerar retorno com o uso de capital próprio e de terceiros.	$ROIC = \frac{[1 - (IR/100)] \times \text{EBIT}}{\text{Capital Investido}}$
LUCRATIVIDADE		
Margem EBITDA	Mede o percentual de cada unidade monetária vendida, após descontados todos os custos e despesas.	$\text{Margem EBITDA} = \frac{\text{EBITDA}}{\text{Receita Líquida Operacional}}$
Preço/Lucro (P/L)	Relaciona o valor de mercado da ação com o lucro da empresa.	$P/L = \frac{\text{Preço Médio da Ação}}{\text{Lucro Líquido}}$
Margem EBIT	Mede a lucratividade da empresa desconsiderando juros e impostos.	$\text{Margem EBIT} = \frac{\text{EBIT}}{\text{Receita Líquida Operacional}}$
ESTRUTURA DE CAPITAL		
Índice de Endividamento	Mede o ativo total financiado (quanto mais elevado o índice, maior o montante de capital de terceiros usado para gerar lucro).	$\text{Índice de Endividamento} = \frac{\text{Passivos Circulante} + \text{Não Circulante}}{\text{Patrimônio Líquido}}$
Índice de Cobertura	Reflete a capacidade da empresa para realizar os pagamentos necessários ao longo da vigência de uma dívida (é a capacidade de serviço de dívidas).	$\text{Índice de Cobertura} = \frac{\text{EBIT}}{\text{Despesas Financeiras}}$
LIQUIDEZ		
Liquidez Geral	É a solvência da posição financeira geral da empresa.	$\text{Liquidez Geral} = \frac{(\text{Ativo Circulante} + \text{Ativo Realizável a Longo Prazo})}{\text{Passivos Circulante} + \text{Não Circulante}}$
Liquidez Corrente	Mede a capacidade da empresa de pagar suas obrigações de curto prazo.	$\text{Liquidez Corrente} = \frac{\text{Ativo Circulante}}{\text{Passivo Circulante}}$
Liquidez Seca	É a capacidade da empresa de pagar suas obrigações de curto prazo, exceto o estoque.	$\text{Liquidez Seca} = \frac{\text{Ativo Circulante} - \text{Estoque}}{\text{Passivo Circulante}}$
INDICADORES ECONÔMICOS		

Q de Tobin	É o valor de mercado do ativo menos a dívida, dividido pelo ativo total da empresa. A dívida representa a soma dos empréstimos de curto e longo prazos.	Q de Tobin = $\frac{[(N.^{\circ} \text{ Médio de Ações em Circulação} \times \text{Preço Médio da Ação}) + \text{Empréstimos e Obrigações de Curto e Longo Prazo}]}{(\text{Ativos Circulante} + \text{Não Circulante})}$
Price to Book Value	É o preço da ação sobre a relação entre o patrimônio líquido e o número de ações da empresa (valor contábil).	Price to Book Value = $\frac{\text{Preço Médio da Ação}}{(\text{Patrimônio Líquido} / N.^{\circ} \text{ Médio de Ações em Circulação})}$

Elaborado pela autora.

IV.3.3 Coleta dos dados

As duas amostras consistiram nas empresas da B3, analisadas no período entre 1T2019 e 4T2021 para a Covid-19, em intervalos trimestrais, enquanto a análise da guerra entre Rússia e Ucrânia envolveu o período entre 1T2022 e 1T2023, também em intervalos trimestrais. Os números de observações do indicador financeiro e por cada uma de suas *proxies* estão descritos na Tabela IV.1.

Tabela IV.1 – N.º de observações do Desempenho Financeiro e por suas *proxies*, para Análise de Desempenho Financeiro

	Obs. Covid-19	Obs. Guerra Russo-Ucraniana
Desempenho Financeiro	2.831	1.495
Proxies		
ROA	2.880	1.495
ROE	2.424	1.290
ROIC	3.132	1.275
Margem EBITDA	3.552	1.475
Margem EBIT	3.564	1.480
Preço/Lucro	1.920	1.015
Liquidez Geral	3.312	1.490
Liquidez Corrente	3.564	1.485
Liquidez Seca	3.324	1.495
Índice de Endividamento	1.680	1.495
Índice de Cobertura	3.228	1.380
Q de Tobin	3.324	1.786
Price to Book Value	3.000	1.455

Fonte: Dados de pesquisa, a partir das informações do banco de dados Refinitv (maio/2023).

Nota: A fim de evitar a influência de empresas individuais sobre o resultado da média geral de um setor específico, e garantir que todas possuem dados publicados, relativos aos períodos considerados nesta pesquisa, foram selecionadas as empresas com situação CVM⁷ ativa.

⁷ CVM – Comissão de Valores Mobiliários: criada pela Lei 6.385 de 07/12/1976, disciplina o mercado de valores mobiliários, podendo auditar as demonstrações contábeis de companhias abertas, entre outras.

IV.3.4 Regressão de dados em painel

Em séries temporais são observados os valores de uma ou mais variáveis em um período de tempo, e os cortes transversais nestas séries permitem coletar dados de uma ou mais variáveis de um grupo amostral, no mesmo intervalo de tempo. A análise de dados em painel tem, portanto, uma dimensão espacial e outra temporal, e as séries temporais podem ser analisadas nestas dimensões mediante regressão, chamada de análise de dados em painel, amplamente utilizada em pesquisas nas áreas financeira e econômica.

Entre as vantagens da metodologia de dados em painel sobre dados de corte transversal ou de séries temporais, Baltagi (1995) ressalta as seguintes:

- Pelo fato de os dados em painel se relacionarem a indivíduos, com o tempo, tende a haver heterogeneidade nessas unidades;
- Combinando séries temporais com observações de corte transversal, os dados em painel oferecem mais informações, variabilidade e graus de liberdade entre as variáveis, e menos colinearidade, constituindo uma técnica de análise mais eficiente, uma vez que ela se torna mais adequada para examinar a dinâmica da mudança ao longo da série;
- Os dados em painel podem detectar e medir melhor os efeitos que não podem ser observados em um corte transversal puro ou em uma série temporal pura, inclusive em modelos de comportamento mais complicados. Ademais, ao lidar com grande número de dados, minimizam eventuais vieses resultantes da análise de um agregado de indivíduos (como empresas, por exemplo).

O método de dados de painel para análise de dados ao longo do tempo para as mesmas unidades de seção transversal é útil pela possibilidade de observação das relações dinâmicas entre elas e pelo controle da heterogeneidade não observada da seção cruzada. O autor lembra ainda que, para aplicar as estatísticas do Método dos Mínimos Quadrados (MMQ) na análise em painel, é necessário que a série temporal apresente homocedasticidade e ausência de correlação serial.

Os painéis possíveis se diferenciam de acordo com certas características; assim, o painel é chamado balanceado quando cada unidade de corte transversal (empresas, indivíduos etc.) tem o mesmo número de observações (ou dados). Porém, se cada unidade tiver um número diferente de observações, o painel é desbalanceado. Os autores declaram ainda que os painéis podem ser curtos ou longos — em um painel curto, o número de indivíduos de corte transversal é maior que o número de períodos de tempo analisados, enquanto, em um painel longo, ocorre

o contrário. Para cada modelo de painel, existe uma técnica de estimação de variáveis adequada, descrita no Quadro II.3.

Quadro IV.3 – Modelos de Dados em Painel

Modelo de Painel	Estimação da Regressão
MQO para dados empilhados (<i>pooled data</i>)	Observações empilhadas, desprezando a natureza de corte transversal e de séries temporais. Todos os coeficientes de regressão são estatisticamente significativos, e o valor R^2 é muito alto. É possível não haver autocorrelação e/ou correlação espacial nos dados. O modelo não faz distinção entre os indivíduos da amostra e nem se os valores das variáveis explanatórias no tempo são os mesmos para todos os indivíduos, ou seja, uma eventual heterogeneidade da amostra seria camuflada.
Mínimos quadrados com variáveis <i>dummies</i> para efeitos fixos (MQVD)	Cada unidade de corte transversal tem sua própria variável <i>dummy</i> (intercepto), de forma que há heterogeneidade entre indivíduos, de maneira que existe uma correlação arbitrária entre o efeito (ou heterogeneidade) não observado e as variáveis explicativas observadas. Assim, embora o intercepto possa diferir entre os indivíduos, ele não varia com o tempo. A diferença entre os modelos <i>pooled</i> e de efeitos fixos é que o segundo apresenta vários problemas: (i) ao introduzir muitas variáveis <i>dummies</i> , haverá falta de graus de liberdade (ou ausência de observações suficientes para fazer uma análise estatística significativa); (ii) com diversas variáveis <i>dummies</i> , tanto individuais quanto interativas ou multiplicativas, existe a possibilidade de multicolinearidade, o que dificultaria a estimação exata de um ou mais parâmetros; (iii) em algumas situações, o modelo de efeitos fixos pode não identificar o impacto das variáveis que não mudam ao longo do tempo.
Efeitos fixos dentro de um grupo (<i>fixed effects within-group model</i>)	Ao combinar todas as observações, e para cada uma, expressar cada variável como um desvio de seu valor médio, estima-se uma regressão de MQO contra esses valores corrigidos para a média.
Efeitos aleatórios (MEA)	Se as variáveis <i>dummies</i> representam a falta de conhecimento sobre o modelo real, isso é expresso por meio do termo de erro (ou efeito não observado), que, em um modelo de efeito aleatório, não tem correlação com as variáveis explicativas observadas. Assim, as variáveis têm um valor médio comum para o intercepto, e as diferenças individuais se refletem no termo de erro, que consiste em dois componentes: o de corte transversal (específico dos indivíduos), e o termo de erro combinado da série temporal e corte transversal, chamado de termo de erro idiossincrático, pois varia com o indivíduo e com o tempo. Ademais, a correlação serial no erro é avaliada pelo Método dos Mínimos Quadrados Generalizados (MMQG) e precisa de exogeneidade estrita entre as variáveis explicativas e o erro composto.

Elaborado pela autora.

Fontes: Wooldridge (1999).

Duarte, Lamounier e Takamatsu (2007) ilustram o modelo geral para dados em painel que, adaptado para a pesquisa deste capítulo da tese, foi utilizado na mensuração do desempenho financeiro das empresas da B3, conforme amostra definida no início desta seção. O modelo envolveu uma regressão linear dos cinco indicadores descritos no Quadro 4, a qual está representada pela equação (3). Esses indicadores, por sua vez, foram obtidos por meio de regressões de suas respectivas *proxies* (Quadro 4), apresentadas pelas equações (4), (5), (6), (7) e (8):

$$DF_{it} = \beta_{0it} + \beta_{1it}RENT_{1it} + \beta_{2it}LUCR_{2it} + \beta_{3it}EC_{3it} + \beta_{4it}LIQ_{4it} + \beta_{5it}IE_{5it} + \varepsilon_{it} \quad (3),$$

em que DF_{it} = desempenho financeiro de cada empresa i analisada no período t ; β_{0it} = parâmetro de intercepto; β_{1it} a β_{5it} = coeficientes correspondentes a cada indicador (variável explicativa) do modelo; $RENT_{1it}$, $LUCR_{2it}$, EC_{3it} , LIQ_{4it} , IE_{5it} = indicadores financeiros e econômicos (*proxies* de DF) e ϵ_{it} = erro idiossincrático (varia aleatoriamente para todas as empresas e períodos).

O indicador de rentabilidade das empresas é expresso por:

$$RENT_{it} = \beta_{0it} + \beta_{1it}ROA_{1it} + \beta_{2it}ROE_{2it} + \beta_{3it}ROIC_{3it} + \epsilon_{it} \quad (4)$$

em que $RENT_{it}$ = rentabilidade de para cada empresa i analisada no período t ; β_{0it} = parâmetro de intercepto; β_{1it} a β_{4it} = coeficientes correspondentes a cada *proxy* explicativa do modelo; ROA_{1it} , ROE_{2it} , $ROIC_{3it}$, = *proxies* da rentabilidade e ϵ_{it} = erro idiossincrático (varia aleatoriamente para todas as empresas e períodos).

A lucratividade das empresas é dada por:

$$LUCR_{it} = \beta_{0it} + \beta_{1it}P/L_{1it} + \beta_{2it}MEBIT_{2it} + \beta_{3it}MEBITDA_{3it} + \epsilon_{it} \quad (5),$$

em que $LUCR_{it}$ = lucratividade de cada empresa i analisada no período t ; β_{0it} = parâmetro de intercepto; β_{1it} a β_{3it} = coeficientes correspondentes a cada *proxy* explicativa do modelo; P/L_{1it} , $MEBIT_{2it}$, $MEBITDA_{3it}$ = *proxies* da lucratividade e ϵ_{it} = erro idiossincrático (varia aleatoriamente para todas as empresas e períodos).

A estrutura de capital é representada por:

$$EC_{it} = \beta_{0it} + \beta_{1it}ENDV_{1it} + \beta_{2it}COB_{2it} + \epsilon_{it} \quad (6),$$

em que EC_{it} = estrutura de capital de cada empresa i analisada no período t ; β_{0it} = parâmetro de intercepto; β_{1it} e β_{2it} = coeficientes correspondentes a cada *proxy* explicativa do modelo; $ENDV_{1it}$, COB_{2it} = *proxies* da estrutura de capital e ϵ_{it} = erro idiossincrático (varia aleatoriamente para todas as empresas e períodos).

O indicador de liquidez das empresas é expresso por:

$$LIQ_{it} = \beta_{0it} + \beta_{1it}LGE_{1it} + \beta_{2it}LSE_{2it} + \beta_{3it}LCO_{3it} + \epsilon_{it} \quad (7),$$

em que LIQ_{it} = liquidez total de cada empresa i analisada no período t ; β_{0it} = parâmetro de intercepto; β_{1it} a β_{3it} = coeficientes correspondentes a cada *proxy* explicativa do modelo; LGE_{1it} , LSE_{2it} , LCO_{3it} = *proxies* da liquidez e ϵ_{it} = erro idiossincrático (varia aleatoriamente para todas as empresas e períodos).

Finalmente, dois indicadores econômicos de mercado foram definidos por:

$$IE_{it} = \beta_{0it} + \beta_{1it}QTB_{1it} + \beta_{2it}PBV_{2it} + \epsilon_{it} \quad (8),$$

em que IE_{it} = indicadores econômicos para cada empresa i analisada no período t ; β_{0it} = parâmetro de intercepto; β_{1it} e β_{2it} = coeficientes correspondentes a cada *proxy* explicativa do

modelo; QTB_{1it} , PBV_{2it} = *proxies* de indicadores econômicos e ϵ_{it} = erro idiossincrático (varia aleatoriamente para todas as empresas e períodos).

Para proceder à escolha entre os modelos de efeito fixo e de efeito aleatório, pode-se aplicar o teste de Hausman, cuja hipótese nula afirma que os estimadores de ambos não diferem substancialmente. O teste de Hausman tem uma distribuição assintótica, de forma que, se a hipótese nula for rejeitada, a conclusão é que o modelo efeito aleatório não é adequado, porque os efeitos aleatórios provavelmente estão correlacionados com um ou mais regressores, e deve-se aplicar o modelo de efeitos fixos na análise.

Além do teste de Hausman, pode ser aplicado também o teste de Breusch-Pagan para verificar a hipótese de que não há efeitos aleatórios na amostra da série temporal. Sob a hipótese nula, o teste de Breusch-Pagan segue uma distribuição χ^2 com 1 grau de liberdade porque testa-se a hipótese única de que a variância é zero. A análise deve ser iniciada a análise com o teste de Breusch-Pagan para comparar o modelo de efeitos aleatórios com o *pooled*; se o resultado indicar que a variância dos efeitos não observáveis é zero, deve-se usar o *pooled*; caso contrário, utiliza-se o modelo de efeitos aleatórios. Aplica-se o teste de Hausman para comparar os modelos de efeitos fixos e efeitos aleatórios: se o resultado indicar que a correlação entre os efeitos não observáveis e as variáveis é zero, utiliza-se o modelo de efeitos aleatórios; caso contrário, utiliza-se o modelo de efeitos fixos.

Na análise de efeitos fixos podem ser estimados, consistentemente, os efeitos parciais na presença de variáveis constantes no tempo que podem ser arbitrariamente relacionadas aos efeitos observáveis. Nesse aspecto, esta análise é mais robusta do que a de efeitos aleatórios; porém, o autor alerta que tal robustez tem um preço: sem outras suposições, não se podem incluir fatores constantes no tempo na série temporal, uma vez que, se a variável não observada puder ser arbitrariamente correlacionada com cada variável observada, não há como distinguir os efeitos observáveis constantes no tempo daqueles não observáveis constantes no tempo. Após a seleção do modelo adequado, serão realizados testes de autocorrelação, multicolinearidade, normalidade dos resíduos e homoscedasticidade para verificar se as premissas do modelo selecionado foram cumpridas.

A decisão entre o uso de um modelo de efeito fixo ou aleatório depende, sobretudo, da premissa sobre a provável correlação entre o componente de erro específico ao corte transversal ou individual e os regressores. Se o erro e os regressores não estão correlacionados, o modelo de efeito aleatório pode ser adequado; mas, se estiverem correlacionados, o modelo de efeitos

fixos pode ser adequado. A hipótese subjacente ao modelo de efeito aleatório é que os erros são extrações aleatórias de uma população muito maior.

IV.3.5 Análise de dados

Para testar H_3 e H_4 foi aplicada a metodologia de análise de dados em painel desbalanceado, com o suporte do *software* de tratamento estatístico Rstudio. Os dados inseridos no R foram obtidos mediante cálculos de indicadores financeiros obtidos na base de dados Refinitiv.

Após a coleta dos dados, os mesmos foram tratados para identificar a presença de *outliers*, e aplicou-se a técnica de “Winsorização” das séries temporais das duas crises, com limites inferior de 5% e superior de 95%. Tal técnica consiste em substituir *outliers* (valores fora dos limites inferior e superior) pelos valores mínimo e máximo correspondentes a esses limites estabelecidos (Fortunato, Funchal & Da Motta, 2012), e tem a vantagem de não descartar os *outliers*, que compuseram os cálculos sem distorção das estimativas estatísticas.

IV.4 Análise e discussão dos resultados

IV.4.1 Estatísticas descritivas e gráficos das séries temporais

Primeiramente foram calculadas as estatísticas descritivas para cada amostra (Tabela II.1) e obtidos os gráficos das séries temporais para cada *proxy*, de ambas as amostras (Figuras II.2^a, b, c, d, e, f, g, h, i, j, k, l, m).

Tabela IV.2 – Estatísticas descritivas na pandemia e no início da GR-U

<i>Proxies</i>	Covid-19			Guerra Russo-Ucraniana		
	Média	Mediana	DesvPad	Média	Mediana	DesvPad
ROA (%)	2,4	3,7	15	4,6	4,4	12
ROE (%)	11	10	40	15	12	36
ROIC (%)	130	0,0	4.400	-1.129	0,0	12.943
Margem EBITDA	0,14	0,16	0,39	0,20	0,17	0,52
Margem EBIT	0,046	0,11	0,44	0,16	0,11	0,67
Preço/Lucro	21	10	37	24	8,1	189
Liquidez Geral	0,94	0,66	1,1	1,1	0,71	1,3
Liquidez Corrente	2,2	1,5	3,6	2,2	1,6	2,9
Liquidez Seca	1,9	1,5	1,6	2,0	1,4	2,9
Índice de Endividamento	1,8	1,2	4,5	7,8	1,3	125
Índice de Cobertura	-0,19	0,0	0,58	-1,1	0,0	3,2
Q de Tobin	1,3	0,82	2,6	1,2	0,78	2,2
<i>Price to Book Value</i>	2,5	1,1	5,6	1,6	1,1	2,6

Fonte: dados de pesquisa.

Entre as *proxies* de rentabilidade para as empresas na Covid-19, todas apresentaram valores positivos e acima de 1%, apontando para retornos superiores aos investimentos realizados no período. No caso do ROIC, a superioridade do desvio-padrão em relação à média indica que este retorno sobre o capital investido tem uma alta variabilidade na amostra. No início da GR-U, o ROA e ROE seguiram o comportamento na Covid-19, porém o ROIC foi negativo, indicando ausência de lucro sobre o investimento e apresentando também alta variabilidade entre as empresas da amostra.

Sobre a lucratividade das empresas da B3 na amostra da Covid-19 e na GR-U, e as Margens EBITDA abaixo de 1 significam que as empresas da B3, em média, geraram pouco lucro operacional, ou operaram com prejuízo (“lucro negativo”), sendo esse resultado condizente com a rentabilidade. Nesse sentido, a maioria da receita foi consumida pelos custos de operação, demonstrando ineficiência operacional para cobertura dos custos fixos e despesas financeiras. Da mesma forma, a Margem EBIT abaixo de 1 indicou que o lucro operacional das empresas esteve muito baixo em relação às respectivas receitas, antes de pagar juros e impostos.

Por outro lado, os resultados do Preço/Lucro acima de 20 implicam que as empresas estavam valorizadas no mercado (as ações tinham preços elevados sobre seus lucros). Esses resultados sugeriram que, apesar de as empresas terem uma estrutura de custos fixos altos ou variáveis que reduziam a rentabilidade operacional, o Preço/Lucro alto indica que os investidores tinham expectativas de crescimento significativo dos lucros no futuro, indicando uma confiança do mercado nas empresas mesmo em meio a crises mundiais, especialmente a Covid-19 que impactou diretamente o Brasil em diversos aspectos.

Sobre a liquidez geral abaixo de 0,94 na Covid-19, é um indicativo de que as empresas enfrentaram alguma dificuldade para pagar suas dívidas, enquanto, na GR-U, seu valor de 1,1 indicou a presença de mais ativos disponíveis do que de dívidas nas empresas. A liquidez corrente igual a 2,2 em ambas as crises mostra que as empresas possuíam mais ativos circulantes do que passivos circulantes, indicando uma boa margem de segurança. Em relação à liquidez seca, os valores próximos em ambas as crises (1,9 e 2) mostraram as capacidades das empresas de cobrirem suas dívidas de curto prazo sem depender da venda de estoques, sendo este um bom sinal de liquidez.

A estrutura de capital apresentou resultados ruins em relação ao índice de endividamento, e em ambas as crises o valor acima de 1 indicou que as empresas tinham mais dívidas do que patrimônio líquido. No 1º semestre de 2022, esse índice foi cerca de 4 vezes superior que na pandemia. Em termos práticos, esse resultado sugere que as empresas da B3 no

início da GR-U estavam mais alavancadas, aumentando os riscos financeiros caso não conseguissem gerar lucro para cumprir suas obrigações de pagamento de juros e amortização de dívida. Os índices de cobertura médios negativos em ambas as crises corroboraram os lucros operacionais baixos ou negativos antes de considerar os custos de juros, impostos e outras despesas não operacionais (EBIT), bem como os altos níveis de alavancagem financeira (endividamento) encontrados.

O Q de Tobin acima de 1 para ambos os períodos analisados indicou que o valor de mercado médio das empresas da B3 foi maior que o custo de reposição de seus ativos, ou seja, ocorreu uma valorização pelo mercado superior ao custo dos ativos das empresas. Em ambientes de crise econômica, como nos casos da Covid-19 e da GR-U, esses resultados podem ser explicados pela expectativa inicial de queda desses preços seguida de posterior sobrevalorização das ações, uma vez que, em momentos de alta insegurança e incerteza sobre o futuro, decisões irracionais dos investidores podem inflar os preços das ações além do valor intrínseco dos ativos.

Os resultados obtidos para o Q de Tobin na pandemia e na guerra foram corroborados por aqueles do *Price to Book Value* acima de 1, significando que os preços de mercado das ações das empresas foram negociados a valores superiores aos seus valores contábeis. Novamente, tem-se outra evidência de irracionalidade nas decisões dos investidores em momentos de insegurança sobre o mercado.

Os gráficos das Figuras IV.2^a, b, c, d, e, f, g, h, i, j, k, l, m ilustram os comportamentos das *proxies* da Tabela IV.2 durante os períodos de análise das crises da Covid-19 e da guerra entre Rússia e Ucrânia.




Figura IV.2^a – ROA na Covid-19 (esquerda) e início da GR-U (direita).

Fonte: dados de pesquisa.

Nos gráficos da Figura IV.2^a, observou-se que o ROA teve quedas em ambos os períodos

analisados, sendo estas mais acentuadas no 3º trimestre de 2020, quando a economia brasileira sofria mais fortemente os efeitos da pandemia com as restrições de mobilidade que impactaram o consumo; e durante o 1º semestre de 2022 quando a guerra na Ucrânia se iniciava trazendo incertezas econômicas ainda desconhecidas para o mercado.




Figura IV.2b – ROE na Covid-19 (esquerda) e início da GR-U (direita).

Fonte: dados de pesquisa.

Na Figura IV.2.b, o ROE das empresas da B3 sofreu a maior queda no período analisado da pandemia no início do 2º trimestre de 2020 até o 4º trimestre do mesmo ano. Para a guerra, ao contrário, o ROE apresentou um crescimento constante entre o 1º e 2º trimestres de 2022, sofrendo em seguida uma queda acentuada, comparativamente, até o 1º trimestre de 2023.




Figura IV.2c – ROIC na Covid-19 (esquerda) e início da GR-U (direita).

Fonte: dados de pesquisa.

O ROIC sofreu sua maior queda no início da pandemia durante o 2º trimestre de 2020 quando as empresas começaram a sofrer os primeiros impactos da baixa de demanda pela população, reclusa em casa. Já no início da GR-U, o ROIC manteve-se constante até junho/2022, quando caiu mais suavemente no final do 3º trimestre de 2022, ao sofrer uma queda bem mais acentuada até final de dezembro/2024.

A Figura IV.2d mostra que a Margem EBITDA sofreu quedas sucessivas entre o 2º e o 3º trimestres de 2020, recuperando parte desta queda a partir do 4º trimestre. Esse comportamento é coerente com aqueles da rentabilidade das empresas. Para a guerra, essa *proxy* teve seu pico (dentro do período analisado) no início do 2º trimestre de 2022, vindo de um crescimento pelo menos desde o final de 2021, sofrendo uma queda continuada a partir deste pico até o final do 3º trimestre de 2022, quando volta a crescer.




Figura IV.2d – Margem EBITDA na Covid-19 (esquerda) e início da GR-U (direita).

Fonte: dados de pesquisa.

Esses resultados foram diferentes daqueles encontrados na Tabela IV.2, pois, nesta, os cálculos envolveram todo o período, e não somente aqueles coloridos nos gráficos. Assim, para a Covid-19, este aumento da *proxy* no período especificado no gráfico pode ser devido à melhoria da eficiência operacional das empresas para enfrentar essa crise. Para a guerra, parece não haver um impacto inicial expressivo.




Figura IV.2e – Margem EBIT na Covid-19 (esquerda) e início da GR-U (direita).

Fonte: dados de pesquisa.

A Margem EBIT no início da pandemia teve um comportamento semelhante à Margem EBITDA, entretanto, para a guerra seu comportamento foi o oposto da Margem EBITDA; isso pode indicar a combinação de pressões de custo que afetaram o lucro operacional (Margem EBIT) e melhorias na eficiência operacional que também afetam lucro, porém positivamente (Margem EBITDA).




Figura IV.2f – Preço/Lucro na Covid-19 (esquerda) e início da GR-U (direita).
Fonte: dados de pesquisa.

Na Figura IV.2f, o Preço/Lucro apresentou uma tendência de crescimento no início da Covid-19, o que pode ser explicado pela supervalorização das ações em função da insegurança do mercado sobre como a pandemia afetaria as empresas. Em relação ao início da guerra entre Rússia e Ucrânia, essa *proxy* oscilou entre janeiro e junho de 2022 seguindo o comportamento da Margem EBIT.

No início da Covid-19, a liquidez geral e a corrente sofreram quedas ao longo de 2020, refletindo o desequilíbrio no ciclo econômico das empresas, que pode ser explicado pela queda dos empregos gerando baixa na renda para consumo. A liquidez seca teve um comportamento semelhante, porém com uma alta maior no 1º trimestre de 2020. Na guerra, as três *proxies* de liquidez comportaram-se de forma semelhante também, apresentando queda durante o 1º trimestre de 2022 e crescimento no 2º trimestre.




Figura IV.2g – Liquidez Geral na Covid-19 (esquerda) e início da GR-U (direita).
Fonte: dados de pesquisa.




Figura IV.2h – Liquidez Corrente na Covid-19 (esquerda) e início da GR-U (direita).
Fonte: dados de pesquisa.




Figura IV.2i – Liquidez Seca na Covid-19 (esquerda) e início da GR-U (direita).
Fonte: dados de pesquisa.

O índice de endividamento reduziu nos inícios de ambas as crises, até 3º trimestre de 2020 para a pandemia e 2º trimestre de 2022 para a guerra. Após esses períodos, ambas as *proxies* aumentaram, de forma contínua para a Covid-19, refletindo a alavancagem das

empresas durante o enfrentamento da crise econômica gerada. Para a guerra, o endividamento oscilou entre quedas e altas após o período inicial.




Figura IV.2j – Índice de Endividamento na Covid-19 (esquerda) e início da GR-U (direita).
Fonte: dados de pesquisa.

O índice de cobertura no início da pandemia teve uma queda no início do 2º trimestre de 2020 até início do 3º trimestre, quando passou a crescer até o 4º trimestre, seguindo o comportamento da lucratividade das empresas neste intervalo. No caso da guerra, esse índice manteve-se no mesmo patamar até o início do 4º trimestre de 2022. Este resultado não foi coerente com aquele da lucratividade, o que pode ser devido aos poucos dados presentes na amostra para esta *proxy*.




Figura IV.2k – Índice de Cobertura na Covid-19 (esquerda) e início da GR-U (direita).
Fonte: dados de pesquisa.

Na Figura IV.2l, o Q de Tobin no início da pandemia teve um período de queda e baixa entre o 1º trimestre de 2020 até o 1º trimestre de 2021, quando voltou a subir. O período de baixa mostrou uma desvalorização das empresas da B3 pelo mercado. Já no período inicial da invasão na Ucrânia, houve uma desvalorização do mercado até o final do 1º trimestre e um aumento da valorização a partir do início do 2º trimestre.




Figura IV.2l – Q de Tobin na Covid-19 (esquerda) e início da GR-U (direita).
Fonte: dados de pesquisa.

Os comportamentos da *proxy Price to Book Value* em ambas as crises foram semelhantes àqueles do Q de Tobin, corroborando a desvalorização inicial das ações das empresas pelo mercado, seguida da valorização após os períodos mais críticos economicamente de ambas as crises (Figura IV.2m).




Figura IV.2m – Price to Book Value na Covid-19 (esquerda) e início da GR-U (direita)
Fonte: dados de pesquisa.

Na seção seguinte, foram analisados os testes estatísticos dos dados em painel, que, juntamente aos resultados obtidos na presente seção, fundamentaram as conclusões sobre as hipóteses de pesquisa propostas para este capítulo.

II.4.2 Análise de dados em painel

As séries temporais das *proxies* do desempenho financeiro na Covid-19 e no início da guerra Russo-Ucraniana foram agrupadas em planilhas (painéis desbalanceados) de acordo com os indicadores descritos no Quadro IV.2. Após a winsorização os dados dos painéis, os mesmos

foram inseridos no R Studio para análises de regressão. Inicialmente, cada um dos painéis de desempenho financeiro foram testados e comparados para encontrar o melhor modelo de regressão para cada um (Tabela IV.3).

A comparação entre os modelos de efeitos fixos e aleatórios foi feita por meio da aplicação do teste de Hausman, que comparou os coeficientes obtidos em cada modelo. A premissa desse teste é que a hipótese nula (assumida com $p\text{-valor} \leq 5\%$) afirma que os coeficientes estimados pelos modelos de efeitos fixos e aleatórios são consistentes e eficientes, enquanto a hipótese alternativa (assumida com $p\text{-valor} > 5\%$) afirma que os coeficientes dos modelos de efeitos aleatórios não são eficientes.

Dessa forma, se o teste de Hausman rejeitar a hipótese nula, os efeitos aleatórios seriam ineficientes, e o modelo de efeitos fixos seria preferível. Por outro lado, se o teste não rejeitar a hipótese nula, ambos os modelos podem ser usados, com uma inclinação potencial para o de efeitos aleatórios devido à sua eficiência. O modelo *pooled* é geralmente menos eficiente que os modelos de efeitos fixos e aleatórios, porque desconsidera a heterogeneidade entre os dados das amostras, podendo mascarar o comportamento real das séries temporais.

Tabela IV.3 – Resultados dos testes de modelos de análises de dados em painel para o desempenho financeiro das empresas da B3 no início das crises da Covid-19 e da GR-U

Crise	R ²	Teste de Hausman	Estatística F	Teste de Breusch-Pagan	
Desempenho financeiro na Covid-19	1 (EF)	1.888,3***	1,9e+33***	1,0 (heteroced.)	556,5*** (autocor.)
Desempenho financeiro na GR-U	1 (EF)	6.090,8***	1,5e+32***	18.256 (heteroced.)	275*** (autocor.)

Fonte: dados de pesquisa.

Nota: p-valor: *** 0,001; ** 0,01; * 0,05; “.” 0,1.

(EF): efeitos fixos; (EA): efeitos aleatórios; (P): *pooled*.

O modelo de efeitos aleatórios sobre a série temporal do desempenho financeiro na Covid-19 não rodou devido à multicolinearidade presente entre as *proxies*; assim, foi calculado o *Variance Inflation Factor* (VIF) afim de identificar qual (is) *proxy(ies)* encontravam-se nesta condição. Os resultados apontaram para o ROIC e Índice de Cobertura, que estavam perfeitamente correlacionadas com as outras *proxies*, ou seja, estas poderiam ser representadas como combinações lineares das demais. Uma possível explicação para tal relação entre estas duas variáveis seria o fato de um valor de ROIC elevado resultar em maior capacidade da empresa gerar lucro, e aumentar o índice de cobertura, uma vez que maiores lucros significam mais recursos disponíveis para pagar dívidas da empresa. Dessa forma, as *proxies* ROIC e

Índice de Cobertura foram removidas do painel e o modelo de efeitos aleatórios foi rodado. Para fins de comparação, o modelo de efeitos fixos foi novamente rodado sem essas duas *proxies*.

Para a Covid-19, o modelo de efeitos fixos teve a menor Soma dos Quadrados dos Resíduos; ademais, o teste de Hausman foi estatisticamente significativo indicando a preferência do modelo de efeitos fixos sobre o modelo de efeitos aleatórios. Isso significa que as variáveis não observadas que afetam o desempenho financeiro estavam correlacionadas com as *proxies* utilizadas no modelo. Em contextos de crises financeiras, a significância do teste pode indicar que as relações entre as variáveis mudaram, exigindo um modelo que capture essas novas dinâmicas.

A estatística F significativa sinalizou que as *proxies* utilizadas explicavam o desempenho financeiro, podendo-se inferir que o comportamento das mesmas na crise da Covid-19 afetou o desempenho financeiro das empresas no período considerado. O teste de Breusch-Pagan para a heterocedasticidade foi não significativo, assumindo valores iguais para ambos os modelos – esse resultado mostrou a inexistência de evidências para rejeitar a hipótese nula de homocedasticidade, ou seja, os resíduos do modelo não apresentaram variação sistemática em relação às *proxies*. Com homoscedasticidade confirmada, os erros padrão dos coeficientes estimados foram considerados válidos.

Sobre a autocorrelação, o modelo de efeitos fixos teve um valor maior que o de efeitos aleatórios (ambos foram estatisticamente significantes), evidenciando a presença de correlação entre os erros ao longo do tempo ou entre as observações. Isso pode indicar que as variáveis não observadas ou a dinâmica temporal que afetam os erros foram mais pronunciadas no modelo de efeitos fixos. Esta maior autocorrelação sugeriu que esse modelo era mais sensível a padrões nos dados, sendo talvez necessária a inclusão de variáveis adicionais ou interações no modelo para garantir a validade das estimativas e inferências – isto não foi feito nesta pesquisa.

Na análise do desempenho financeiro das empresas da B3 no início da guerra na Ucrânia, o modelo de efeitos fixos mostrou-se também o mais adequado, porém, ao contrário do período pandêmico, não apresentou multicolinearidade entre as *proxies*. O modelo de efeitos fixos teve menor Soma dos Quadrados dos Resíduos que aquela dos efeitos aleatórios, e o teste de Hausman foi estatisticamente significativo, indicando que o modelo foi especificado corretamente em relação às variáveis utilizadas. A estatística F significativa sinalizou que as *proxies* utilizadas explicaram o desempenho financeiro, podendo-se inferir aqui também a

presença de impacto da guerra no desempenho das empresas da B3, o que contraria a hipótese de pesquisa H4.

O teste de Breusch-Pagan para a heterocedasticidade resultou em valores iguais para ambos os modelos, sugerindo que a variância dos erros não foi constante. A autocorrelação do modelo de efeitos fixos foi 10^{-9} vezes inferior àquela dos efeitos aleatórios (ambos estatisticamente significantes), indicando que os erros (resíduos) eram menos correlacionados ao longo do tempo ou entre as observações. Isso sugeriu que o modelo de efeitos fixos capturou melhor a estrutura dos dados, tendo um ajuste mais preciso, estimativas mais confiáveis e inferências mais robustas, uma vez que os erros tenderam a ser mais aleatórios e menos sistemáticos.

Foi realizado ainda o teste de Chow para verificar se existiam diferenças significativas entre os impactos da Covid-19 e da GR-U sobre o desempenho financeiro. A rejeição da hipótese nula do teste sugeriu a presença de uma diferença significativa entre os grupos. A análise inicial do teste de Chow mostrou que as *proxies* ROA, P/L, liquidez seca, e geral, endividamento e *price to book value* impactaram o desempenho financeiro em ambas as crises analisadas. O R^2 de 28% indicou, entretanto, que os modelos para ambas as crises tiveram performances diferentes, ou seja, a *proxies* na Covid-19 explicaram o desempenho financeiro no período de forma diferente daquela no período da guerra. A estatística F significativa reafirmou o resultado do R^2 , indicando a existência de diferenças significativas entre os modelos das duas crises, o que pode implicar impactos com intensidades diferentes sobre os respectivos desempenhos financeiros das empresas. Por fim, a soma dos quadrados dos erros dos dois modelos também foi significativamente diferente, corroborando as sugestões dos resultados acima de que cada crise impactou diferentemente os desempenhos financeiros das empresas da B3.

Os gráficos da Figura IV.3 mostram as relações entre cada indicador e o desempenho financeiro, para ambas as crises. Na Figura IV.3a observa-se que a rentabilidade no início da pandemia teve um impacto relevante sobre o desempenho financeiro da maioria das empresas da B3, enquanto na guerra os gráficos não demonstraram impactos ruins. Esse resultado corroborou os achados do estudo de Boungou e Yatié (2022), mostrando que países geograficamente distantes da zona de conflito sofreram menos os impactos econômicos da guerra.

Em relação à crise da Covid-19, a economia e as empresas brasileiras sofreram gravemente, conforme relatado por Caldas, Silva, Júnior e Cruz (2021), em função das

incertezas geradas sobre o desempenho do mercado financeiro. Isso provocou a desvalorização das ações, afetando seus retornos. É interessante observar que as linhas de tendência (azul) nos gráficos inclinam-se em sentidos contrários às dispersões dos valores das *proxies*, ou seja, para a Covid-19 há uma tendência de crescimento do desempenho financeiro, enquanto para a GR-U a tende é de queda. Uma possível explicação é a estabilização do mercado após o impacto inicial negativo da pandemia, e similarmente, após a fase inicial de especulação do mercado nos primeiros meses após a invasão da Ucrânia.




Figura IV.3a – DF x Rentabilidade: Covid-19 (esquerda) e início da GR-U (direita)
Fonte: dados de pesquisa.

A Figura IV.3b apresentou um comportamento da lucratividade das empresas da amostra semelhante àquele da rentabilidade, ou seja, a maioria das empresas no início da crise pandêmica teve lucratividade inferior àquela no início da invasão na Ucrânia. Esse resultado faz sentido não só pela questão geopolítica explicitada por Boungou e Yatié (2022), como também pelo fato de a lucratividade e a rentabilidade serem interdependentes; dessa forma, o comportamento da lucratividade influencia a rentabilidade.

Assim como aconteceu com a rentabilidade, e devido à co-dependência com este indicador, as linhas de tendência das *proxies* de lucratividade foram contrárias aos valores assumidos pelas mesmas. A exceção foi a tendência de crescimento do preço/lucro da ação no

caso da GR-U, que pode ser devido à expectativa da continuidade do aumento dos preços das *commodities* como petróleo, grãos e fertilizantes, que poderiam impactar expressivamente o custo da produção agrícola nacional e, consequentemente, os preços de produtos alimentícios.




Figura IV.3b – DF x Lucratividade: Covid-19 (esquerda) e início da GR-U (direita)
Fonte: dados de pesquisa.

Em relação à liquidez das empresas da amostra, apesar de seus valores médios e medianos serem próximos em ambas as crises (Tabela IV.2), e da Figura IV.3c apresentar tendências de crescimento para este indicador nos dois eventos, comportamentos opostos em relação ao impacto sobre o desempenho financeiro foram evidenciados. Durante a pandemia, enquanto muitos setores enfrentaram paralisações não planejadas de suas operações, na guerra esse impacto foi mais ameno ou mesmo inexistente, sendo em muitos casos, específico para setores como energia e *commodities*.

Ademais, no início da guerra as expectativas de recuperação econômica eram mais otimistas devido à recuperação do choque sofrido na pandemia, o que manteve a confiança dos investidores na economia e nos resultados das empresas. Setores como energia e *commodities* se beneficiaram com o aumento dos preços advindos da guerra, contrabalanceando perdas em outros setores. Isso pode ter contribuído para maior resiliência das empresas em relação ao desempenho financeiro nos primeiros meses da guerra, quando se compara com o cenário altamente inseguro que se configurou no início da pandemia.




Figura IV.3c – DF x Liquidez: Covid-19 (esquerda) e início da GR-U (direita)

Fonte: dados de pesquisa.

Como a *proxy* Índice de Cobertura não fez parte da análise em painel devido à multicolinearidade identificada, o indicador de estrutura de capital foi composto somente pela

proxy Índice de Endividamento. Nos gráficos da Figura IV.3d observa-se que o endividamento das empresas no início da Covid-19 também impactou de forma negativa o desempenho financeiro. Já no início da invasão russa o endividamento das mesmas empresas não expressou impacto sobre o desempenho.




Figura IV.3d – DF x Estrutura de Capital: Covid-19 (esquerda) e início da GR-U (direita)
Fonte: dados de pesquisa.

Finalmente a Figura IV.3e apresenta os comportamentos do desempenho financeiro das empresas da B3 frente aos indicadores econômicos Q de Tobin e PBV, revelando o impacto mais expressivo dos preços das ações sobre o desempenho no início da pandemia, comparativamente ao início da guerra. As linhas de tendência mostraram comportamentos semelhantes àqueles dos demais indicadores, justificadas pelos motivos expostos anteriormente.




Figura IV.3e – DF x Indicadores Econômicos: Covid-19 (esquerda) e início da GR-U (direita)
Fonte: dados de pesquisa.

A análises anteriores deste capítulo conduziram à conclusão de que a pandemia da Covid-19 promoveu impactos mais relevantes e ruins sobre o desempenho financeiro das empresas analisadas, confirmando a hipótese de pesquisa proposta. Esse resultado não excluiu, entretanto, os impactos sofridos pelas empresas nos primeiros meses da guerra na Ucrânia, conforme revelado nas análises da Tabela IV.3.

IV.5 Conclusões

Os resultados apresentados pelas estatísticas descritivas e regressões de dados em painel conduziram à conclusão de que tanto o período inicial da pandemia da Covid-19 quanto da guerra entre Rússia e Ucrânia impactaram o desempenho financeiro das empresas da B3, em relação aos indicadores analisados. Esse impacto, entretanto, foi mais proeminente na pandemia, que afetou expressivamente toda a economia brasileira e mundial. Os resultados das análises em painel sugeriram que todos os indicadores impactaram o desempenho financeiro das empresas nos períodos analisados.

Apesar do modelo de efeitos fixos ter sido selecionado aquele com melhor ajuste tanto para a série temporal da Covid-19 quanto para a série da guerra, ele se mostrou mais adequado aos dados da guerra, sendo necessário, no caso da Covid-19 a proposição de variáveis (*proxies*) adicionais para garantir a validade das estimativas e inferências do modelo. Isso deveu-se à presença de uma maior autocorrelação nesse modelo, tornando-o mais sensível a padrões dos dados. Ainda assim, em ambos os eventos, os indicadores utilizados boas variáveis explicativas para o desempenho financeiro.

Os resultados obtidos neste capítulo concordaram com a hipótese H_3 que propôs que a crise econômica da pandemia da Covid-19 afetaria significativamente o desempenho financeiro das empresas listadas na B3, no período entre janeiro/2020 e dezembro/2021. Algumas possibilidades de justificativas seriam o fato de muitas empresas terem se adaptado rapidamente às novas condições de mercado impostas pela pandemia, como a digitalização e o *e-commerce*, permitindo sua sobrevivência e mesmo o aumento das vendas. Outro fator foi a redução de custos operacionais e renegociação de dívidas das empresas para manterem a lucratividade.

Ademais, muitas empresas se recuperaram rapidamente devido à flexibilização das restrições e à reabertura econômica. Contudo, essa adaptação em alguns setores pode ter mascarado impactos financeiros negativos primários, de forma que o período de análise pode ter incluído tempo suficiente para a recuperação após os choques iniciais.

Sobre os resultados obtidos para a GR-U, a pesquisa rejeitou a hipótese H₄, demonstrando que os indicadores de desempenho financeiro sofreram impactos dessa crise, porém em menor intensidade. A análise inicial do teste de Chow mostrou que as *proxies* ROA, P/L, liquidez seca, e geral, endividamento e *price to book value* impactaram o desempenho financeiro em ambas as crises analisadas. O R² de 28% desse teste indicou, entretanto, que as *proxies* na Covid-19 explicaram o desempenho financeiro de forma diferente daquela na guerra. As diferenças entre os modelos das duas crises podem ser explicadas por impactos de intensidades diferenciadas sobre os desempenhos financeiros das empresas.

Os resultados deste capítulo demonstraram como as incertezas e especulações no mercado financeiro podem afetar a saúde das empresas, especialmente em economias como a brasileira, que é muito sensível às intempéries das crises externas, mesmo àquelas que estão geograficamente e politicamente mais distantes do país. O fato do Brasil ser um grande exportador de *commodities* o torna vulnerável às flutuações de preços no mercado internacional, de forma que crises como a guerra na Ucrânia podem refletir na balança comercial e na inflação nacional.

Outro motivo para o impacto da guerra no mercado acionário brasileiro deveu-se à “ressaca” da crise pandêmica que desconcertou o mercado, provocando reações irracionais e desesperadas que impactaram as empresas naquela época, e que pode ter despertado novamente medos e inseguranças nos investidores. A economia brasileira e seu mercado financeiro mostraram vulnerabilidade em relação a crises globais, como a Covid-19 e a guerra na Ucrânia, e, portanto, as empresas precisam se planejar para lidarem com outros desafios futuros. Sua resiliência, aliada a uma política econômica sólida, é fundamental para mitigar os impactos de crises importantes para garantir resultados financeiros sustentados e longevos.

Referências

- Adekoya, O. B., & Oliyide, J. A. (2021). How Covid-19 Drives Connectedness Among Commodity and Financial Markets: Evidence from TVP-VAR and Causality-in-Quantiles Techniques. *Resour. Pol*, 70.
- Afza, T., & Sajid Nazir, M. (2014). Audit quality and firm value: A case of Pakistan. *Research Journal of Applied Sciences, Engineering and Technology*, 7(9), p. 1.803-1.810.
- Agarwal, R., Barney, J. B., Foss, N. J., & Klein, P. G. (2009). Heterogeneous Resources and the Financial Crisis: Implications of Strategic Management Theory. *Strategic Organization*, 7(4), p. 467-484.

Alam, K., Mosab I., Tabash, M. I., Billah, M., Kumar, S., & Anagreh, S. (2022). The Impacts of the Russia–Ukraine Invasion on Global Markets and Commodities: A Dynamic Connectedness among G7 and BRIC Markets. *J. Risk Financial Manag.*, 15, 352. <https://doi.org/10.3390/jrfm15080352>.

Albulescu, C. T. (2021). COVID-19 and the United States Financial Markets' Volatility. *Finance Research Letters*, 38.

Alsmady, A. A. (2022). Quality of financial reporting, external audit, earnings power and companies' performance: The case of Gulf Corporate Council Countries. *Research in Globalization*, 5. <https://doi.org/10.1016/j.resglo.2022.100093>.

Andrade, G. C. T., Oliveira, E. R., Santos, G. C., Oliveira, E. D., & Silva, A. T. (2020). Análise do desempenho econômico-financeiro de três empresas de capital aberto do setor de construção civil (2009-2018). *DESENVOLVE - Revista de Gestão do Unilasalle*, 9(2), p. 119-137. <http://dx.doi.org/10.18316/desenv.v9i2.6510>.

Ang, S.H, Leong, S.M., & Kotler, P. (2000). The Asian Apocalypse: Crisis Marketing for Consumer and Businesses. *Long Range Planning*, 33, p. 97-119.

Avelar, E. A., Ferreira, P. O., da Silva, B. N. E. R., & Ferreira, C. O. (2021). Efeitos da Pandemia de Covid-19 sobre a Sustentabilidade Econômico-Financeira de Empresas Brasileiras. *RGO - Revista Gestão Organizacional*, 14(1), p. 131-152.

BACEN. (maio/2020). Relatório de Inflação, 22(1). Recuperado de: <https://www.bcb.gov.br/content/ri/relatorioinflacao/202003/ri202003p.pdf>.

BACEN. (junho/2020). Enfrentamento dos Efeitos Econômicos da Covid-19. Recuperado de: <https://www.bcb.gov.br/resultadobusca?termo=lockdown%20brasil%20covid%2019&source=>.

Baek, S., Mohanty, S. K., & Glambosky, M. (2020). COVID-19 and Stock Market Volatility: An Industry Level Analysis. *Finance Research Letters*, 37.

Bai, L., Wei, Y., Wei, G., Li, X., & Zhang, S. (2021). Infectious Disease Pandemic and Permanent Volatility of International Stock Markets: A Long-Term Perspective. *Finance Research Letters*, 40. Recuperado de: <https://doi.org/10.1016/j.frl.2020.101709>.

Baltagi, Badi H. (1995). *Econometric analysis of panel data*. Nova York: John Wiley and Sons.

Bandeira, M. L., & Britto, P. A. P. (2020). Desempenho econômico-financeiro e valor das ações em um contexto de mudança regulatória: o caso do setor elétrico brasileiro. *Revista Catarinense da Ciência Contábil*, 19, p. 1-18.

Beraich, M., Amzile, K., Laamire, J., Zirari, O., & Fadali, M. A. (2022). Volatility Spillover Effects of the US, European and Chinese Financial Markets in the Context of the Russia–Ukraine Conflict. *International Journal of Financial Studies*, 10, 95. <https://doi.org/10.3390/ijfs10040095>.

Boungou, W., & Yatié, A. (2022). The Impact of the Ukraine–Russia War on World Stock Market Returns. *Economics Letters* 215, 110516.

Brada, J. C., Gajewski, P., & Kutan, A. M. (2021). Economic Resiliency and Recovery, Lessons from the Financial Crisis for the COVID-19 Pandemic: A Regional Perspective from Central and Eastern Europe. *International Review of Financial Analysis*, 74.

Caldas, A. V. S., Silva, E. S., Júnior, A. F. A. S., & Cruz, U. B. (2021). Os Efeitos da Covid-19 sobre os Desempenhos das Ações dos Setores da B3. *Contextus – Revista Contemporânea de Economia e Gestão*, 19(2), 15-28.

Caponi, S. (2020). Covid-19 no Brasil: Entre o Negacionismo e a Razão Neoliberal. *Estudos Avançados*, 34(99), 209-223.

Chen, X., & Chiang, T.C. (2020). Empirical Investigation of Changes in Policy Uncertainty on Stock Returns- Evidence from China's Market. *Res. Int. Bus. Finance*, 53.

Cohen, S. (2022). Is the bowl bare? - the cost of under-development. *The Journal of North African Studies*, 27, p. 433-40.

Conlon, T., & McGee, R. (2020). Safe Haven or Risky Hazard? Bitcoin During the COVID-19 bear market. *Finance Research Letters*, 35.

Costa, D. M. D., Ramos, K. S., Eufrásio, G. B., Estevão, J. A., & Azevedo, D. M. C. (2010). *Os Efeitos da Crise do Mercado Imobiliário Americano Subprime sobre o Desempenho Econômico-Financeiro das Empresas de Capital Aberto no Brasil*. Anais XVII Congresso Brasileiro de Custos. Belo Horizonte/MG. Recuperado de: <https://anaiscbc.emnuvens.com.br/anais/article/view/639/639>.

Costa, S. S. (2020). Pandemia e desemprego no Brasil. *Revista de Administração Pública*, 54(4), p. 969-978.

Creswell, J. W. (2007). *Projeto de Pesquisa – Métodos Qualitativo, Quantitativo e Misto*. 2ª edição. Porto Alegre. ed. Artmed.

Dario, C., Conlisk, S., Iacoviello, M., & Penn, M. (2022). The Effect of the War in Ukraine on Global Activity and Inflation. FEDS Notes. Washington: Board of Governors of the Federal Reserve System, May 27, 2022. Recuperado de: <https://doi.org/10.17016/2380-7172.3141>.

Dellagnezze, René. (2022). *O Conflito Rússia e a Ucrânia*. 1ª ed. Revista REASE. 79 p.

Demir, E., Bilgin, M. H., Karabulut, G., & Doker, A. C. (2020). The Relationship Between Cryptocurrencies and COVID-19 Pandemic. *Eurasian Economic Review*, 10(3), p. 349-360.

Dewi, K., & Monalisa, M. (2016). Effect of Corporate Social Responsibility Disclosure on Financial Performance with Audit Quality as a Moderating Variable. *Binus Business Review*, 7(2).

Ding, W., Levine, R., Lin, C., & Xie, W. (2021). Corporate Immunity to the COVID-19 Pandemic. *Journal of Financial Economics*, 141(2), p. 802-830.

Dopierała, Ł., Mosionek-Schweda, M., Laskowicz, T., & Ilczuk, D. (2022). Financial performance of renewable energy producers: A panel data analysis from the Baltic Sea. *Region Energy Reports*, 8, p. 0-11.

Duarte, P. C., Lamounier, W. M., & Takamatsu, R. T. (2007). *Modelos econométricos para dados em painel: aspectos teóricos e exemplos de aplicação à pesquisa em contabilidade e finanças*. Anais Congresso USP de Controladoria e Contabilidade. v. 4, p. 1-15.

Economou, F., Panagopoulos, Y., & Tsouma, E. (2018). Uncovering Asymmetries in the Relationship Between Fear and the Stock Market Using a Hidden-Co-Integration Approach. *Res. Int. Bus. Finance*, 44, p. 459-470.

Edan, T. S., Hraiga, R. A., & Farhan, R. M. (2022). The Role of Key Financial Performance Indicators in Investment Decision. *International Journal of Economics, Business and Management Studies (EBMS)*, 9(11), p. 115-121.

Egbunike, C. F., & Okerekeoti, C. U. (2018). Macroeconomic factors, firm characteristics and financial performance: A study of selected quoted manufacturing firms in Nigeria. *Asian Journal of Accounting Research*, 3(2), p. 142-168.

Ellaboudy, S. (2010). The Global Financial Crisis: Economic Impact on GCC Countries and Policy Implications. *International Research Journal of Finance and Economics*, 41, p. 180-193.

Endri, E., Sari, A. K., Budiasih, Y., Yuliantini, T., & Kasmir, K. (2020). Determinants of profit growth in food and beverage companies in Indonesia. *Journal of Asian Finance, Economics and Business*, 7(12), p. 739-748.

Engelhardt, N., Krause, M., Neukirchen, D., & Posch, P. N. (2021). Trust and Stock Market Volatility During the COVID-19 Crisis. *Finance Research Letters*, 38.

Fahlenbrach, R., Rageth, K., & Stulz, R. M. (2020). How Valuable is Financial Flexibility when Revenue Stops? Evidence from the COVID-19 Crisis. *Review of Financial Studies*, 34(11). DOI:10.1093/rfs/hhaa134.

Falato, A., Goldstein, I., & Hortaçsu, A. (2021). Financial Fragility in the COVID-19 Crisis: The Case of Investment Funds in Corporate Bond Markets. *Journal of Monetary Economics*, 123, p. 35-52.

Farasi, W. M. (2022). Profitability Analysis to Measure Financial Performance at PT Astra Agro Letari Tbk. *International Journal of Social Science and Human Research*, 5(12), p. 5.257-5.263.

Feijo, C., & Sampaio, A.V. (2022). Brasil Estagnado e Mundo em Conflito: os Desafios ao Desenvolvimento. *Boletim FINDE*, 3(1), ISSN: 2675-7389.

- Fiocruz. Observatório Covid-19. Borges, L. *et al.* (2020). O Aparente Dilema Implicado pela Pandemia da Covid-19: Salvar Vidas ou a Economia? Recuperado de: <https://portal.fiocruz.br/documento/o-aparente-dilema-implicado-pela-pandemia-da-covid-19-salvar-vidas-ou-economia>.
- Flach, L., & Mattos, L. K. (2020). Indicadores Econômico-Financeiros e o Retorno das Ações de Empresas Listadas na B3. *Navus - Revista de Gestão e Tecnologia*, 10, p. 01-15.
- Fortunato, G., Funchal, B. & Da Motta, A. P. (2012). Impacto dos investimentos no desempenho das empresas brasileiras. *Rev. Adm. Mackenzie*, 13(4).
- Gharib, C., Mefteh-Wali, S., & Jabeur, S. B. (2021). The Bubble Contagion Effect of COVID-19 Outbreak: Evidence from Crude Oil and Gold Markets. *Finance Research Letters*, 38.
- Giot, P. (2005). Relationships Between Implied Volatility Indexes and Stock Index Returns. *Journal of Portfolio Management*, 31, p. 92-100.
- Goodell, J. W., & Huynh, T. L. D. (2020). Did Congress Trade Ahead? Considering the Reaction of US Industries to COVID-19. *Finance Research Letters*, 36.
- Guo, H., Zhao, X., Yu, H., & Zhang, X. (2021). Analysis of Global Stock Markets' Connections with Emphasis on the Impact of COVID-19. *Physica A*, 569.
- Halkos, G.E., & Tzeremes, N.G. (2012). Analyzing the Greek renewable energy sector: A data envelopment analysis approach. *Renew. Sustain. Energy Rev.*, 16(5), p. 2884-2893.
- Hall, R. J., Beck, F., & Toledo Filho, J. R. (2013). Análise do Impacto da Crise *Subprime* nas Empresas do Agronegócio Listadas na BM&F Bovespa. *Custos e Agronegócio on line*, 9(1).
- Haroon, O., & Rizvi, S. A. R. (2020). Flatten the Curve and Stock Market Liquidity—An Inquiry into Emerging Economies. *Emerging Markets Finance and Trade*, 56(10), p. 2151-2161.
- Hassan, A. (2019). Do renewable energy incentive policies improve the performance of energy firms? Evidence from OECD countries. *OPEC Energy Rev.*, 43(2), p. 168-192.
- Herawaty, V., & Solihah, D. (2019). The Effect of CEO Tenure, Managerial Skills and Earning Power on Earnings Manipulation with Corporate Governance as a Moderating Variable on Manufacturing Companies in Indonesia Stock Exchange. *Academy of Accounting and Financial Studies Journal*, 23(1), p. 1-17.
- Husna, N., & Desiyanti, R. (2016). The analysis of financial performance on net profit margin at the coal company. *International Journal of Management and Applied Science*, 2(4), p. 105-108.
- Imhanzenobe, J. O. (2020). Managers' financial practices and financial sustainability of Nigerian manufacturing companies: Which ratios matter most? *Cogent Economics & Finance*, 8(1), p. 1-23.

Iwata, H., & Okada, K. (2011). How does environmental performance affect financial performance? Evidence from Japanese manufacturing firms. *Ecol. Econom.*, 70(9), p. 1691-1700.

Ji, Q., Dayong, Z., & Zhao, Y. (2020). Searching for Safe-Haven Assets During the COVID-19 Pandemic. *International Review of Financial Analysis*, 71.

King, A. A., & Lenox, M. J. (2001). Does it really pay to be green? An empirical study of firm environmental and financial performance. *J. Ind. Ecol.*, 5(1), p. 105-116.

Krauter, E. (2012). Executive compensation and financial performance in Brazilian companies. SSRN Working Paper Series. 2012. Recuperado de: <http://ssrn.com/abstract=217104>

Leal, J., & de Paula, L. F. (2022). Impactos do Conflito Rússia-Ucrânia para a Hegemonia do Dólar. *Boletim FINDE*, 3(1), ISSN: 2675-7389.

Li, Z. F., Zhou, Q., Chen, M., & Liu, Q. (2021). The Impact Of COVID-19 on Industry-Related Characteristics and Risk Contagion. *Finance Research Letters*, 39.

Lima Neto, O., Martins, M. N. A. L., Martins, W. S., Nagatsuka, D. A. S., Ráo, E. M., & Rodrigues Júnior, R. (2022). Impacto da Pandemia na Economia Brasileira. *Revista Gestão em Foco*, 14, p. 199-205.

Ling, D. C., Wang, C., & Zhou, T. (2020). A First Look at the Impact of COVID-19 on Commercial Real Estate Prices: Asset-Level Evidence. *Review of Asset Pricing Studies*, 10(4), p. 669-704.

Lo, G-D., Marcelin, I., Bass`ene, T., & S`ene, B. (2022). The Russo-Ukrainian War and Financial Markets: The Role of Dependence on Russian Commodities. *Finance Research Letters*, 50, 103194.

Luz, E. R. (2013). Indicadores tradicionais de liquidez e de rentabilidade: Um estudo comparativo da média setorial das empresas brasileiras nos anos 2000 a 2010. *Revista ADMpg Gestão Estratégica*, 6(2), p. 87-95.

Mahrani, M., & Soewarno, N. (2018). The effect of good corporate governance mechanism and corporate social responsibility on financial performance with earnings management as mediating variable. *Asian Journal of Accounting Research*, 3(1), p. 41-60.

Mensi, W., Sensoy, A., Vo, X. V., & Kang, S. H. (2020). Impact of COVID-19 Outbreak on Asymmetric Multifractality of Gold and Oil Prices. *Resources Policy*, 69.

Milcheva, S. (2021). Volatility and the Cross-Section of Real Estate Equity Returns During COVID-19. *The Journal of Real Estate Finance and Economics*, 65, p. 293-320. Recuperado de: <https://doi.org/10.1007/s11146-021-09840-6>.

Ministério da Economia. 15/09/2020. Recuperado de: <https://www.gov.br/economia/pt-br/assuntos/noticias/2020/setembro/ministerio-da-economia-divulga-lista-dos-setores-mais-afetados-pela-pandemia-da-covid-19-no-brasil>.

Ministério da Saúde. Secretaria de Vigilância em Saúde e Ambiente. Boletim Epidemiológico Especial 151 - Doença pelo Novo Coronavírus – COVID-19. Boletim mensal, Vigilância da covid-19 no Brasil, maio, 2023.

Mnif, E., Jarboui, A., & Mouakhar, K. (2020). How the Cryptocurrency Market has Performed During COVID 19? A Multifractal Analysis. *Finance Research Letters*, 36.

Monteiro, L. A., Feijo, C., & D'Agostini, L. L. M. (2022). Breves Notas Exploratórias sobre a Rentabilidade das Grandes Empresas de Capital Aberto. *Boletim FINDE*, 3(1), ISSN: 2675-7389.

Müller, C. (2013). The Incremental Importance of Confirming Dividend Changes in Signaling Earnings Persistence Conditional on Earnings Quality. In *Confirming Dividend Changes and the Non-Monotonic Investor Revision of Earnings Persistence*: Springer Fachmedien Wiesbaden, p. 105-116.

Njindan, I. B. (2020). The Disease Outbreak Channel of Exchange Rate Return Predictability: Evidence from COVID-19. *Emerging Markets Finance and Trade*, 56(10), p. 2277-2297.

Nunes, R., & Sales, G. (2019). O impacto da crise brasileira por meio de indicadores financeiros na estimação da liquidez na tesouraria de algumas empresas. In: CONVIBRA, 16., 2019. Anais... [S. l.]: CONVIBRA. Recuperado de: <<https://bit.ly/3dCkmcr>.

OECD (2022). *Impacts of the Russian Invasion of Ukraine on Financial Market Conditions and Resilience: Assessment of Global Financial Markets*, OECD Publishing, Paris. Recuperado de: <https://doi.org/10.1787/879c9322-en>.

Okorie, D. I., & Lin, B. (2020). Did China's ICO Ban alter the Bitcoin Market? *International Review of Economics & Finance*, Elsevier, v. 69(C), p. 977-993.

Okorie, D. I., & Lin, B. (2021). Adaptive Market Hypothesis: The Story of the Stock Markets and Covid-19 Pandemic. *The North American Journal of Economics and Finance*, 57:101397.

Okorie, D. I., & Lin, B. (2022). Crude Oil Market and Nigerian Stocks: An Asymmetric Information Spillover Approach. *International Journal of Finance and Economics*, 27(4), p. 4002-4017.

Oliveira, C. V. C., Hall, R. J., Viana, J. J. S., & Silva, T. B. J. S. (2018). *Impacto da Crise Subprime na Competitividade do Setor Siderúrgico-Metalúrgico Listado na B3*. Anais Congresso Internacional de Administração. Sucre, Bolívia. Recuperado de: https://admpg2018.com.br/anais/2018/arquivos/05022018_210551_5aea5bbf1abca.pdf.

Oluwasegun, B. A., & Johnson A. O. (2022). Commodity and Financial Markets' Fear Before and During COVID-19 Pandemic: Persistence and Causality Analyses. *Resources Policy*, 76.

Onali, E. (2020). COVID-19 and Stock Market Volatility. *SSRN Electronic Journal*. DOI: 10.2139/ssrn.3571453.

- Orozco, L. A., Vargas, J., & Galindo-Dorado, R. (2018). Trends on the relationship between board size and financial and reputational corporate performance: The Colombian case. *European Journal of Management and Business Economics*, 27(2), p. 183-197.
- Prahalathan, B., & Ranjany, R. P. (2011). The impact of capital structure choice on firm performance: Empirical investigation of listed companies in Columbo Stock Exchange, Sri Lanka. *International Journal of Research in Commerce and Management*, 2(4), p. 12-16.
- Prajapati, D. (2019). A Study on Financial KPI's of a Company. *Advance and Innovative Study*, 35.
- Ramelli, S., & Wagner, A. F. (2020). Feverish Stock Price Reactions to COVID-19. *The Review of Corporate Finance Studies*, 9(3), p. 622-655.
- Reuters. How the Ukraine-Russia War Rattled Global Financial Markets. Marc Jones. August 23, 2022.
- Ritta, C. O., Jacomossi, F. A., Fabris, T. R., & Klann, R. C. (2017). Um estudo sobre causalidade entre EBITDA e retorno das ações de empresas brasileiras (2008 - 2014). *Enfoque: Reflexão Contábil*, 36(2), p. 115-130. DOI: 10.4025/enfoque.v36i2.34126.
- Sajid, M., Mahmood, A., & Sabir, H. M. (2016). Does financial leverage influence investment decisions? Empirical evidence from KSE-30 index of Pakistan. *Asian Journal of Economic Modelling*, 4(2), p. 82-89.
- Salisu, A. A., & Vo, X. V. (2020). Predicting Stock Returns in the Presence of COVID-19 Pandemic: The Role of Health News. *International Review of Financial Analysis*, 71.
- Sayyar, H. (2015). The impact of audit quality on firm performance: Evidence from Malaysia. *Journal of Advanced Review on Scientific Research*, 10, p. 1-19.
- Schwab, L., Gold, S., & Reiner, G. (2019). Exploring financial sustainability of SMEs during periods of production growth: A simulation study. *International Journal of Production Economics*, 212, p. 8-18.
- Sharif, A., Aloui, C., & Yarovaya, L. (2020). COVID-19 Pandemic, Oil Prices, Stock Market, Geopolitical Risk and Policy Uncertainty Nexus in the US Economy: Fresh Evidence from the Wavelet-Based Approach. *International Review of Financial Analysis*, 70.
- Siahaan, S., Sadalia, I., & Silalahi, A. S. (2021). Effect of financial ratios on stock returns with earning per share as moderating variable in banking companies on the Indonesia Stock Exchange (2012 - 2017 Period). *International Journal of Research and Review*, 8(8), p. 398-406.
- Silva, A., Ramos, S. P., Kroenke, A., & Hein, N. (2019). Análise exploratória de indicadores de desempenho. *Revista de Administração Contabilidade e Economia*, 18(1), p. 157-176.
- Silva Junior, S. D., & Luciano, E. M. (2016). Teoria da perspectiva e os riscos envolvidos no processo de tomada de decisão: Análise de Conteúdo em Artigos do ProQuest. *Future Studies Research Journal*, 8(1), p. 60-89.

Suhadak, S., Kurniaty, K., Handayani, S. R., & Rahayu, S. M. (2019). Stock return and financial performance as moderation variable in influence of good corporate governance towards corporate value. *Asian Journal of Accounting Research*, 4(1), p. 18-34.

Souza, W. R. S., Peters, M., Silva, A. F., & Antunes, M. T. P. (2018). Vinte e um anos sem correção monetária no Brasil: impactos na comparabilidade da informação contábil em empresas siderúrgicas e metalúrgicas. *R. Cont. Fin.*, 29(78), p. 355-374.

Tudose, M. B., & Avasilcai, S. (2020). A review of the research on financial performance and its determinants. In G. Prostean, J. Lavios Villahoz, L. Brancu, & G. Bakacsi (Eds.), *Innovation in sustainable management and entrepreneurship. SIM 2019. Springer Proceedings in Business and Economics*, p. 229-244.

Tudose, M. B., Rusu, V. D., & Avasilcai, S. (2022). Financial Performance – Determinants and Interdependencies Between Measurement Indicators. *Business, Management and Economics Engineering*, 20(1), p.119-138.

Umar, Z., Adekoya, O. B., Oliyide, J.A., & Gubareva, M. (2021). Media Sentiment and Short Stocks Performance During a Systemic Crisis. *International Review of Financial Analysis*, 78.

Venkatraman, N., & Ramanujam, V. (1987). Measurement of business economic performance: an examination of method convergence. *Journal of Management*, 13(1), p. 109-122.

Vieira, E. M. M., Santos, A. A., Lagioia, U. C. T, Vieira, G. F., & Santos, J. F. (2014). Melhores Grupos de Índices e Demonstrações Contábeis para Análise da Situação Econômico-Financeira das Empresas na Percepção de Analistas do Mercado de Capitais. *Journal of Accounting, Management and Governance*, 17(3), p. 29-46.

Vieira, K. M., Velasquez, M. D. P., Losekann, V. L., & Ceretta, P. S. (2011). A influência da governança corporativa no desempenho e na estrutura de capital das empresas listadas na Bovespa. *Revista Universo Contábil*, 7(1), p. 46-67.

Wang, X., Dennis, L., & Tu, Y. (2007). Measuring Financial Condition: A study of U. S. states. *Public Budgeting and Finance*, 27(2), p. 1-21.

Wooldridge, J. M. (1999). *Econometric analysis of cross section and panel data*. Cambridge, Massachusetts: MIT Press.

World Bank. 2022. Global Growth to Slow through 2023, Adding to Risk of ‘Hard Landing’ in Developing Economies. Recuperado de: <https://www.worldbank.org/en/news/press-release/2022/01/11/global-recovery-economics-debt-commodityinequality>.

Wu, B., Wang, L., Wang, S., & Zeng, Y. R. (2021). Forecasting the US Oil Markets Based on Social Media Information During the COVID-19 Pandemic. (Oxf).1;226:120403. doi: 10.1016/j.energy.2021.120403.

Yap, B. C-F., Mohamed, Z., & Chong, K-R. (2014). The Effects of the Financial Crisis on the Financial Performance of Malaysian Companies *Asian Journal of Finance & Accounting*, 6(1).

Zaremba, A., Kizys, R., Aharon, D. Y., & Demir, E. (2020). Infected Markets: Novel Coronavirus, Government Interventions, and Stock Return Volatility Around the Globe. *Finance Research Letters*, 35.

Zaremba, A., Kizys, R., Tzouvanas, P., Aharon, D. Y., & Demir, E. (2021). The Quest for Multidimensional Financial Immunity to the Covid-19 Pandemic: Evidence from International Stock Markets. *Journal of International Financial Markets Institutions and Money*, 71.

Zeitun, R., & Saleh, A. S. (2015). Dynamic Performance, Financial Leverage and Financial Crisis: Evidence from GCC Countries. *EuroMed Journal of Business*, 10(2), p. 147-162.

V. CONSIDERAÇÕES FINAIS

V.1 Principais resultados

Dois anos após o choque inicial da pandemia, a guerra entre Rússia e Ucrânia teve impactos variados nos setores da B3. Enquanto alguns setores, como consumo cíclico, demais serviços, consumo não cíclico e materiais básicos, sofreram desvalorizações nos retornos das ações nos primeiros meses após o início do conflito, outros setores não foram estatisticamente afetados. Isso reflete a sensibilidade diferenciada dos setores econômicos às perturbações geopolíticas e às mudanças nas condições macroeconômicas globais.

Em contrapartida, a volatilidade dos preços das ações no início da pandemia aumentou significativamente em meados de março/2020, com o acionamento do *circuit breaker*, que teve resultados diversificados entre setores, permanecendo a inconclusão da sua efetividade. Quanto à sazonalidade nos preços, a análise revelou *clusters* significativos de volatilidade, especialmente intensificados no início da crise em março de 2020. Setores como tecnologia e saúde mostraram-se particularmente afetados, com variações de preço mais amplas e distintas.

O uso de modelos estatísticos como SARIMA e GARCH foi adequado para capturar essas flutuações, embora tenha sido observado que o modelo TGARCH não foi o mais adequado para esse contexto específico. No cenário de crise econômica em meio à Covid-19, os setores de consumo cíclico tiveram alta nos preços das ações, enquanto os setores industrial, de serviços e materiais básicos atingiram níveis baixos. Os setores de tecnologia e saúde mostraram picos de alta seguidos por quedas, indicando anomalias significativas. O setor imobiliário apresentou o comportamento mais estável.

As análises de dados em painel indicaram que, tanto a pandemia da Covid-19 quanto a guerra na Ucrânia impactaram o desempenho financeiro das empresas listadas na B3, sendo o impacto da pandemia mais intenso em função de toda a desorganização econômica provocada por esta crise no Brasil e no mundo. O impacto da guerra contrariou a hipótese de pesquisa, pois esperava-se que a distância geopolítica entre o Brasil e a Rússia e Ucrânia fosse um obstáculo difícil de transpor. Entretanto, conforme analisado no último artigo desta tese, a economia brasileira, já fragilizada pelos anos anteriores e ainda sob os resquícios da Covid-19, se viu sujeita às inseguranças e ameaças de choques devido às altas inflacionária e cambial internacionais e medo de prejuízos no comércio internacional.

V.2 Contribuições e limitações da pesquisa

As contribuições desse estudo conduzem a uma melhor compreensão sobre o comportamento dos setores de atividades brasileiros diante de uma crise geopolítica distante do Brasil geograficamente, no caso da guerra, que trouxe consequências econômicas ao mercado nacional, talvez mais pela expectativa da relação demanda x oferta do que pela realidade dos números. Isso leva à conclusão de que a HME ainda “segue seu reinado”, demonstrando que informações divulgadas no ambiente econômico e absorvidas pelo mercado financeiro são rapidamente bem ou mal “digeridas” e podem ser traduzidas em respostas anômalas em setores mais sensíveis às mesmas.

Essa tese pode contribuir para o desenvolvimento e aprimoramento de metodologias de análise de séries temporais por processos diversos, e sob contextos de análise de impactos específicos nos mercados financeiros, como pandemias e conflitos geopolíticos. Ao testar hipóteses relacionadas à eficiência de mercado e aos efeitos de eventos específicos sobre os preços e retornos das ações, esta pesquisa pode ajudar a validar teorias financeiras existentes ou ao menos refiná-las. Ao fornecer evidências empíricas sobre os efeitos da pandemia da Covid-19 e da guerra na Ucrânia sobre os mercados financeiros, há uma oportunidade de ampliar o conhecimento sobre os impactos econômicos desses eventos.

As conclusões dessa pesquisa fornecem *insights* sobre os impactos da pandemia da Covid-19 e da guerra Rússia-Ucrânia nos mercados financeiros brasileiros, destacando a complexidade e a variabilidade das respostas setoriais a eventos disruptivos. Ao identificar e analisar os impactos de eventos como pandemias e conflitos geopolíticos nos preços das ações, as análises discutidas no presente estudo podem ajudar as empresas a entenderem melhor e gerenciar os riscos financeiros associados a esses eventos. Compreender como os mercados reagem a crises econômicas globais pode informar o planejamento estratégico das empresas, permitindo que antecipem possíveis cenários e adaptem suas estratégias de negócios de acordo com o ambiente econômico em mudança.

As principais limitações desta pesquisa foram os períodos relativamente curtos de análise para o primeiro artigo, prejudicando a aplicação da metodologia de análise em painel. Outra limitação foi a ausência de considerável volume de dados na base de dados do Refinitiv, exigindo uma grande parte de dados winsorizados.

Uma dificuldade foi ajustar cada série temporal, de cada período e setor, às modelagens aplicadas, pelo fato de cada série ter um comportamento diferenciado das demais. Isso gerou a

necessidade de utilizar diferentes modelos para diferentes setores, demonstrando a complexidade na adaptação de técnicas de análise temporal às características específicas de cada segmento de mercado.

As limitações identificadas apontam para a necessidade de estudos mais abrangentes e metodologicamente robustos no futuro, visando uma compreensão mais completa e detalhada dos fenômenos observados nos mercados financeiros em períodos de crise global.

V.3 Sugestões para pesquisas futuras

Uma sugestão de estudos futuros é a investigação dos efeitos de longo prazo da pandemia da Covid-19 e da guerra Rússia-Ucrânia sobre o desempenho financeiro das empresas, considerando a recuperação econômica, mudanças estruturais e adaptações estratégicas a longo prazo nas empresas, bem como a segmentação setorial para uma investigação mais aprofundada e refinada dos impactos sobre cada setor de atividade.

Seria enriquecedor analisar em profundidade a resiliência setorial aprofundando a compreensão dos fatores que determinam a resiliência de diferentes setores econômicos diante de crises econômicas e geopolíticas, explorando como características setoriais específicas influenciam o impacto financeiro sobre as empresas.

Comparar os resultados do mercado brasileiro com outros mercados internacionais afetados pelas mesmas crises, para entender melhor os padrões globais e as interações entre economias globais e regionais.

Desenvolver outros estudos aplicando novos modelos estatísticos adaptáveis que lidem melhor com a heterogeneidade dos dados e as mudanças comportamentais observadas nos mercados durante crises econômicas intensas.