



Universidade de Aveiro  
2023

**MAFALDA ELISABETE BORGES E SOUSA** **VOLATILIDADE DOS PREÇOS DE  
FECHO DAS EMPRESAS DO SETOR  
ENERGÉTICO: PRÉ E PÓS-CONFLITO  
RUSSO-UCRANIANO**



Universidade de Aveiro  
2023

**MAFALDA ELISABETE  
BORGES E SOUSA**

**VOLATILIDADE DOS PREÇOS DE  
FECHO DAS EMPRESAS DO SETOR  
ENERGÉTICO: PRÉ E PÓS-CONFLITO  
RUSSO-UCRANIANO**

Dissertação apresentada à Universidade de Aveiro para cumprimento dos requisitos necessários à obtenção do grau de Mestre em Ciência de Dados para as Ciências Sociais, realizada sob a orientação científica da Doutora Mara Teresa da Silva Madaleno, Professora Auxiliar do Departamento de Economia, Gestão, Engenharia Industrial e Turismo da Universidade de Aveiro, e sob coorientação científica do Doutor José Manuel Matos Moreira, Professor Auxiliar do Departamento de Eletrónica, Telecomunicações e Informática da Universidade de Aveiro.

## **o júri**

presidente

**Prof. Doutor João José Lourenço Marques**  
professor associado c/agregação da Universidade de Aveiro

vogais

**Prof. Doutora Beatriz Rosa Lopes Cancela**  
professora adjunta convidada do Iscac – Instituto Politécnico de Coimbra

**Prof. Doutora Mara Teresa da Silva Madaleno**  
professora auxiliar da Universidade de Aveiro

## **agradecimentos**

Primeiramente, agradeço à minha orientadora, Prof. Doutora Mara Teresa da Silva Madaleno, por todo o acompanhamento, disponibilidade e orientações prestadas.

Agradeço igualmente ao Prof. Doutor José Manuel Matos Moreira pelo conhecimento imprescindível e ensinamentos para a realização deste trabalho.

Agradeço à minha colega do mestrado Joana pela partilha, ajuda e companheirismo que me proporcionou ao longo do desenvolvimento desta dissertação.

Agradeço aos meus amigos e namorado por todo o apoio, incentivo e força neste processo.

Agradeço, com muito carinho, à minha família, em especial, aos meus pais e irmã, pelo amor e carinho incondicional e por me fazerem acreditar nas minhas capacidades e no meu valor todos os dias.

Um especial agradecimento ao meu cunhado Tiago por todo o tempo, entusiasmo, paciência e apoio na realização desta dissertação.

Agradeço a todos que direta ou indiretamente contribuíram para o desenvolvimento deste trabalho. Muito obrigada!

**palavras-chave**

Conflitos geopolíticos; guerra Rússia-Ucrânia; *Chow Test*, *Gradient Boosting Decision Tree* (GBDT); aprendizagem computacional; mercados financeiros; setor energético; Euronext

**resumo**

Este estudo analisa o impacto do conflito entre Rússia e Ucrânia nos mercados financeiros, com foco em 102 empresas do setor de energia cotadas na Euronext. Eventos extremos, como conflitos geopolíticos, historicamente afetam os mercados financeiros, gerando incerteza e volatilidade. A União Europeia, que importa energia da Rússia, é particularmente vulnerável à guerra russa-ucraniana, podendo sofrer efeitos e consequências deste efeito. Através de uma análise preliminar, da utilização do *Chow Test*, aplicação do modelo de aprendizagem computacional *Gradient Boosting Decision Tree* (GBDT) e da avaliação do desempenho das suas previsões, a presente dissertação indica que a invasão russa ao território Ucrainiano não apresenta um impacto significativo nos mercados financeiros do setor energético das empresas selecionadas. A rápida resposta da UE em busca de alternativas de fornecimento e outras decisões estratégicas podem ter atenuado e mitigado possíveis efeitos desta guerra. No entanto, a análise continua relevante para orientar políticas económicas e decisões de investimento em face aos eventos geopolíticos.

**keywords**

Geopolitical conflicts; Russia-Ukraine war; Chow test; Gradient Boosting Decision Tree (GBDT); machine learning; financial markets; energy sector; Euronext

**abstract**

This study examines the impact of the conflict between Russia and Ukraine on financial markets, focusing on 102 energy sector companies listed on Euronext. Historical evidence shows that extreme events, such as geopolitical conflicts, typically affect financial markets, causing uncertainty and volatility in stock markets. The European Union, which imports energy from Russia, is particularly vulnerable to the Russian-Ukrainian war and its potential consequences. Through preliminary analysis, the application of the Chow test, the utilization of the Gradient Boosting Decision Tree (GBDT) machine learning model, and the evaluation of its forecasting performance, this study suggests that the Russian invasion on Ukrainian territory has not significantly affected the financial markets of the selected energy sector companies. The EU's swift response in seeking alternative sources of energy supply and implementing strategic decisions may have mitigated potential effects of this war. Nevertheless, this analysis remains relevant for guiding economic policies and investment decisions in the context of geopolitical events.

# Índice

1	Introdução.....	1
2	Revisão de literatura.....	6
2.1	Euronext .....	6
2.2	Setor de energia .....	6
2.3	Guerra entre a Rússia e a Ucrânia .....	10
2.3.1	Enquadramento histórico .....	10
2.3.2	Explicação do conflito .....	11
2.3.3	Impacto do conflito.....	12
2.3.4	Comportamento dos investidores .....	14
2.3.5	Outros fatores relevantes .....	15
3	Metodologia de investigação e Dados.....	17
3.1	Dados.....	17
3.2	Subdivisão do trabalho e métodos utilizados .....	19
4	Resultados .....	28
4.1	Gráfico linear.....	28
4.2	Chow Test.....	31
4.3	Gradient Boosting Decision Tree .....	32
5	Análise e Discussão dos Resultados.....	41
6	Conclusão .....	45
7	Limitações e Passos Futuros .....	47
	Referências .....	43
Anexo A	Resultado Chow Test .....	48
Anexo B	Medidas de Performance .....	99
Anexo C	Médias Medidas de Performance .....	103
Anexo D	Informação das empresas .....	106

## Índice de Figuras

Figura 1-Dependência de Importações Energéticas de Petróleo .....	7
Figura 2-Dependência de Importações de Gás Natural .....	8
Figura 3-Dependência de Importações Energéticas de Gás Natural Líquido.....	8
Figura 4-Dependência de Importações Energéticas de Óleo e Petróleo.....	8
Figura 5-Dependência de Importações Energéticas de Combustíveis Fósseis Sólidos.....	9
Figura 6-Dependência de Importações Energéticas Total.....	9
Figura 7-Período Temporal .....	19
Figura 8-Petróleo Brent.....	29
Figura 9-Taxa de câmbio.....	30
Figura 10-Emissões de Carbono .....	30
Figura 11-Gás Natural.....	31
Figura 12-Taxa Média de Inflação.....	31
Figura 13-Accuracy no período Pré-Guerra.....	35
Figura 14-Accuracy no período Pós-Guerra .....	36
Figura 15-Precision no período Pós-Guerra (1) .....	36
Figura 16-Precision no período Pré-Guerra (1).....	37
Figura 17-Recall no período Pós-Guerra (-1).....	38
Figura 18-Recall no período Pós-Guerra (1).....	38
Figura 19- F1-score no período Pré-Guerra (1).....	39
Figura 20- F1-score no período Pós-Guerra (1) .....	39
Figura A. 1-Resultados Chow Test Eli.....	48
Figura A. 2-Resultados Chow Test Eni.mi.....	48
Figura A. 3-Resultados Chow Test Flux .....	49
Figura A. 4-Resultados Chow Test Grpg .....	49
Figura A. 5-Resultados Chow Test Mro.....	50
Figura A. 6-Resultados Chow Test Nsen .....	50
Figura A. 7-Resultados Chow Test Oyx.....	51
Figura A. 8-Resultados Chow Test Rwi.....	51
Figura A. 9-Resultados Chow Test Sbmo .....	52
Figura A. 10-Resultados Chow Test Shel .....	52
Figura A. 11-Resultados Chow Test Sifg.....	53
Figura A. 12-Resultados Chow Test Edp .....	53
Figura A. 13-Resultados Chow Test Edpr.....	54
Figura A. 14-Resultados Chow Test Galp.....	54
Figura A. 15-Resultados Chow Test Rene .....	55
Figura A. 16-Resultados Chow Test Acca .....	55
Figura A. 17-Resultados Chow Test Aglx .....	56
Figura A. 18-Resultados Chow Test Akast .....	56
Figura A. 19-Resultados Chow Test Akh.....	57
Figura A. 20-Resultados Chow Test Akrbp .....	57
Figura A. 21-Resultados Chow Test Aksoa .....	58
Figura A. 22-Resultados Chow Test Archa.....	58
Figura A. 23-Resultados Chow Test Awdr .....	59
Figura A. 24-Resultados Chow Test Borr .....	59
Figura A. 25-Resultados Chow Test Bwe .....	60
Figura A. 26-Resultados Chow Test Bwo.....	60
Figura A. 27-Resultados Chow Test Carbn.....	61



Figura A. 28-Resultados Chow Test Cloud.....	61
Figura A. 29-Resultados Chow Test Dno.....	62
Figura A. 30-Resultados Chow Test Dof .....	62
Figura A. 31-Resultados Chow Test Efuel.....	63
Figura A. 32-Resultados Chow Test Eiof.....	63
Figura A. 33-Resultados Chow Test Elmra.....	64
Figura A. 34-Resultados Chow Test Emgs .....	64
Figura A. 35-Resultados Chow Test Eqnr.....	65
Figura A. 36-Resultados Chow Test Geos .....	65
Figura A. 37-Resultados Chow Test Havi.....	66
Figura A. 38-Resultados Chow Test Hrgi .....	66
Figura A. 39-Resultados Chow Test Hunt .....	67
Figura A. 40-Resultados Chow Test Hypro .....	67
Figura A. 41-Resultados Chow Test Iox .....	68
Figura A. 42-Resultados Chow Test Mng.....	68
Figura A. 43-Resultados Chow Test Mpces.....	69
Figura A. 44-Resultados Chow Test Ndol .....	69
Figura A. 45-Resultados Chow Test Nel.....	70
Figura A. 46-Resultados Chow Test Nol .....	70
Figura A. 47-Resultados Chow Test Nor .....	71
Figura A. 48-Resultados Chow Test North .....	71
Figura A. 49-Resultados Chow Test Odlo .....	72
Figura A. 50-Resultados Chow Test Okea.....	72
Figura A. 51-Resultados Chow Test Osun.....	73
Figura A. 52-Resultados Chow Test Ots .....	73
Figura A. 53-Resultados Chow Test Pgs.....	74
Figura A. 54-Resultados Chow Test Pner .....	74
Figura A. 55-Resultados Chow Test Prso .....	75
Figura A. 56-Resultados Chow Test PSE.....	75
Figura A. 57-Resultados Chow Test Qec .....	76
Figura A. 58-Resultados Chow Test Qfuel .....	76
Figura A. 59-Resultados Chow Test Reach .....	77
Figura A. 60-Resultados Chow Test Sbuc .....	77
Figura A. 61-Resultados Chow Test Sbx .....	78
Figura A. 62-Resultados Chow Test Scana.....	78
Figura A. 63-Resultados Chow Test Scact.....	79
Figura A. 64-Resultados Chow Test Sdsd.....	79
Figura A. 65-Resultados Chow Test Seaw7.....	80
Figura A. 66-Resultados Chow Test Shlf.....	80
Figura A. 67-Resultados Chow Test Sioff .....	81
Figura A. 68-Resultados Chow Test Soff.....	81
Figura A. 69-Resultados Chow Test Teco .....	82
Figura A. 70-Resultados Chow Test Tgs .....	82
Figura A. 71-Resultados Chow Test Zena .....	83
Figura A. 72-Resultados Chow Test Akmet.....	83
Figura A. 73-Resultados Chow Test Alagp.....	84
Figura A. 74-Resultados Chow Test Albud .....	84
Figura A. 75-Resultados Chow Test Aldol .....	85

Figura A. 76-Resultados Chow Test Alene.....	85
Figura A. 77-Resultados Chow Test Aloe2.....	86
Figura A. 78-Resultados Chow Test Alesa.....	86
Figura A. 79-Resultados Chow Test Algbe.....	87
Figura A. 80-Resultados Chow Test Alver.....	87
Figura A. 81-Resultados Chow Test Auer.....	88
Figura A. 82-Resultados Chow Test Cche.....	88
Figura A. 83-Resultados Chow Test Dbg.....	89
Figura A. 84-Resultados Chow Test Edf.....	89
Figura A. 85-Resultados Chow Test Edsp.....	90
Figura A. 86-Resultados Chow Test Egab.....	90
Figura A. 87-Resultados Chow Test Engie.....	91
Figura A. 88-Resultados Chow Test Essf.....	91
Figura A. 89-Resultados Chow Test Fdel.....	92
Figura A. 90-Resultados Chow Test Geph.....	92
Figura A. 91-Resultados Chow Test Gpep.....	93
Figura A. 92-Resultados Chow Test Gtt.....	93
Figura A. 93-Resultados Chow Test Maup.....	94
Figura A. 94-Resultados Chow Test Mcphy.....	94
Figura A. 95-Resultados Chow Test Mlseq.....	95
Figura A. 96-Resultados Chow Test Neoen.....	95
Figura A. 97-Resultados Chow Test Nhoa.....	96
Figura A. 98-Resultados Chow Test Orege.....	96
Figura A. 99-Resultados Chow Test Slbp.....	97
Figura A. 100-Resultados Chow Test Ttef.....	97
Figura A. 101-Resultados Chow Test Vie.....	98
Figura A. 102-Resultados Chow Test Vltsa.....	98
Figura C. 1- Média Precision (Pré-Guerra -1).....	103
Figura C. 2-Média Precision (Pós-Guerra 1).....	103
Figura C. 3-Média Recall (Pré-Guerra -1).....	104
Figura C. 4-Média Recall (Pré-Guerra 1).....	104
Figura C. 5-Média F1-score (Pré-Guerra -1).....	105
Figura C. 6-Média F1-score (Pós-Guerra -1).....	105

## Índice de Tabelas

Tabela 1-Dependência de importações energéticas em % da UE .....	7
Tabela 2-Sanções da UE à Rússia .....	12
Tabela 3-Matriz de Confusão .....	26
Tabela 4-Performance do GBDT, período Pré-Guerra.....	33
Tabela 5-Performance do GBDT, período Pós-Guerra .....	33
Tabela 6-Importações da União Europeia de produtos energéticos da Rússia.....	44
Tabela B. 1-Medidas de Performance das 102 empresas.....	99
Tabela D. 1-Informação das 102 Empresas.....	106

## Índice de Equações

Equação 1-Chow Test F-Statistic .....	20
Equação 2-Função Previsão.....	23
Equação 3-Accuracy .....	26
Equação 4-Precision .....	26
Equação 5-Recall.....	27
Equação 6-F1-score .....	27

## 1 Introdução

Nos últimos anos, eventos extremos, sejam de origem natural ou não, têm impactado significativamente o setor energético, desencadeando mudanças substanciais nas cadeias de abastecimento globais. A análise do impacto destes eventos neste setor e nos mercados financeiros relacionados tornou-se de extrema importância, não apenas para os investidores diretos, mas também para os agentes políticos que dependem das previsões das implicações decorrentes de tensões políticas nestes mercados. O objetivo desta dissertação reside na compreensão, avaliação e validação da existência de implicações do recente conflito entre a Rússia e a Ucrânia, iniciado a 24 de fevereiro de 2022, nos mercados financeiros. Este estudo tem como alvo principal as empresas do setor de energia cotadas na Euronext, que desempenham um papel crucial na economia mundial e nas relações comerciais internacionais. O motivo para este foco específico reside no facto de que as nações envolvidas têm laços substanciais com o resto do mundo, especialmente no que se refere às importações, particularmente de recursos energéticos. Considerando ainda a extrema dependência dos mercados europeus da energia fóssil (Adekoya et al., 2023; Korkmaz, 2022), escolheu-se trabalhar com este setor de atividade económica para perceber até que ponto a volatilidade destas ações em específico se alterou desde o início do conflito.

A relevância deste estudo estende-se além da mera replicação de pesquisas anteriores. Enquanto o trabalho de Zhang et al. (2022) forneceu evidências valiosas, esta pesquisa adquire um carácter distintivo por explorar um mercado diferente, concentrando-se de forma precisa num setor particular e noutra contexto histórico. Além disso, diferentemente do estudo anterior, esta análise incorpora mais de uma série temporal, agregando complexidade à investigação. Como tal, espera-se que este estudo contribua significativamente para o *corpus* de conhecimento existente, ao oferecer uma visão aprofundada das implicações de conflitos de carácter geopolíticos como a guerra entre a Rússia e Ucrânia, nos mercados financeiros e, especificamente, no setor de energia cotado na Euronext.

Grandes conflitos geopolíticos têm historicamente demonstrado influenciar o comportamento dos mercados financeiros (Goodell et al., 2023), introduzindo incertezas que afetam o desempenho dos ativos e a estratégia dos investidores. Estudos anteriores analisaram o impacto de eventos como o ataque de 11 de setembro (Brounen & Derwall, 2010; Chesney et al., 2011; Nikkinen et al., 2008), a pandemia do COVID-19 (Ashraf & Goodell, 2022; Kumar et al., 2023; Liu et al., 2023; Pandey & Kumari, 2021), a Segunda Guerra Mundial (Hudson & Urquhart, 2015) e outros eventos significativos, no comportamento dos mercados financeiros, evidenciando a relação destes com eventos políticos e económicos. Estas pesquisas evidenciam que eventos de natureza política, como guerras, exercem um impacto substancial nos mercados financeiros e nos preços dos ativos, embora os efeitos variem de acordo com o mercado, o país e o período de

análise. Além disso, estes estudos demonstram a existência de roturas estruturais nos movimentos de preços e na volatilidade dos retornos das ações.

A pandemia de Covid-19 teve um impacto significativo nos mercados financeiros, com quedas acentuadas nos preços das ações e nos retornos diários do mercado, afetando vários setores (Pandey & Kumari, 2021). Outros eventos como os ataques de 11 de setembro demonstraram a capacidade de causar impactos negativos significativos em pelo menos um mercado de ações, enquanto a incerteza e a volatilidade do mercado aumentaram após este acontecimento (Chesney et al., 2011).

Assim, com base na literatura existente, é razoável esperar que a guerra entre a Rússia e a Ucrânia tenha efeitos semelhantes nos mercados financeiros, não apenas nos países diretamente envolvidos, mas também noutros mercados globais que mantêm relações comerciais com estas duas nações (Cui et al., 2023). Logo, a importância deste conflito estende-se além das questões políticas e humanitárias, afetando diretamente os mercados financeiros. Este acontecimento tem o potencial de provocar mudanças significativas nestes mercados e pode influenciar o comportamento dos investidores, a volatilidade dos ativos e a economia global. Portanto, a sua análise é de grande importância para compreender e antecipar os impactos económicos e financeiros deste evento (Khan et al., 2023).

A Rússia desempenha um papel fundamental no fornecimento de recursos energéticos a nível mundial, mais especificamente com a União Europeia (UE), sendo responsável por uma parcela significativa das suas necessidades energéticas, principalmente de gás natural e petróleo. Isso, aliado à limitada capacidade de produção interna da UE (apenas 43% das suas necessidades energéticas são atendidas internamente, segundo os dados da Eurostat (2023c), cria uma situação de vulnerabilidade a eventos que afetam as relações entre a Rússia e a UE (Adekoya et al., 2023; Korkmaz, 2022; Z. Zhang et al., 2023).

O setor de energia é considerado um dos pilares fundamentais da economia global e uma área crítica para empresas e governos na tomada de decisões que moldam o seu desenvolvimento e crescimento (Mensi et al., 2020). Devido à relevância da Rússia como um dos principais fornecedores nos mercados globais de energia e ao tamanho da sua economia, o recente conflito entre Rússia e Ucrânia intensificou consideravelmente o risco geopolítico (RGP) nos mercados regionais e internacionais, como observado por Umar et al., (2022). Esse aumento do risco geopolítico tem implicações diretas nos preços dos recursos energéticos e no fornecimento dos mesmos, colocando os Estados-membros da União Europeia numa posição sensível e complexa (Adekoya et al., 2023; Korkmaz, 2022; Z. Zhang et al., 2023).

De facto, a União Europeia, como uma das principais geografias de consumo de energia do mundo, enfrenta desafios significativos devido à sua crescente dependência de importações de energia, uma vez que possui recursos escassos de energia fóssil, como o petróleo e gás natural. Nesse contexto, eventos que impactam direta ou indiretamente estas relações podem representar

um risco substancial para os países europeus e para o seu crescimento económico e provocar consequências nos mercados financeiros do setor de energia, como indicado por (Bigerna et al., 2023). Com isto, surge a necessidade de estudar as consequências decorrentes deste evento nos mercados financeiros europeus com especial atenção ao setor energético. Como tal, seleccionei 102 empresas deste setor cotadas na Euronext para realizar o presente estudo.

A Euronext emerge como uma das principais bolsas de valores na Europa, desempenhando um papel fundamental na promoção da diversidade de ativos financeiros, desde ações a derivados, e na facilitação do investimento em empresas de diversos setores e tamanhos. Esta instituição financeira, resultado da fusão das bolsas de Paris, Bruxelas, Amesterdão e Lisboa em 2000, opera em diferentes mercados sob regulamentações específicas, que visam garantir a integridade e a transparência do sistema financeiro (Bollen, 2023; Euronext, 2023). Esta bolsa de valores oferece não apenas aos investidores a oportunidade de investir em empresas de diversas dimensões, setores e indústrias, mas também contribui para o crescimento do capital destas empresas. Como dito anteriormente, neste estudo, as empresas sob análise estão cotadas na Euronext e inserem-se no setor de energia.

Este estudo é relevante e oportuno, uma vez que o conflito russo-ucraniano é uma questão crítica que envolve dois países com papéis fundamentais e importantes na economia global e tendo uma forte atuação nos mercados financeiros, mais especificamente, do setor energético. As implicações deste conflito vão além das fronteiras dos países envolvidos, podendo afetar a estabilidade financeira e económica em todo o mundo. Portanto, é fundamental compreender as dinâmicas e os possíveis impactos deste conflito para melhor informar a tomada de decisões no mundo dos investimentos e políticas económicas.

Neste contexto, abordou-se inicialmente, então, a história da Euronext e no que esta consiste, o setor de energia europeu, o enquadramento histórico do conflito e o seu possível impacto nos mercados financeiros do setor energético das empresas escolhidas. Posteriormente, com base na informação analisada na revisão da literatura, procedeu-se à seleção, recolha e tratamento dos dados mais apropriados a utilizar neste estudo. Após esta fase, optou-se por fazer uma análise preliminar às variáveis utilizadas que, segundo a literatura, estão correlacionadas com os preços das ações dos mercados financeiros. Esta análise foi realizada através de gráficos lineares que permitiram observar o comportamento das séries das variáveis independentes das 102 empresas em estudo e perceber se houve alguma alteração no comportamento destas na data exata do início da guerra (24 de fevereiro de 2022) e no período subsequente. De seguida, para complementar esta fase inicial, utilizou-se o *Chow Test* para validar um possível ponto de quebra estrutural nos preços das ações. O *Chow Test* é um método amplamente utilizado na econometria e nas ciências sociais e o principal objetivo da sua utilização é identificar a presença de mudanças estruturais ou quebras num conjunto de dados. Essas mudanças podem indicar a influência de eventos significativos que afetam os dados. Assim, este teste possibilitou perceber se o ponto de

quebra estrutural que, de acordo com a literatura, foi definido como sendo 24 de fevereiro de 2022 (início do conflito entre a Ucrânia e a Rússia), representa ou não uma mudança nos preços das ações. De seguida, neste estudo, testou-se os padrões dos preços diários das ações entre os períodos pré e pós-guerra. Esta análise é muito importante, visto que, quaisquer padrões previsíveis podem apoiar a tomada de decisões estratégicas nos mercados financeiros (Q. Zhang et al., 2022). Para realizar este tipo de análise, os métodos mais utilizados são modelos de aprendizagem computacional. Assim, foi aplicado o modelo *Gradient Boosting Decision Tree* (GBDT) para prever as variações dos retornos dos preços das ações das 102 empresas selecionadas. O GBDT é um algoritmo robusto usado para classificação e previsão que visa agregar várias árvores de decisão num único preditor mais eficiente (Boldini et al., 2023). Neste sentido, foi definida como variável dependente as variações dos retornos das ações, que foi calculada a partir da variável dos retornos dos preços das ações, previamente calculada, e como variáveis independentes a média de inflação (Mensi et al., 2021), o preço de fecho, o preço do índice de mercado, a taxa de câmbio (Adjasi et al., 2008; Ahmad et al., 2010; Kennedy & Nourzad, 2016), os preços futuros de emissões de carbono (Xu et al., 2022), do petróleo Brent (Adekoya et al., 2023; Jebabli et al., 2022; Mensi et al., 2021; Rizvi et al., 2022) e gás natural (Goodell et al., 2023; Jebabli et al., 2022), o dia da semana (Berument et al., 2007; Caporale & Zakirova, 2017; Gayaker et al., 2020; Lee et al., 2010) e o mês (Boudreaux et al., 2011; Vasileiou E. Samitas, 2015). Após calculadas as previsões, a performance do modelo de aprendizagem computacional foi avaliada usando matrizes de confusão e métricas como a *Accuracy*, *Precision*, *Recall* e *F1-score*. Estas métricas são essenciais para analisar o desempenho do modelo de classificação e perceber se este foi o modelo mais adequado para os dados selecionados.

De seguida apresenta-se a análise e discussão de resultados. A análise dos resultados, ao contrário do esperado, não aponta para um impacto significativo do início do conflito entre a Ucrânia e a Rússia nos mercados financeiros, nomeadamente nas cotações das ações das empresas listadas do setor energético utilizadas neste estudo. Na análise preliminar realizada examinamos individualmente o comportamento das variáveis que, de acordo com a literatura, podem afetar a variável principal deste estudo: os preços das ações das empresas do setor energético. Com base nos gráficos lineares, parece que os preços dos futuros de emissões de carbono, de petróleo Brent e gás natural tiveram uma mudança sentida no seu comportamento a partir de 24 de fevereiro de 2023. Por outro lado, não parece haver influência significativa no comportamento das variáveis relacionadas à inflação média e à taxa de câmbio nos períodos após a invasão da Rússia à Ucrânia. Por outras palavras, a partir dessa análise, podemos inferir que a inflação e a taxa de câmbio podem não ter um impacto substancial e determinante nas mudanças bruscas nos preços das ações. Em contraste, as *commodities* de emissões de carbono e gás natural mostraram oscilações nesse período crítico e, assim, podem ter uma influência significativa no comportamento dos preços das

ações. Os resultados do *Chow Test* sugerem que o início da guerra não representou uma quebra estrutural significativa na maioria dos casos. Além disso, as previsões do modelo de aprendizagem computacional GBDT não mostraram divergências significativas entre os dois períodos analisados e a sua performance ficou aquém do esperado. Estes resultados apontam para a inexistência de um efeito positivo ou negativo da guerra nas ações das empresas cotadas do setor de energia e podem ser explicadas, por exemplo, pela forte dependência da Europa em importações de recursos energéticos e pela rápida resposta e prontidão dos países europeus em procurar alternativas quando surgiram as primeiras limitações e dificuldades no fornecimento destes recursos, diversificando as suas fontes de energia e diminuindo a dependência das importações face à Rússia. Concluímos o presente trabalho com a apresentação das conclusões, retirando ilações sobre implicações políticas, apresentando as principais limitações e possíveis passos futuros de investigação proporcionados pela presente análise.



## **2 Revisão de literatura**

### **2.1 Euronext**

A Euronext, uma instituição financeira com uma história rica, destaca-se como uma das maiores bolsas de valores da Europa, oferecendo uma ampla variedade de serviços e cobrindo uma extensa gama de ativos (Euronext, 2023). Estes ativos incluem ações *equities*, Fundos de Investimento Negociados em Bolsa (ETFs), *warrants* e certificados, títulos, derivados, *commodities* e índices, como o AEX, BEL 20, CAC 40 e PSI 20 (Bollen, 2023).

A história da Euronext remonta ao ano de 2000, quando resultou da fusão das bolsas de valores de Paris, Bruxelas e Amesterdão. Posteriormente, incorporou a bolsa de valores de Lisboa, consolidando assim sua presença em diversos mercados financeiros (Bollen, 2023). Como tal, esta opera em diferentes mercados como a Euronext Amsterdam, Euronext Brussels, Euronext Lisbon, e Euronext Paris, sendo que cada um destes tem os seus próprios requisitos e regulações, mas atuam sobre a sombra da Euronext. Deve-se ressaltar que a Euronext está sujeita às regulamentações impostas pela Autoridade Europeia de Mercados de Valores Mobiliários (ESMA) e pela Regulação de Abuso de Mercado (MAR) da União Europeia (UE). Essas regulamentações têm como objetivo primordial garantir a imparcialidade e transparência nos mercados financeiros, preservar sua integridade e, sobretudo, proteger os interesses dos investidores (Bollen, 2023).

Um dos principais papéis desempenhados por essa bolsa de valores é permitir que investidores tenham a oportunidade de investir em empresas de diversas dimensões, setores e indústrias, contribuindo para o aumento do capital dessas empresas. No contexto deste estudo, as empresas analisadas fazem parte do setor de energia, um setor crítico da economia global e que desempenha um papel essencial nas relações comerciais internacionais.

### **2.2 Setor de energia**

Os mercados do setor energia são áreas críticas para empresas e governos decidirem o seu desenvolvimento e crescimento futuro (Mensi et al., 2021). Deste modo, a utilização destes recursos de forma eficiente e eficaz é fundamental, tal como, a criação e definição de políticas públicas alinhadas com os objetivos dos países, sendo estas de extrema importância. A falta de políticas energéticas definidas, na verdade, resulta numa série de consequências, especialmente em tempos de crise.

A União Europeia (UE) constitui uma das geografias com maior consumo de energia em todo o mundo e abriga um dos mercados de energia mais desenvolvidos globalmente. No entanto, a sua pobreza em termos de recursos de energia fóssil, como o petróleo e o gás natural, é responsável pelo aumento constante da sua dependência nas importações destes recursos e outros energéticos (Sarkhanov & Muradzada, 2023).

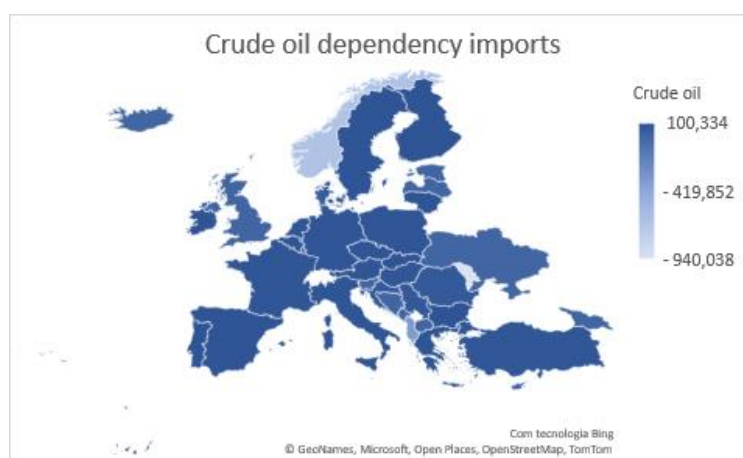
Esta dependência energética é calculada através do rácio entre as importações líquidas e energia bruta disponível, isto é, a capacidade de um país ou região de satisfazer todas as suas necessidades energéticas. Segundo a Eurostat, (2023a, 2023b, 2023c), em 2021, a UE importou cerca de 55% da energia que consome o que representou 15% das importações totais desta. Estes valores variam para cada Estado-membro e, como se pode observar na Tabela 1, com enfoque nos países utilizados neste estudo, a Bélgica e a Irlanda são aqueles que apresentam uma maior dependência de importações de recursos energéticos e, por outro lado, devido à produção própria de matéria energética a Noruega.

*Tabela 1-Dependência de importações energéticas em % da UE*

País	2019	2020	2021
Bélgica	77,592	78,043	70,817
Irlanda	68,631	71,153	76,963
França	47,548	44,402	44,174
Países Baixos	64,359	68,021	58,379
Noruega	-560,581	-618,061	-616,598

Fonte: Elaboração própria

Cerca de 92% das necessidades de óleo e produtos de petróleo, juntamente com 83% das necessidades de gás natural, são supridas por meio de importações, enquanto essa dependência é significativamente menor para os combustíveis fósseis sólidos (37,5%) (Eurostat, 2023a, 2023b, 2023c). A dependência nas importações de cada tipo de recurso energético pode ser observada nas Figura 1, Figura 2, Figura 3, Figura 4, Figura 5 e Figura 6, onde são evidenciados os distintos valores de importação para cada categoria de recursos em toda a geografia europeia.



*Figura 1-Dependência de Importações Energéticas de Petróleo*

Fonte: Eurostat

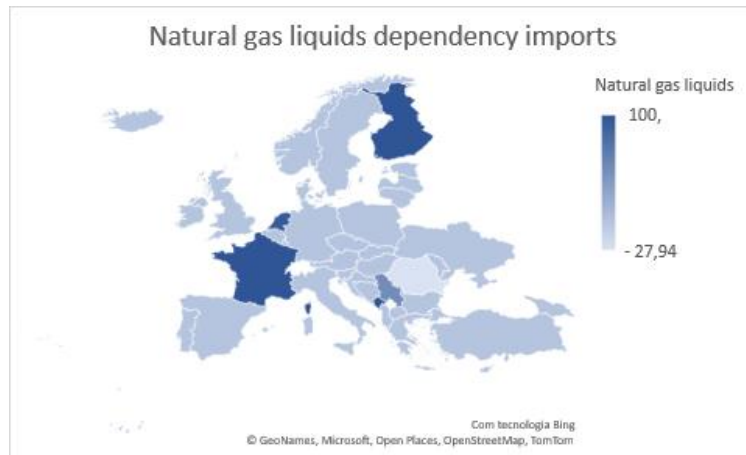


Figura 2-Dependência de Importações de Gás Natural

Fonte: Eurostat

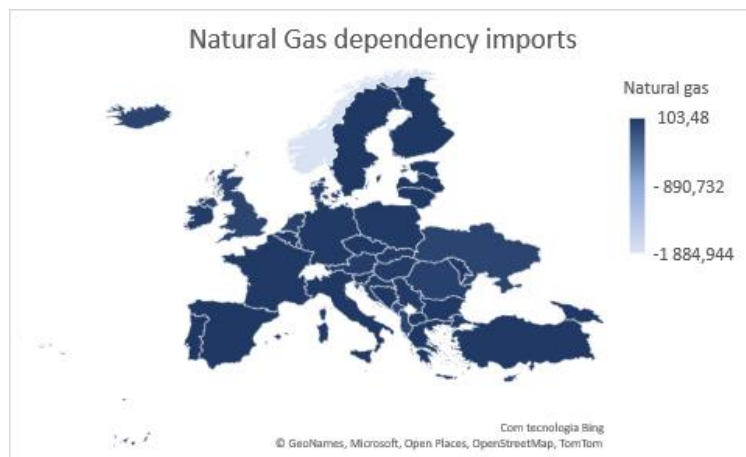


Figura 3-Dependência de Importações Energéticas de Gás Natural Líquido

Fonte: Eurostat

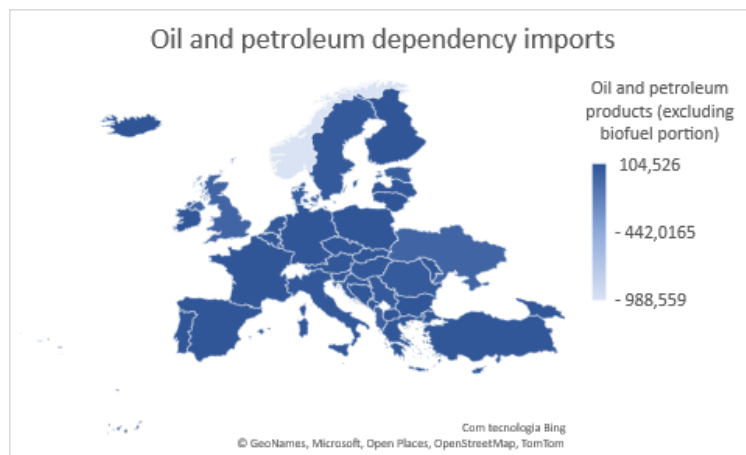


Figura 4-Dependência de Importações Energéticas de Óleo e Petróleo

Fonte: Eurostat

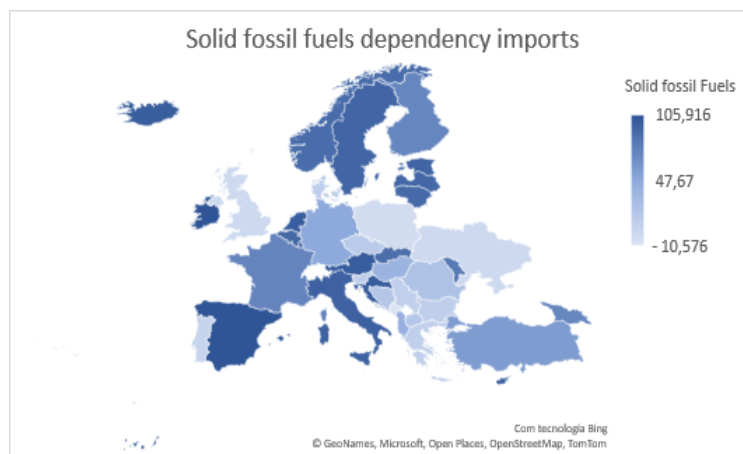


Figura 5-Dependência de Importações Energéticas de Combustíveis Fósseis Sólidos

Fonte: Eurostat

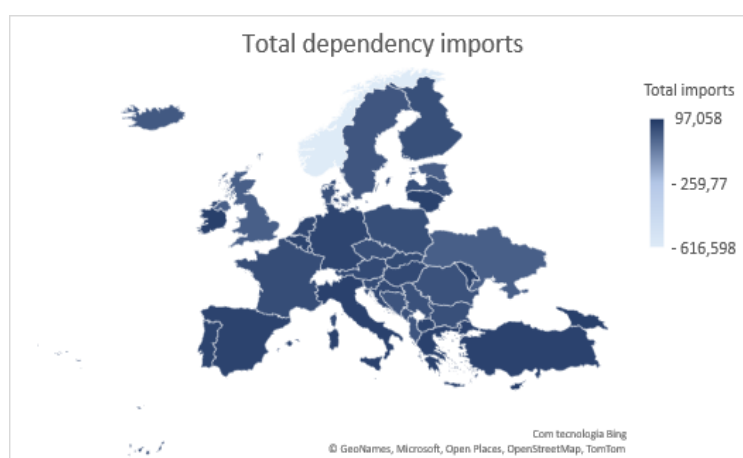


Figura 6-Dependência de Importações Energéticas Total

Fonte: Eurostat

Estas necessidades de importações energéticas dos países europeus são asseguradas por países como a Rússia, Noruega, Iraque, Cazaquistão, Arábia Saudita, entre outros. A Rússia é a principal fonte de importação de recursos energéticos da UE, sendo responsável por cerca de 24,4% das suas necessidades energéticas (Eurostat, 2023b, 2023c). A UE dependeu da Rússia para 41,1% das suas importações de gás natural e de 25,7% de óleo e petróleo bruto. No caso dos combustíveis fósseis líquidos estes valores são aproximadamente 19,3%. Assim sendo, a Rússia tem um papel crucial no abastecimento energético da UE o que aliada ao facto de esta só conseguir satisfazer através da sua própria produção cerca de 43% das suas necessidades energéticas, contribui para a dependência da UE na importação destes recursos. Com isto, acontecimentos que afetem direta ou indiretamente estas relações, podem ser um risco elevado para os países europeus e para o seu crescimento económico, tendo, também, um possível impacto significativo nos mercados financeiros do setor de energia (Bigerna et al., 2023).

Dada a posição da Rússia como um importante ator nos mercados globais de energia e o tamanho de sua economia, o mais recente conflito entre esta e a Ucrânia provocou um aumento

acentuado do risco geopolítico (RGP) nos mercados regionais e internacionais (M. Umar et al., 2022), tendo influência nos preços dos recursos energéticos e no seu abastecimento, colocando, assim, os estados-membros da UE numa situação sensível e complexa.

## **2.3 Guerra entre a Rússia e a Ucrânia**

### **2.3.1 Enquadramento histórico**

Nos últimos anos, diversos eventos extremos têm afetado drasticamente o setor energético, provocando reformulações e mudanças nas cadeias de abastecimento globais (Goodell et al., 2023). Eventos extremos são ocorrências naturais e não naturais que podem potencialmente causar danos nos âmbitos social e económico. Enquanto eventos naturais estão além do nosso controlo, como inundações, terremotos ou tempestades, os eventos não naturais são provocados por uma variedade de fatores incluindo eventos políticos, ocorrências imprevisíveis, os chamados *black swan* e atos intencionais como conflitos armados (Assaf et al., 2023).

Analisar o impacto desses eventos nos mercados financeiros é de extrema importância, não apenas para os investidores diretos que procuram otimizar o seu desempenho financeiro, mas também para os agentes políticos que baseiam as suas decisões e políticas nas previsões de possíveis consequências derivadas de tensões políticas nestes mercados. Estudos recentes na literatura financeira têm explorado a influência desses eventos extremos nos mercados, demonstrando uma conexão clara entre esses acontecimentos e o comportamento dos mercados financeiros. Estas investigações remetem a eventos de grande impacto como o ataque de 11 de setembro (Brounen & Derwall, 2010; Chesney et al., 2011; Nikkinen et al., 2008), Covid-19 (Ashraf & Goodell, 2022; Goodell et al., 2023; Ho et al., 2023; Kinateder et al., 2021; Kumar et al., 2023; Liu et al., 2023; Pandey & Kumari, 2021; Rao et al., 2021), a Segunda Guerra Mundial e outras guerras (Brune et al., 2015; Choudhry, 2010; Hassan et al., 2022; Hudson & Urquhart, 2015; Kollias C. Papadamou S., 2010) e outros acontecimentos significativos (Benos & Johec, 2013; Brune et al., 2015; Guidolin & La Ferrara, 2010).

Segundo, Kollias C. Papadamou S., (2010), eventos de carácter político como guerras, têm um impacto substancial nos mercados financeiros e nos preços dos ativos, embora a magnitude desses efeitos varie de acordo com o mercado, o país e o período de análise. Choudhry (2010) refere que as guerras podem afetar os mercados de ações de 2 formas: através do aumento ou diminuição dos preços das ações e/ou através do aumento da incerteza dos investidores. De facto, Hudson & Urquhart, (2015) estudaram o impacto da segunda guerra mundial nos mercados financeiros e encontraram evidências de uma forte ligação entre estes. Os resultados deste estudo mostraram que os eventos da guerra resultaram em roturas e mudanças estruturais significativas tanto no movimento de preços quanto na volatilidade dos retornos das ações. Além disso, destacaram a presença de um “efeito de negatividade”, no qual tanto eventos considerados negativos como

aqueles considerados positivos afetam profundamente os preços do mercado. O mesmo foi comprovado por Brune et al. (2015), que sustentaram que o histórico de guerras demonstra que os preços do mercado reagem sensivelmente à probabilidade de eclosão destas.

Estas conclusões são consistentes com os resultados dos estudos realizados sobre o efeito da pandemia do Covid 19 nos mercados financeiros. Liu et al. (2023) confirmaram que os preços das ações sofreram quedas substanciais durante a pandemia. O impacto deste surto epidêmico foi, claramente, negativo e significativo nos mercados financeiros globais Pandey & Kumari (2021), afetando adversamente os retornos diários do mercado e os diferentes setores deste (Rao et al., 2021).

Além disso, outro evento que tem destaque nesta área de estudo é o 11 de setembro onde o mercado financeiro global sofreu significativamente. Chesney et al. (2011), revelam que, aproximadamente, dois terços dos ataques terroristas considerados no seu estudo, o 9/11 incluído, resultam num impacto negativo significativo em pelo menos um mercado de ações por eles considerado. Já Johnston & Nedelescu (2006) por meio do seu estudo, também concluíram que os mercados financeiros, após este ataque terrorista nos EUA, foram impactados pelos danos massivos à propriedade e sistemas de comunicação e os níveis de incerteza aumentaram, tal como, a volatilidade de mercado (Nikkinen et al., 2008).

Com base nesta literatura, é razoável esperar que o recente conflito russo-ucraniano tenha efeitos e consequências semelhantes nos mercados financeiros, não só dos países diretamente envolvidos, mas, também, nos restantes mercados globais que estabelecem relações com estes dois países.

### **2.3.2 Explicação do conflito**

A guerra entre a Ucrânia e a Rússia iniciada, a 24 de fevereiro de 2022, representa um desafio único e complexo para os mercados financeiros globais, uma vez que, sendo a Rússia umas das principais economias a nível mundial e tendo esta uma presença predominante nos mercados de energia, coloca o setor de energia sob uma pressão severa, evidenciando a vulnerabilidade deste.

Este conflito iniciou-se em 2014, com a anexação da Crimeia e de partes do leste da Ucrânia por grupos separatistas apoiados pela Rússia. Existiram tentativas por parte de diversos países de estabelecer acordos que procurassem uma solução pacífica, como os Acordos de Minsk, em 2015. No entanto, as tensões continuaram a crescer, tal como a presença das tropas russas na fronteira da Ucrânia. Em 21 de fevereiro de 2022, o presidente russo, Vladimir Putin, oficialmente reconheceu a independência da região de Donbas, que incluía as áreas de Donetsk e Luhansk, já ocupadas por grupos separatistas. No dia seguinte, várias nações impuseram sanções à Rússia, que, em 24 de fevereiro de 2022, lançou uma operação militar e invadiu o território ucraniano.

Em resposta a esse conflito, a União Europeia e outras nações, como Estados Unidos, Austrália, Japão e outras, implementaram uma série de pacotes de sanções contra a Rússia. A Tabela 2 oferece uma visão geral de algumas das sanções adotadas pela UE (Cui et al., 2023).

*Tabela 2-Sanções da UE à Rússia*

Data	Sanção
Fev 2022	A União Europeia anunciou que irá retirar o status de nação mais favorecida (MFN) da Rússia e proibir as empresas da UE de investirem no setor de energia da Rússia
Fev 2022	A União Europeia anunciou que proibirá a venda, fornecimento, transferência ou exportação de certos produtos e tecnologias de refino de petróleo para a Rússia.
Mar 2022	A União Europeia anunciou planos para reduzir as importações de gás russo em dois terços em 2022, gradualmente diminuir sua dependência energética da Rússia e deixar de comprar combustíveis fósseis da Rússia até 2030
Mar 2022	A União Europeia anunciou a proibição de novos investimentos no setor de energia da Rússia e restrições abrangentes à exportação de equipamentos, tecnologia e serviços no setor de energia
Abril 2022	A União Europeia proibiu a compra, importação ou transferência de carvão russo e outros combustíveis fósseis sólidos russos do mercado da UE, o que entrará em vigor em agosto.
May 2022	A União Europeia anunciou que banirá todas as formas de importações de petróleo russo de forma 'ordenada' ao longo dos próximos seis meses

Fonte: Elaboração própria

Espera-se que a perturbação causada por este conflito e as sanções aplicadas por vários países tenham repercussões nos mercados internacionais e regionais, em particular nos preços globais dos recursos energéticos e outros tipos de recursos (Tong, 2024).

### **2.3.3 Impacto do conflito**

Embora este conflito seja de caráter bilateral, inúmeros estudos têm enfatizado o impacto que conflitos geopolíticos dessa natureza exercem nos mercados financeiros. A razão para tal preocupação reside na percepção generalizada de que a incerteza associada à instabilidade política pode ter efeitos substanciais tanto no desempenho do mercado de ações quanto nos perfis de risco de ativos financeiros (Ahmed et al., 2023; Kapar & Buigut, 2020; Zaiane & others, 2018).

Esta volatilidade dos mercados é evidenciada por Berkman et al. (2011) que, a partir de uma amostra de grande dimensão de grandes crises políticas internacionais, testaram a relação entre as mudanças de risco de desastres e a variação nos preços das ações no mercado. Assim, conseguiram demonstrar que o número de crises internacionais afeta significativamente os retornos médios e a volatilidade dos mercados internacionais de ações. Além disso, pesquisas conduzidas por Dimic et al. (2015), bem como por Lehkonen & Heimonen (2015), sugerem que um ambiente de menor risco político tende a se correlacionar com retornos mais elevados nos mercados de ações, independentemente do tipo de mercado.

A literatura mais recente tem exposto a conexão entre variáveis financeiras e períodos existentes de tensão (Bossman et al., 2022). Em relação ao conflito russo-ucraniano, os países envolvidos têm papéis fundamentais no fornecimento de diversos recursos a nível mundial. Assim, esta invasão influencia ou pode influenciar futuramente, em diversos aspetos, os restantes países que estabelecem relações com ambos. As suas atuações no setor energético fazem com que o mercado de energia e financeiro seja suscetível e sensível à sua invasão no território ucraniano.

Segundo a análise empírica efetuada por Cui et al. (2023), a indústria energética é altamente sensível a fatores geopolíticos o que significa que esta guerra e as sanções impostas causarão impactos contínuos no mercado global de energia. Como resultado, eles previram que o conflito russo-ucraniano levará a aumentos de curto prazo nos preços de energia, seguidos por uma transição para uma determinação mais orientada pelo mercado. No longo prazo, este conflito afetará profundamente os padrões de comércio global de energia e reconfigurará o mapa de fornecimento de energia. Além disso, estes estudos também apontaram para o impacto económico direto das ações tomadas por várias nações em resposta ao conflito. A suspensão do comércio entre a Rússia e a Ucrânia teria consequências significativas para a economia ucraniana, com uma redução de 4,18% no PIB. Entretanto, a imposição de sanções conjuntas por parte dos EUA, UE, Coreia do Sul, Japão e Canadá afetaria substancialmente a economia russa, com uma contração de 5,49% no PIB. A UE suportaria grande parte dos custos económicos das sanções, enquanto os EUA enfrentariam perdas relativamente limitadas. Adicionalmente, essas ações resultariam em aumentos nos preços ao consumidor em outras regiões, indicando que a guerra teria um impacto inflacionário global, exceto na Rússia e na Ucrânia. Por fim, o conflito também afetaria os preços de consumo de energia na Ucrânia, com aumentos significativos nos preços do gás natural e do petróleo refinado.

Na verdade, já são vários os estudos realizados que comprovam os efeitos da guerra nos mercados globais. Várias pesquisas, como a de Adekoya et al. (2022), demonstram uma forte conexão entre ativos financeiros durante o período do conflito entre a Rússia e a Ucrânia. Wu et al. (2023) identificaram que esse evento inicialmente reduziu a volatilidade do mercado de ações durante conflitos mais baixos, mas, paradoxalmente, aumentou a volatilidade após a escalada do conflito. O mesmo foi comprovado por Fang & Shao (2022). Outro estudo realizado por Z. Umar



et al. (2022) alcançou análises empíricas que destacaram a influência da guerra nas relações entre os mercados financeiros.

Segundo Mbah & Wasum (2022), é evidente que esta situação provocaria um aumento na inflação, uma redução do consumo das famílias devido aos preços mais elevados de recursos como o petróleo, gás, trigo e minerais. Além disso, as cadeias de abastecimento enfrentam interrupções, a incerteza prejudica o crescimento económico, os investimentos diminuem e ocorrem oscilações nas ações, especialmente na Europa, dado que ambos os países são fornecedores cruciais para muitos estados europeus.

No entanto, vale destacar que, embora esses estudos tenham contribuído significativamente para a compreensão dos impactos imediatos desse conflito, ainda persistem incertezas quanto às repercussões reais na comunidade internacional, bem como em relação às possíveis consequências futuras.

### **2.3.4 Comportamento dos investidores**

Outro fator de considerável importância reside no comportamento dos investidores, um elemento fundamental no ecossistema financeiro.

Como é evidenciado nos estudos realizados por Sharma et al. (2023) e Si Mohammed et al. (2023), a reação dos investidores a incertezas políticas e económicas pode comprometer as suas atuações, resultando numa queda nos investimentos e provocar um crescimento económico mais lento. Este fenómeno traduz-se numa mudança marcante no sentimento do investidor, que tende a adotar uma abordagem mais cautelosa, reavaliar suas estratégias de investimento e optar por ativos com menor risco (Assaf et al., 2023). Consequentemente, essas atitudes contribuem para a instabilidade dos mercados financeiros, já que desencadeiam flutuações nos preços das ações e de outros ativos financeiros.

É importante observar que a crise global atual, desencadeada pela guerra entre Rússia e Ucrânia, provocou uma mudança significativa na dinâmica da volatilidade do mercado de energia. Isso resultou num ambiente de maior vulnerabilidade e incerteza, o que, por sua vez, afeta diretamente o comportamento dos investidores. Como descrito por Fang & Shao (2022), as implicações desse conflito nos mercados e no fornecimento de recursos diversos levam os investidores a adotar uma postura mais conservadora. Isso culmina numa reação negativa nos preços, uma vez que o sentimento do investidor pode exercer uma influência substancial nos efeitos do conflito nos mercados globais, como mencionado anteriormente.

Qadan & Nama (2018), além de descobrirem que indicadores do sentimento do investidor impulsionam mudanças nos retornos e na volatilidade do petróleo, demonstraram que a volatilidade no sentimento do investidor se espalha para o mercado de petróleo, que, por sua vez, provoca uma reação paralela nos retornos e na volatilidade. Não somente isso, essas pesquisas também fornecem evidências sólidas de que o sentimento do investidor pode servir como um preditor do

preço do petróleo e dos valores das principais ações de empresas envolvidas na indústria petrolífera.

No mesmo contexto, Shahzad et al. (2019) destacam, na sua análise, que choques no mercado de petróleo, ou seja, perturbações em variáveis que refletem o sentimento do investidor, têm um impacto significativo na volatilidade desse mercado. Estes choques também desempenham um papel fundamental na previsão de incertezas, taxas de tesouro e no próprio sentimento do investidor, seja ele otimista ou pessimista, especialmente durante períodos de turbulência.

Assim, tal como o estudo de Fang & Shao (2022) indica, perante situações de crise como a escalada do conflito russo-ucraniano, não só a incerteza dos mercados globais aumentou como também a insegurança do investidor, provocando um aumento do impacto da guerra e do risco de volatilidade dos mercados. Como tal, o sentimento do investidor é um fator de extrema importância, uma vez que pode impactar o comportamento de toda a envolvente dos mercados financeiros.

### **2.3.5 Outros fatores relevantes**

Para além do sentimento do investidor, são muitos os fatores que potencialmente influenciam os preços das ações dos mercados financeiros.

Eventos extremos, como guerras, podem causar um aumento acentuado da inflação e consequentemente nos preços das ações dos mercados financeiros (Baker et al., 2019). Além disso, estes eventos podem afetar as taxas de câmbio e, uma vez que estas, segundo Adjasi et al. (2008) e Lawal & Ijirshar (2013), têm uma relação inversa com os retornos dos mercados de ações, alterações no seu comportamento podem provocar mudanças nestes.

No contexto do setor energético, variáveis como os preços do petróleo de Brent têm um impacto significativo nos mercados financeiros globais e nas economias desenvolvidas e emergentes Jebabli et al. (2022). Isto ocorre porque mudanças nos seus preços afetam o desempenho de ativos financeiros (Adekoya et al., 2022). O comportamento dos preços futuros de *commodities* como as emissões de carbono (Oberndorfer, 2009; Veith et al., 2009) e o gás natural (Geng et al., 2021; Rizvi et al., 2022), sendo estes dois recursos energéticos muito exportados e importados, podem influenciar os mercados financeiros de maneira semelhante ao petróleo mencionado anteriormente, dado o crescimento contínuo da sua importância na economia global.

Outros fatores a ter em consideração são o dia da semana e o mês devido aos efeitos de calendário que podem indicar anomalias nos mercados financeiros. Estes incluem o efeito de janeiro, o efeito do dia da semana, o efeito do mês de negociação e o efeito da mudança do mês. Estes efeitos foram encontrados em estudos anteriores (Berument et al., 2007; Boudreaux et al., 2011; Gayaker et al., 2020; Vasileiou E. Samitas, 2015) e são importantes considerações ao analisar a volatilidade e os retornos das ações.

Todos as variáveis mencionadas, segundo a literatura existente, podem influenciar significativamente os preços das ações dos mercados financeiros, mais especificamente, o preço das ações das 102 empresas do setor energético cotadas na Euronext e, por isso, neste estudo, investigamos o seu comportamento individualmente e implementamos estes fatores no modelo de aprendizagem computacional *Gradient Boosting Decision Tree*, de forma a perceber se têm ou não impacto nos preços das ações.

De notar que existem características alternativas às apresentadas que podem, igualmente, influenciar as séries temporais em estudo.

### 3 Metodologia de investigação e Dados

#### 3.1 Dados

A volatilidade dos retornos das ações, como resultado da guerra entre a Rússia e a Ucrânia, não pode ser compreendida exclusivamente através deste evento específico. Portanto, optamos por ter em consideração um conjunto de variáveis que, com base na literatura existente, são reconhecidas por ter o potencial de afetar a variável principal em estudo, ou seja, a volatilidade dos retornos.

Neste estudo, foram utilizados dados dos mercados financeiros de 102 empresas do setor energético cotadas na Euronext, mais especificamente, os preços de fecho das respetivas ações (As informações das empresas como o nome, o mercado, as indústrias, entre outras, encontram-se no Anexo D). Além disso, agregamos, então, um conjunto de variáveis adicionais que tenham, assumindo à priori, influência no comportamento das ações dos mercados financeiros do setor da energia. Identificar corretamente estas características importantes que influenciam os preços das ações é fundamental, visto que pode não apenas melhorar significativamente a precisão das previsões, mas também trazer enormes benefícios económicos para os investidores (Yang et al., 2022). Assim, ao todo foram utilizadas 10 variáveis que incluem, o preço de fecho, a variação do preço de fecho, o preço do índice de mercado correspondente, o preço do petróleo Brent (Adekoya et al., 2023; Jebabli et al., 2022; Mensi et al., 2021; Rizvi et al., 2022), valores da inflação (Mensi et al., 2021), valores da taxa de câmbio (Adjasi et al., 2008; Ahmad et al., 2010; Kennedy & Nourzad, 2016), o preço dos futuros de emissões de carbono (Xu et al., 2022), o preço dos futuros de gás natural (Goodell et al., 2023; Jebabli et al., 2022), o dia da semana (Berument et al., 2007; Caporale & Zakirova, 2017; Lee et al., 2010) e, por fim, o mês (Boudreaux et al., 2011; Vasileiou E. Samitas, 2015).

Optou-se por utilizar os preços do petróleo de Brent, dado que o petróleo é conhecido por ser um fator crítico no mercado financeiro global e por ser um determinante em várias economias, tanto desenvolvidas como emergentes (Jebabli et al., 2022). Por essa razão, uma alteração no seu preço pode influenciar o desempenho de ativos financeiros (Adekoya et al., 2022). Os preços dos futuros de gás natural também foram incluídos, pois, de maneira semelhante ao petróleo, têm o potencial de impactar os mercados financeiros. O papel do gás natural na economia global está em constante crescimento, e sua importância é cada vez mais evidente (Geng et al., 2021; Rizvi et al., 2022). As mudanças nos benefícios económicos do mercado de gás natural podem ser notadas no mercado de ações, atuando como um indicador da atividade económica (Jebabli et al., 2022). Assim, dada a importância do petróleo bruto e do gás natural como *commodities* energéticas importantes para a economia mundial e a interdependência de preços entre estas duas (Mensi et al., 2021), considerou-se crucial utilizar estes dados neste estudo.

De acordo com Chiang & Chen (2023) eventos extremos, como uma guerra, podem provocar uma inflação elevada e, como resultado, a série temporal estudada será interrompida e perturbada por alguns valores influentes, que devem ser controlados. Para além disso, estudos como o de Baker et al. (2019) indicam que a volatilidade do mercado de ações exibe co-movimentos com a inflação. Assim sendo, assumi uma possível influência da inflação na série temporal relativa aos preços das ações das empresas do setor de energia cotadas na Euronext.

Por sua vez, a partir do estudo realizado por Adjasi et al. (2008), é possível perceber que a volatilidade das taxas de câmbio e os retornos do mercado de ações apresentam uma relação inversa. Lawal & Ijirshar (2013) indicam, também, que existe um impacto negativo da taxa de câmbio no desempenho dos mercados de ações. Por esta razão, decidiu-se utilizar as taxas de câmbio para este estudo.

Por outro lado, apesar de não existir conclusões significativas do impacto do comportamento dos preços de emissões de carbono nos mercados de ações, existem alguns estudos que indicam uma relação positiva entre estes (Veith et al., 2009) ou uma relação negativa (Oberndorfer, 2009).

Por último considerou-se as variáveis “dia da semana” e “mês”. Os efeitos de calendário podem ser definidos como sendo anomalias. Estas anomalias podem indicar ineficiências de mercado ou inadequações nos modelos de precificação de ativos (Schwert, 2003). A literatura remete para quatro efeitos de calendário: o *Turn of the year Effect* (TOY) ou *January Effect* onde os retornos das ações são maiores em janeiro em relação aos restantes meses do ano; o *Day of the week effect* (DOW) sendo o qual os retornos diferem consideravelmente consoante o dia da semana; o *trading month Effect* (TM), onde os retornos são maiores na primeira quinzena do mês e menores na segunda e, por fim, o *turn of the month effect* (TOM) que sugere na mudança do mês os valores dos retornos são superiores aos restantes dias. Boudreaux et al. (2011) e Vasileiou E. Samitas (2015) encontraram no seu estudo evidências do efeito de janeiro, onde estava presente a tendência de retornos significativamente mais altos no primeiro mês do ano, em relação aos restantes. Por outro lado, segundo os estudos de Berument et al. (2007) e Gayaker et al. (2020), existem evidências de que os dias da semana têm influência nos retornos das ações como, por exemplo, as quintas-feiras estão associadas a retornos mais altos e segundas-feiras a retornos mais baixos comparados com quartas-feiras e segundas e terças apresentam uma maior volatilidade do que quartas-feiras (Berument et al., 2007) (estas conclusões diferem de estudo para estudo). Assim, estes dois efeitos são anomalias importantes do mercado financeiro e que devem ser consideradas em qualquer estudo que considera efeitos de volatilidade e retornos de ações.

A recolha dos dados foi feita através das plataformas Investing .com (preços das ações, índices do mercado, taxa de câmbio, preço dos futuros de gás natural, emissões de carbono e óleo de brent), Yahoo Finance (preço de ações) e European Central Bank (taxa de inflação). A partir destas informações, foram, posteriormente, calculadas as variáveis dos retornos dos preços das ações e as respetivas variações, tal como foram associados os dias da semana e os meses

correspondentes. Estas novas variáveis foram utilizadas no teste de quebras estruturais, *Chow Test* e na aplicação do modelo de aprendizagem computacional GBDT.

O intervalo de tempo abordado neste estudo está presente na Figura 7 e abrange desde 1 de janeiro de 2021 até 31 de janeiro de 2023, sendo subdividido em dois períodos distintos: o período Pré-Guerra, compreendido entre 1 de janeiro de 2021 e 23 de fevereiro de 2022, e o período Pós-Guerra, que decorreu entre 24 de fevereiro de 2022 e 31 de janeiro de 2023.




Figura 7-Período Temporal

Fonte: Elaboração própria

De notar que todos os dados analisados são de natureza diária, com a exceção da inflação, que é uma variável mensal. No caso específico da inflação, a abordagem utilizada consistiu em calcular uma média a partir dos dados de vários países europeus, e essa média foi então aplicada como a variável representativa da inflação. Adicionalmente, essa média foi replicada para cada dia do mês correspondente.

### 3.2 Subdivisão do trabalho e métodos utilizados

A primeira etapa deste estudo envolveu a recolha e seleção de dados e características que seriam utilizados na análise subsequente. Após este passo e posterior ao tratamento de dados, foi realizada uma análise preliminar dos dados. Nesta fase inicial, as variáveis foram visualizadas por meio de gráficos lineares, permitindo observar visualmente qualquer mudança notável no seu comportamento ao longo do tempo.

Posteriormente, a fim de identificar potenciais pontos de quebra estrutural nos dados, recorreu-se ao uso do *Chow Test*, desenvolvido por Chow (1960). Este teste é amplamente utilizado na econometria e nas ciências sociais para avaliar mudanças estruturais em séries temporais. Ele examina a possibilidade de existirem diferenças significativas entre os coeficientes de dois modelos de regressão separados, estimados em subconjuntos de dados. O procedimento envolve a divisão da amostra de dados em dois subperíodos, a estimação dos parâmetros em cada subperíodo e, em seguida, a aplicação de um teste estatístico F-clássico para avaliar a igualdade

dos dois conjuntos de parâmetros (1). No entanto, é importante ressaltar que o *Chow Test* apresenta uma limitação significativa, que é a necessidade de selecionar uma data de quebra potencial de forma arbitrária ou com base em algum conhecimento prévio sobre os dados. Isto é, este exige um conhecimento e domínio sobre o possível momento de quebra associado (Hansen & Sargent, 2001; Pancera & Alves, 2020).

$$ChowTest\ F - Statistic = \frac{\frac{RSS_p - (RSS_1 + RSS_2)}{K}}{\frac{RSS_1 + RSS_2}{n - 2K}} \quad (1)$$

Onde:

- $RSS_p$  é a soma dos quadrados dos resíduos de um modelo que considera todos os dados como uma única amostra.
- $RSS_1$  é a soma dos quadrados dos resíduos da primeira subamostra (antes da suposta mudança estrutural).
- $RSS_2$  é a soma dos quadrados dos resíduos da segunda subamostra (depois da suposta mudança).
- $K$  é o número de variáveis independentes no modelo.
- $n$  é número total de observações nos dados, isto é, a dimensão da amostra

Neste estudo, este teste é aplicado para validar potenciais quebras estruturais nos retornos dos preços de fecho e das séries dos índices de mercado das empresas do setor energético cotadas na Euronext, devido ao impacto indireto da guerra neste setor.

Define-se como hipótese nula a estabilidade ou consistência do comportamento dos retornos das ações das empresas do setor energético cotadas na Euronext, isto é, não existe quebra estrutural. Identificou-se como possível *breakpoint* a data de início da Guerra entre a Rússia e a Ucrânia, ou seja, 24 de fevereiro de 2022, uma vez que este marco teve influência no setor da energia, mais propriamente, no preço dos bens e, conseqüentemente, teve impacto em decisões dos acionistas destas empresas.

Dividimos o nosso estudo em seis segmentos distintos, que abrangem diferentes períodos antes e depois do evento: uma semana antes e uma semana depois, duas semanas antes e duas semanas depois, três semanas antes e três semanas depois, um mês antes e um mês depois, dois meses antes e dois meses depois, quatro meses antes e quatro meses depois, e, por fim, o período completo. Essa segmentação foi adotada para avaliar possíveis variações nos resultados do teste decorrentes da escolha do período de análise.

Após a identificação e validação do ponto de quebra estrutural, testou-se os padrões dos preços diários das ações entre os períodos pré e pós-guerra. Esta análise desempenha um papel crítico nos mercados financeiros, pois padrões que podem ser previstos desempenham podem contribuir para escolhas estratégicas por parte dos investidores e até mesmo para políticas públicas (Q. Zhang et al., 2022). Este passo envolveu a aplicação do modelo de aprendizagem computacional *Gradient Boosting Decision Tree* para prever as variações nos dados. O desempenho deste modelo foi posteriormente avaliado através de matrizes de confusão e de métricas de avaliação de *performance*.

O rápido desenvolvimento de técnicas de aprendizagem computacional tem potenciado a utilização destes modelos nas mais diversas áreas, como nos mercados financeiros, devido à sua capacidade de analisar séries temporais (Pan Tang & Yu, 2023). De facto, as abordagens de aprendizagem computacional apoiam os mercados financeiros, uma vez que, os movimentos dos preços das ações são altamente não lineares e complexos o que dificulta a previsão destes (Pan Tang & Yu, 2023). No seu estudo, Basak et al. (2019), previram movimentos dos preços das ações em relação ao preço do dia anterior através de modelos de aprendizagem computacional e demonstraram que o uso destes métodos é uma vantagem significativa e pode contribuir para uma alta precisão na previsão da direção dos preços das ações e talvez na previsão do grau de mudança nos preços das ações ao longo do tempo.

Neste estudo, estamos perante um problema de classificação. Segundo Basak et al. (2019), o modelo de classificação fornece uma visão probabilística da análise preditiva e, portanto, desempenha um papel mais seguro, pois prevê a direção da tendência. Ele usa a probabilidade da situação e, portanto, os resultados são mais confiáveis. Mas é importante destacar que estes modelos de previsão são altamente insensíveis a picos e vales dos dados das series temporais e, por esta razão, pode provocar previsões incorretas. Desta forma, utilizar métodos de classificação de árvores de decisão pode contornar este problema (Basak et al., 2019).

O GBDT é um algoritmo de conjunto que visa agregar várias árvores de decisão num único preditor mais eficiente (Boldini et al., 2023). Este tem sido amplamente utilizado com sucesso em classificação, aprendizagem de classificação, previsão estruturada, entre outros. A literatura recente demonstra a robustez deste modelo e o bom desempenho do mesmo. (Q. Zhang et al., 2022), referem no seu estudo que o GBDT alcançou um melhor desempenho de classificação que os restantes modelos utilizados, tanto nos conjuntos de validação, como nos conjuntos de teste. Além disso, Basak et al. (2019), indicam também que este produziu resultados de alta *performance* na construção do seu modelo preditivo, que demonstrou ser robusto na previsão da direção dos movimentos das ações. Krauss et al. (2017), chegaram à mesma conclusão de que a *performance* do modelo de seleção de ações construído por eles, foi superior quando combinado com o GBDT.



Com base nestas evidências, adotei a utilização o modelo *Gradient Boosting Decision Tree* no contexto do meu trabalho. O GBDT é uma abordagem notável que se destaca pelo seu processo de treino. Este processo engloba várias etapas cruciais que são fundamentais para o sucesso do modelo, como:

- **Inicialização:** Inicia-se o processo com a criação de um modelo inicial simples, conhecido como  $F_0(x)$ . Este modelo inicial é frequentemente estabelecido como uma estimativa fundamental, como a média dos valores-alvo em problemas de regressão ou a classe majoritária em problemas de classificação. A motivação por trás dessa abordagem é permitir que o modelo comece com uma estimativa "ingénuo" com base nos dados disponíveis. À medida que o processo de *Gradient Boosting Decision Tree* avança, o modelo empenha-se em aprimorar esta estimativa em cada iteração. O GBDT adota uma estratégia de aprendizagem incremental. Numa fase inicial, as previsões do modelo podem ser imprecisas. No entanto, à medida que o processo prossegue, o GBDT realiza ajustes graduais no modelo para corrigir essas imprecisões. Isso ocorre por meio da adição de árvores de decisão que visam capturar os erros residuais deixados pelo modelo anterior. O resultado é uma progressiva melhoria na precisão do modelo, à medida que ele se aproxima cada vez mais das previsões corretas.
- **Cálculo dos resíduos:** Calcula os resíduos entre as previsões atuais e os valores reais. Previsões atuais são as previsões feitas pelo modelo na iteração atual. Valores Reais são os valores reais do alvo no conjunto de dados. Isso ajuda a identificar os erros do modelo atual. Os resíduos desempenham um papel fundamental no contexto do *Gradient Boosting Decision Tree*, pois são utilizados como alvos para o treino de árvores de decisão adicionais com o propósito de corrigir os erros do modelo vigente. Em cada iteração, uma nova árvore é treinada com o objetivo de capturar os resíduos remanescentes deixados pelo modelo anterior. A combinação sucessiva dessas árvores resulta num modelo final mais preciso. Esse processo é conhecido como "treino sequencial" ou "impulsioneamento", uma vez que cada nova árvore impulsiona a correção dos erros do modelo anterior. Através dessa abordagem, o GBDT consegue aprender de maneira iterativa e aprimorar as suas previsões, focalizando os erros residuais e refinando continuamente o seu desempenho.
- **Treino:** O treino envolve a criação de árvores de decisão adicionais que visam corrigir os erros residuais do modelo anterior. Neste processo, a cada iteração, uma nova árvore, representada como  $F_0(x)$  é desenvolvida com o objetivo de minimizar os resíduos que ainda persistem. Os resíduos dos modelos anteriores são utilizados como os novos valores-alvo para o treino das árvores adicionais, estabelecendo uma conexão direta entre as iterações. Algumas implementações do GBDT permitem a aplicação de

técnicas de regularização, como a limitação do número de folhas ou a introdução de termos de penalização. Essas práticas têm o propósito de manter o crescimento das árvores sob controle e assegurar a estabilidade do modelo. É importante notar que o número de árvores a serem incluídas deve ser cuidadosamente equilibrado, uma vez que um excesso de árvores pode resultar em complexidade excessiva e até mesmo *overfitting*. Além disso, a profundidade das árvores desempenha um papel essencial na construção do modelo. Árvores menos profundas podem simplificar o modelo, enquanto árvores mais profundas são capazes de capturar relações mais intrínsecas nos dados. Tal como a gestão do número de árvores, a gestão da profundidade é uma medida de controlo contra o *overfitting*. O treino das árvores de decisão adicionais é o ponto fulcral do GBDT e ocorre de forma sequencial, permitindo que o modelo se concentre em corrigir os erros residuais e aprimorar continuamente o seu desempenho. A combinação progressiva de múltiplas árvores, cada uma dedicada a retificar os erros do modelo anterior, culmina num modelo final altamente preciso e robusto. Esta abordagem sequencial é uma das principais características que torna o GBDT tão eficaz em diversas aplicações de aprendizagem computacional.

- Atualização do modelo: Após a criação de cada nova árvore de decisão, ela é adicionada de forma iterativa ao modelo existente. A nova árvore é ponderada pela taxa de aprendizagem ( $\eta$ ), que é um hiperparâmetro do GBDT. Isso significa que o impacto da nova árvore nas previsões globais é controlado pela taxa de aprendizagem. Ela controla o tamanho dos ajustes feitos em cada iteração. Valores menores de que  $\eta$  resultam em ajustes menores e mais suaves, enquanto valores maiores podem levar a ajustes mais bruscos. Encontrar o valor adequado de  $\eta$  é uma parte importante do ajuste do GBDT. A atualização do modelo ocorre de forma sequencial a cada iteração do processo de treino. À medida que novas árvores são adicionadas, o modelo aproxima-se das previsões corretas, corrigindo os erros residuais a cada passo. A cada iteração, a função de previsão é atualizada como:

$$F(x) = F(x) + \eta * f_m(x) \quad (2)$$

Onde:

- $F(x)$  é a função de previsão atualizada.
- $\eta$  é a taxa de aprendizagem.
- $f_m(x)$  é a árvore de decisão recém-adicionada na iteração  $m$

Após todas as iterações, o modelo resultante é uma combinação ponderada de todas as árvores de decisão criadas, ajustadas para minimizar os erros residuais em cada

etapa. Esse modelo final é a previsão do GBDT para novas amostras. A atualização do modelo no GBDT é um componente fundamental, pois permite que o modelo aprenda e corrija os erros residuais iterativamente, levando a previsões mais precisas à medida que mais árvores são adicionadas. A combinação das árvores ajustadas, cada uma concentrando-se em corrigir os erros do modelo anterior, resulta num modelo global forte e preciso.

- Repetição: Os passos 2 a 4 são reiterados por um número predefinido de iterações ou até que um critério de paragem seja satisfeito. Esse processo de treino é executado várias vezes, com cada iteração incorporando uma nova árvore de decisão ao modelo. O número de iterações é um hiperparâmetro ajustável, adaptado de acordo com as necessidades específicas do problema e os recursos disponíveis. Durante o curso das iterações, é possível interromper uma iteração assim que critério de paragem seja alcançado. Este critério pode incluir a constatação de que o desempenho do modelo atingiu um patamar satisfatório ou que o número desejado de árvores foi adicionado, por exemplo. Esta flexibilidade permite que o treino do modelo seja ajustado de acordo com os objetivos específicos do problema. Ao longo da repetição do processo, é viável realizar ajustes nos hiperparâmetros, como a taxa de aprendizado ( $\eta$ ), a profundidade das árvores e o número de árvores, com o intuito de otimizar o desempenho do modelo. Esse ajuste refinado contribui para o aprimoramento contínuo do modelo. A característica fundamental do GBDT é a repetição do processo, o que possibilita que o modelo seja gradualmente ajustado até que as previsões atinjam um nível desejado de precisão ou até que sejam alcançados os critérios de paragem estipulados. Esta abordagem sequencial confere ao GBDT eficácia na captura de relacionamentos complexos nos dados e na correção de erros a cada iteração, culminando num modelo final que é mais robusto e preciso, como dito anteriormente.

Para realizar este teste optou-se por duas abordagens, o pré-guerra e o pós-guerra, que na verdade é o período que inicia com o começo deste conflito. Definiu-se como período a utilizar o de 1 de janeiro de 2021 a 24 de março de 2022 e subdividiu-se este período consoante a abordagem anteriormente referida. Para a pré-guerra, dividiu-se o período definido em dois subperíodos: 1 de janeiro de 2021 até 24 de janeiro de 2022 (1 mês antes do início da guerra), sendo este considerado o conjunto de treino, e 24 de fevereiro de 2022 até 24 de março de 2022, período correspondente ao conjunto de teste. Já no segundo caso, o conjunto de treino estende-se até 24 de fevereiro de 2022 e o conjunto de teste mantêm-se igual.

Este estudo envolve um problema de aprendizagem computacional multivariado. A volatilidade dos retornos das ações, em decorrência da guerra entre a Rússia e a Ucrânia, não pode ser explicada apenas por esse evento isoladamente. Portanto, considerou-se um conjunto de variáveis que, de acordo com a literatura, têm o potencial de influenciar a variável principal, a

volatilidade dos retornos e, por isso, foram incluídas no modelo. Assim, considerou-se como variáveis independentes a média de inflação, o preço de fecho, o preço do índice de mercado, a taxa de câmbio, os preços futuros de emissões de carbono, de petróleo Brent e gás natural, o dia da semana e o mês. Para a variável dependente, inicialmente calcularam-se os retornos dos preços de fecho das ações das empresas em estudo e a variação desses retornos. Assim, o modelo prevê com base nessa nova variável calculada, que pode assumir valores de -1 ou 1.

Após calculada a previsão, então é analisada a performance deste modelo de aprendizagem computacional, através da matriz de confusão e de medidas como o *Accuracy*, *Precision*, *Recall* e *F1-score*. Calculou-se as matrizes de confusão de cada uma das empresas e as medidas de performance correspondentes. Estas métricas de avaliação desempenham um papel fundamental na análise do desempenho de um modelo de classificação, pois permitem considerar diversos aspectos das previsões calculadas. A escolha das medidas adequadas depende das características específicas do problema em questão e de seus requisitos específicos, possibilitando assim selecionar a métrica (ou métricas) que melhor se ajusta ao contexto para avaliar e comparar diferentes modelos.

Uma matriz de confusão é uma representação fundamental usada para avaliar o desempenho de um modelo de aprendizagem computacional de um problema de classificação. Geralmente é organizada numa tabela 2x2, podendo ser adaptada ao problema de classificação em estudo, e oferece uma visão detalhada das previsões resultantes da utilização do modelo em relação aos valores reais dos dados utilizados. É principalmente utilizada na classificação de níveis de risco, na identificação da possibilidade de falência ou na pesquisa sobre análise de preferência por risco no campo financeiro (Kong et al., 2023). Neste estudo, o problema de classificação é binário e por isso, a matriz representada na Tabela 3 inclui as seguintes categorias:

- Verdadeiro Positivo (True Positive - TP): indica as instâncias corretamente previstas como positivas pelo modelo, quando essas instâncias são de facto positivas. Ou seja, neste caso, significa que as previsões calculadas correspondem corretamente às variações dos retornos dos preços das ações negativas (-1).
- Verdadeiro Negativo (True Negative - TN): representa as instâncias que o modelo corretamente previu como negativas e que são realmente negativas. Neste estudo, refere-se às previsões corretas das variações positivas (1) dos retornos dos preços das ações.
- Falso Positivo (False Positive - FP): demonstra as instâncias que foram classificadas como positivas pelo modelo, quando, na verdade, são negativas. Esta situação é conhecida por ser um erro do Tipo I. Isto é, os valores das previsões deviam ter sido iguais a -1, no entanto, o modelo previu variações positivas (1).
- Falso Negativo (False Negative - FN): refere-se às instâncias que foram previstas como negativas pelo modelo, quando, segundo os valores reais, são realmente

positivas. Neste caso estamos perante um erro do Tipo II. Esta situação acontece quando o modelo prevê variações negativas (-1) e, na verdade, deviam ser variações positivas (1).

Tabela 3-Matriz de Confusão

		Valor Previsto	
		-1	1
Valor Real	-1	Verdadeiro Positivo (TP)	Falso Negativo (FN)
	1	Falso Positivo (FP)	Verdadeiro Negativo (TN)

Fonte: Elaboração própria

Assim, esta matriz é uma ferramenta essencial para calcular várias métricas de avaliação do modelo, como a *Accuracy*, a *Precision*, a *Recall (Sensitivity)* e a *F1-score*, entre outras. Estas métricas ajudam a avaliar a capacidade de classificação de diferentes classes do modelo e são fundamentais na análise e aprimoramento de modelos de aprendizagem computacional para problemas de classificação.

A *Accuracy* avalia a precisão global das previsões feitas por um modelo, sendo calculada como a proporção entre o número de previsões corretas e o total de previsões realizadas. É geralmente utilizada como uma medida agregada para indicar a capacidade do modelo de classificação em categorizar corretamente os resultados positivos e negativos.

$$Accuracy = \frac{TP + TN}{TN + FP + TP + FN} \quad (3)$$

A métrica *Precision* concentra-se nas previsões positivas resultantes do modelo e avalia a sua capacidade de identificar corretamente as instâncias positivas. Representa a razão entre as verdadeiras previsões positivas e a soma das verdadeiras previsões positivas e as falsas previsões positivas e é capaz de quantificar a eficiência do modelo em evitar a ocorrência dos falsos positivos. Esta métrica deve ser idealmente igual a 1.

$$Precision = \frac{TP}{TP + FP} \quad (4)$$

Por outro lado, o *Recall*, também conhecido por *Sensitivity* ou *true positive rate* (taxa de verdadeiros positivos), foca-se nos verdadeiros positivos presentes no conjunto de dados. É calculado através da razão entre as verdadeiras previsões positivas e a soma destas com as falsas previsões negativas. Assim, esta medida avalia a capacidade do modelo em identificar os

verdadeiros positivos e quantifica a eficiência do modelo em evitar a ocorrência dos falsos negativos. Tal como a *Precision*, esta métrica deve ser idealmente igual a 1.

$$Recall = \frac{TP}{TP + FN} \quad (5)$$

Para ser considerado um bom classificador, o modelo deve apresentar a *Precision* e *Recall* iguais a 1 ou o mais próximo possível desse valor. Assim, surge o *F1-score* que é considerado uma combinação da *Precision* e *Recall* numa média harmónica. Esta considera tanto os falsos positivos como os falsos negativos e é considerado como sendo uma melhor medida que a *Accuracy*.

$$F1 - score = 2 * \frac{Precision * Recall}{Precision + Recall} \quad (6)$$

De notar que, para tratar e processar os dados e para realizar os gráficos, o *Chow Test*, o *GBDT* e a avaliação da sua *performance*, recorri ao *python*, uma vez que, devido à disponibilidade de bibliotecas de alta qualidade, como [numpy](#), [pandas](#), [stastmodels](#) e [scikit learn](#) tornou o processo muito mais eficiente e reduzindo a sua complexidade.

## 4 Resultados

Esta secção analisa os resultados obtidos através do processo anteriormente descrito na metodologia, em torno dos dados dos preços de fecho da bolsa de valores das 102 empresas do setor energético cotadas na Euronext.

Como mencionado, o estudo começa com uma análise preliminar dos dados coletados por meio de um gráfico linear, que permite examinar a dinâmica dos dados e identificar quaisquer mudanças no comportamento das variáveis que possam indicar alguma influência do conflito.

Posteriormente, assumindo um possível ponto de quebra estrutural, procedi à utilização do *Chow Test*, para estudar e avaliar mudanças estruturais do conjunto de dados da série temporal, ao longo do período de 1 de janeiro de 2021 a 31 de janeiro de 2023.

De seguida, recorri ao modelo computacional *Gradient Boosting Decision Tree* (GBDT) para executar a previsão dos dados. Por fim, procedi à avaliação do desempenho do modelo através de matrizes de confusão para cada empresa e avaliando as métricas de *performance*, a *Accuracy*, a *Precision*, a *Recall (Sensitivity)* e a *F1-score*

### 4.1 Gráfico linear

Numa fase inicial, optou-se por analisar e identificar possíveis mudanças no comportamento das variáveis independentes, isto é, aquelas que potencialmente podem influenciar a nossa variável dependente. Assim, a partir dos gráficos lineares apresentados abaixo, é possível observar o comportamento das seguintes variáveis: inflação média, preços dos futuros de emissões de carbono, de gás natural e de petróleo Brent e valores da taxa de câmbio. Realizou-se esta análise visto que segundo a literatura existente (Chiang & Chen, 2023; Lawal & Ijirshar, 2013; Mensi et al., 2021; Veith et al., 2009), estas variáveis têm um impacto na volatilidade dos mercados financeiros e, assim, uma mudança significativa do seu comportamento, indicará possivelmente uma mudança na série temporal em estudo.


A inflação média revela uma tendência de crescimento desde o ano de 2021 até aproximadamente novembro de 2022, a partir do qual a curva começa a decrescer. Assim, a análise do gráfico linear, como se pode ver na Figura 12, não sugere nenhum impacto direto na série temporal decorrente do início do conflito entre Ucrânia e Rússia.

O mesmo padrão é observado nos valores da taxa de câmbio (Figura 9). Embora essa variável apresente mais oscilações nos seus valores do que a inflação média, ela segue uma tendência de crescimento e, a partir de novembro de 2022, começa a diminuir. Por outro lado, no caso dos preços dos futuros de emissões de carbono, de acordo com a Figura 10, parece haver um impacto do conflito russo-ucraniano no seu comportamento. Até fevereiro de 2022, essa variável estava em ascensão, mas entre o segundo e o terceiro mês desse ano, observamos uma queda acentuada nos preços, que posteriormente voltam a subir. Por outro lado, os preços do petróleo Brent (Figura 8) mostram um aumento gradual até à data da invasão que posteriormente parece crescer

acentuadamente e ter uma diminuição significativa entre março e abril de 2022, voltando a aumentar após este período.

No que diz respeito aos preços dos futuros de gás natural, eles estão em crescimento até novembro de 2021, a partir do qual começam a decrescer. No entanto, em fevereiro/março de 2022, esta série apresenta um crescimento significativo, que cai novamente em junho/julho do mesmo ano, para então voltar a subir até setembro. Posteriormente, a série começa a diminuir mais uma vez, como se pode observar a partir da Figura 11.


Portanto, com base na análise dos gráficos lineares, os dados das séries temporais da inflação média e da taxa de câmbio não indicam um impacto significativo no seu comportamento durante o período anterior e posterior à escalada do conflito, ao contrário do que parece ocorrer com as séries relacionadas aos preços dos futuros de emissões de carbono, de gás natural e de petróleo Brent.



*Figura 8-Petróleo Brent*


Fonte: Elaboração própria





*Figura 9-Taxa de câmbio*

Fonte: Elaboração própria



*Figura 10-Emissões de Carbono*

Fonte: Elaboração própria




Figura 11-Gás Natural

Fonte: Elaboração própria




Figura 12-Taxa Média de Inflação

Fonte: Elaboração própria

## 4.2 Chow Test

Como referido no capítulo anterior, utilizou-se o *Chow Test* para perceber se a data de início da guerra entre a Ucrânia e a Rússia, 24 de fevereiro de 2022, teve influência no comportamento dos preços de fecho das ações das empresas energéticas cotadas na Euronext e, assim, comprovar se é, de facto, um ponto de quebra estrutural. Utilizou-se os retornos dos preços calculados e dividiu-se esta fase por 6 períodos de forma a perceber se tinha influência nos resultados.

Os resultados do teste, que se encontram-se no Anexo A, revelaram a validação do ponto de quebra estrutural em apenas duas das 102 empresas estudadas e demonstraram que não houve qualquer diferenciação na divisão dos períodos utilizados. Este ponto de quebra ocorreu em relação à empresa Veolia Environnement, cotada na Euronext Paris, do setor industrial de gestão

de resíduos. A hipótese nula foi rejeitada para os seguintes períodos: 1, 2 e 4 semanas antes e depois de 24 de fevereiro de 2022, bem como para o primeiro e segundo mês anterior e posterior a essa data. Nestes casos, os valores do *p-value* estiveram abaixo do nível de significância de 0,05, sugerindo uma quebra estrutural entre os períodos anteriores e posteriores ao início do conflito. A hipótese nula também foi rejeitada para a empresa Ren, listada na Euronext Lisbon, nos quatro meses anteriores e posteriores à data de referência.

Com base nessas constatações, podemos concluir que a data de início da guerra não representou um ponto de quebra estrutural para a maioria das empresas, indicando que, em grande parte, não houve mudanças significativas ou influências no comportamento dos retornos dos preços calculados.

### 4.3 Gradient Boosting Decision Tree

No âmbito deste estudo, o modelo *Gradient Boosting Decision Tree* (GBDT) foi aplicado às variáveis previamente mencionadas. Testou-se os padrões dos preços diários das ações entre os períodos pré e pós-guerra. No contexto do modelo, utilizou-se a variável calculada das variações dos retornos dos preços das ações das empresas do setor de energia cotadas na Euronext, que pode assumir valores de -1 ou 1, como variável dependente. Como variáveis independentes, foram incluídas a inflação média, o preço de fecho, o preço do índice de mercado, a taxa de câmbio, os preços dos futuros das emissões de carbono, do gás natural e do petróleo Brent, o dia da semana e o mês. As previsões foram calculadas para os dois períodos definidos, nomeadamente o pré-guerra e o pós-guerra. Para cada período foram definidos um conjunto de treino e um conjunto de teste. No período pré-guerra o conjunto de treino está compreendido entre 1 de janeiro de 2021 e 24 de janeiro de 2022 e o conjunto de teste entre 24 de fevereiro de 2022 até 24 de março de 2022. Por outro lado, o conjunto de treino no período pós-guerra inicia-se a 1 de janeiro de 2021 e termina a 24 de fevereiro de 2022, sendo que o conjunto de teste é igual para ambos os períodos. Esta análise é fundamental para os mercados financeiros, uma vez que, padrões previsíveis podem ter um papel de extrema importância nas decisões estratégicas de negociação (Q. Zhang et al., 2022).

Após a aplicação do modelo de aprendizagem computacional GBDT e o cálculo das previsões para ambos os períodos, foram geradas matrizes de confusão para as 102 empresas e as medidas de desempenho correspondentes, que incluem *Accuracy*, a *Precision*, a *Recall (Sensitivity)* e a *F1-score*.

De acordo com estes resultados, selecionei as empresas com melhor e pior desempenho com base nos valores das métricas *Accuracy* e *F1-score*. Assim, pode-se ver na Tabela 4 e Tabela 5.

Tabela 4-Performance do GBDT, período Pré-Guerra

Company	City	Csv	Pre Accuracy	Pre Precision (-1)	Pre Recall (-1)	Pre F1-score (-1)	Pre Precision (1)	Pre Recall (1)	Pre F1-score (1)
AKER BP	Oslo	<a href="#">AKRBP</a>	0,75	1	0,17	0,29	0,74	1	0,85
AKER SOLUTIONS	Oslo	<a href="#">AKSOA</a>	0,7	0,62	0,62	0,62	0,75	0,75	0,75
AWILCO DRILLING	Oslo	<a href="#">AWDR</a>	0,3	0,32	0,86	0,46	0	0	0
ELMERA GROUP	Oslo	<a href="#">ELMRA</a>	0,65	0,65	0,92	0,76	0,67	0,25	0,36
OKEA	Oslo	<a href="#">OKEA</a>	0,75	0,5	0,8	0,62	0,92	0,73	0,81
EO2	Paris	<a href="#">ALEO2</a>	0,3	0,3	1	0,46	0	0	0
SEQUA PETROLEUM NV	Paris	<a href="#">MLSEQ</a>	0,5	0,22	0,4	0,29	0,73	0,53	0,62
TOTALENERGIES	Paris	<a href="#">TTEF</a>	0,55	0,5	0,78	0,61	0,67	0,36	0,47
VEOLIA ENVIRON.	Paris	<a href="#">VIE</a>	0,4	0	0	0	0,4	1	0,57

Fonte: Elaboração própria

Tabela 5-Performance do GBDT, período Pós-Guerra

Company	City	Csv	Pos Accuracy	Pos Precision (-1)	Pos Recall (-1)	Pos F1-score (-1)	Pos Precision (1)	Pos Recall (1)	Pos F1-score (1)
AKER BP	Oslo	<a href="#">AKRBP</a>	0,67	0,5	0,2	0,29	0,69	0,9	0,78
AKER SOLUTIONS	Oslo	<a href="#">AKSOA</a>	0,6	1	0,08	0,14	0,59	1	0,74
AWILCO DRILLING	Oslo	<a href="#">AWDR</a>	0,43	0,43	1	0,6	0	0	0
ELMERA GROUP	Oslo	<a href="#">ELMRA</a>	0,53	0,54	0,94	0,68	0,5	0,07	0,12
OKEA	Oslo	<a href="#">OKEA</a>	0,73	0,57	0,44	0,5	0,78	0,86	0,82
EO2	Paris	<a href="#">ALEO2</a>	0,43	0,41	1	0,59	1	0,06	0,11
SEQUA PETROLEUM NV	Paris	<a href="#">MLSEQ</a>	0,73	0	0	0	0,73	1	0,85
TOTALENERGIES	Paris	<a href="#">TTEF</a>	0,5	0,5	1	0,67	0	0	0
VEOLIA ENVIRON.	Paris	<a href="#">VIE</a>	0,43	1	0,06	0,11	0,41	1	0,59

Fonte: Elaboração própria

Destaquei três empresas que demonstram desempenhos distintos em relação ao modelo de previsão, sendo estas: Okea, Total Energies Carbon e EO2. Os resultados das restantes empresas encontram-se no Anexo B.

A Okea, do mercado financeiro norueguês, destaca-se como a empresa cujo modelo apresenta o melhor desempenho global entre todas as 102 empresas analisadas. A partir da Tabela 4, notamos que a *Accuracy* alcança o valor mais elevado em comparação com todas as outras empresas, tanto no período pré-guerra quanto no período pós-guerra. Embora a *Precision* não atinja níveis excepcionalmente altos quando se trata da previsão de variações “-1”, é fundamental destacar que ela apresenta um aumento notável quando nos deparamos com as variações iguais a 1. Isso indica que o modelo é mais preciso na identificação de eventos ou movimentos que levam

a variações “1”, o que pode ser especialmente valioso em contextos de investimento. Além disso, é interessante observar que a *Recall*, que mede a capacidade do modelo em capturar todas as instâncias de um evento, exibe uma diferença notável quando comparamos as previsões de variações iguais a -1 entre o período pré-guerra e o período pós-guerra. Ela demonstra um desempenho superior no primeiro período, sugerindo que o modelo é mais eficaz em identificar eventos que levam a variações “-1” antes do período de conflito. O comportamento do modelo pode ser explicado, possivelmente, pelo facto dos dados não serem balanceados, existindo mais variações “1” do que “-1”, prevê mais valores iguais a 1 de forma a ter mais hipóteses de acertar.

Por fim, o *F1-score* oferece uma visão abrangente do desempenho do modelo na previsão de eventos. É importante notar que observamos uma diminuição desse valor, sobretudo em relação às variações “-1”, durante o período pós-guerra. Isso pode ser um indicativo da adaptação do modelo às mudanças no ambiente econômico ou de mercado que ocorreram após a guerra. Esta redução pode ser vista como um sinal de alerta e sugere que, embora o modelo seja sólido na sua capacidade de previsão num contexto amplo, podem ser necessários ajustes adicionais. Especificamente, a queda no desempenho na previsão de variações iguais a -1 após o período de guerra pode indicar a necessidade de refinamentos no modelo para se adaptar a mudanças no mercado ou nas condições econômicas que ocorreram nesse período.

A Total Energies Carbon oferece um exemplo marcante de como o modelo pode, em algumas situações, enfrentar desafios significativos na previsão de variações iguais a 1 em comparação com as variações “-1”, mais especificamente no período pós-guerra, onde as métricas de performance do modelo *Precision*, *Recall* e *F1-score* são iguais a 0. Isto sugere que o modelo tem dificuldades a prever variações “1” após a escalada do conflito, sugerindo que possa haver mais oscilações e inconsistência no comportamento da série temporal em estudo. Além disso, *Accuracy* apresenta valores abaixo dos 0,55 para ambos os períodos, sugerindo que o modelo não é preciso na identificação e previsão das variações dos preços das ações. No entanto, a medida *Recall*, tanto no período pré guerra como no período pós-guerra, apresenta valores altos para as variações iguais a -1, indicando a eficácia na minimização de falsos negativos.

Em contraste, a empresa do mercado de Paris, EO2 exibe um desempenho notoriamente deficiente em todos os aspetos. Durante ambos os períodos, a *Accuracy* permanece abaixo do limiar de 0,45, sugerindo um baixo desempenho nas previsões do modelo.

No que diz respeito à *Precision*, ela mostra um resultado misto. Durante o período pós-guerra, a *Precision* atinge um valor sólido de 1 na previsão de variações “1”, indicando uma capacidade eficaz de evitar falsos positivos. No entanto, essa performance contrasta drasticamente com o valor zero obtido no período pré-guerra, e os demais cenários apresentam valores muito baixos.

Em relação ao *Recall*, esta medida apresenta um desempenho mais encorajador ao demonstrar eficácia na minimização de falsos negativos, particularmente no período pós-guerra. Isso significa que o modelo é capaz de identificar com sucesso a maioria das instâncias de variações “-1”. No

entanto, essa capacidade eficaz de *Recall* não se estende uniformemente a outros cenários, revelando uma disparidade no desempenho do modelo em diferentes contextos.

Estas 3 empresas apresentam resultados muito diferentes indicando conclusões distintas. Na verdade, não existe um consenso nos resultados das 102 empresas utilizadas neste estudo. Assim, de forma a perceber o desempenho do modelo em geral, recorri ao cálculo das médias de cada medida de performance, como vou mencionar a seguir. Mais uma vez, os resultados completos encontram-se no Anexo C.

Neste caso de estudo, como se pode observar pela Figura 13 e Figura 14, a medida Accuracy apresenta um valor médio superior para o período pré-guerra (0,51353), isto é, quando o modelo apenas considera os dados até 24 de janeiro de 2022. Isto sugere que o modelo parece ter um desempenho melhor no período que não leva em consideração os dados até o início da guerra, possivelmente indicando que os comportamentos dos dados se tornaram mais voláteis e imprevisíveis no segundo período. Isto significa que o modelo tem uma capacidade relativamente melhor de fazer previsões precisas no período anterior ao conflito, sugerindo que os padrões de comportamento das ações se tornaram mais complexos e difíceis de antecipar no período subsequente à guerra. Isto pode indicar uma mudança significativa nos fatores que afetam os preços das ações durante e após o conflito, tornando o modelo menos eficaz na segunda fase do estudo.




Figura 13-Accuracy no período Pré-Guerra

Fonte: Elaboração própria




Figura 14-Accuracy no período Pós-Guerra

Fonte: Elaboração própria

Quanto à métrica de *Precision*, é interessante observar que o modelo demonstrou um desempenho relativamente superior na previsão de variações com valores iguais a 1, tanto no período pré-guerra quanto no pós-guerra, como se pode ver a partir da Figura 15 e da Figura 16. No entanto, mesmo com esse desempenho aparentemente melhor em identificar momentos de aumento nas ações, os valores médios de *Precision* para ambos os períodos permanecem abaixo de 0,54. Estes resultados sugerem que o modelo ainda não atinge uma eficácia ideal na previsão destas variações e na redução dos casos de falsos positivos.

Por outras palavras, embora o modelo seja mais competente na identificação de momentos em que os preços das ações estão a crescer, este ainda comete erros significativos ao classificar algumas destas situações como variações “1” quando, na verdade, não o são.

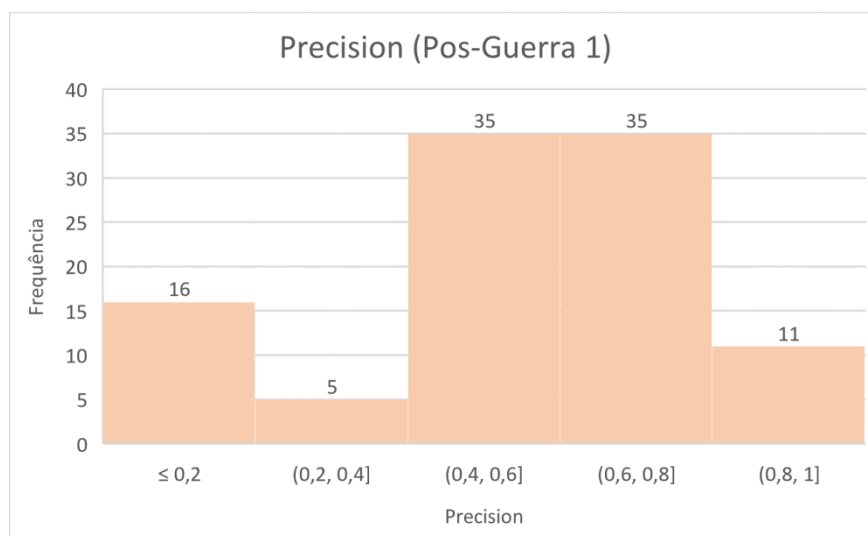


Figura 15-Precision no período Pós-Guerra (1)

Fonte: Elaboração própria

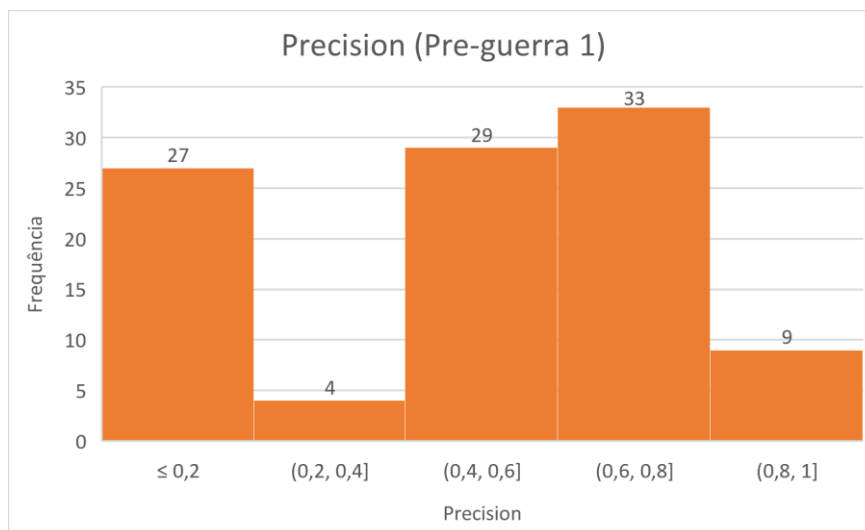


Figura 16-Precision no período Pré-Guerra (1)

Fonte: Elaboração própria

Quando analisamos a métrica de *Recall*, observamos através da Figura 17 que os valores também estão concentrados no intervalo de valores inferiores a 0,2 e no intervalo entre 0,8 e 1, destrancando *performances* contrárias em relação a esta métrica. A partir dos resultados da Figura 17 e da Figura 18 é possível observar que o modelo apresenta valores superiores de *Recall* na previsão de variações iguais a -1 no período pós-guerra (o mesmo acontece no período pré-guerra, como se pode ver no Anexo C. Isto é um indicativo de que o modelo enfrenta desafios na identificação de variações iguais a 1 e não demonstra eficácia em evitar falsos negativos.

Assim, segundo esta medida de *performance* o modelo não consegue com precisão reconhecer e prever quedas nos preços das ações durante o período após o início da guerra. Este baixo desempenho pode ser atribuído à complexidade dos fatores que afetam negativamente o mercado de ações neste período, tornando o modelo menos eficaz na identificação dessas variações. A falta de previsões corretas na identificação de eventos negativos pode ser preocupante para investidores que desejam evitar perdas financeiras.






Figura 17-Recall no período Pós-Guerra (-1)

Fonte: Elaboração própria




Figura 18-Recall no período Pós-Guerra (1)

Fonte: Elaboração própria

O *F1 Score* é uma métrica que leva em consideração tanto a *Precision* quanto o *Recall*. Portanto, segundo a Figura 19 e a Figura 20, quando observamos uma concentração maior nos valores abaixo de 0,5, isto sugere que o modelo não está a alcançar um equilíbrio satisfatório entre a capacidade de prever variações positivas e negativas. Ou seja, ele não é eficaz na previsão tanto das tendências de alta quanto das tendências de baixa no mercado de ações. Esse desempenho inferior do modelo pode levantar preocupações quanto à sua utilidade na tomada de decisões de investimento, uma vez que a previsão precisa das tendências do mercado é crucial para os investidores.




Figura 19- F1-score no período Pré-Guerra (1)

Fonte: Elaboração própria




Figura 20- F1-score no período Pós-Guerra (1)

Fonte: Elaboração própria

Com isto, os resultados apontam para a baixa *performance* do modelo GBDT que não alcançou o desempenho ideal na previsão das variações nos retornos dos preços das ações das empresas do setor de energia cotadas na Euronext.

Esses resultados indicam que, embora o GBDT seja uma técnica de aprendizagem computacional promissora e amplamente utilizada, este pode não ser a escolha mais adequada para o contexto específico deste estudo. A previsão das variações de preços de ações, particularmente num setor tão complexo e volátil como o de energia, requer modelos mais precisos e sofisticados e, possivelmente variáveis independentes adicionais ou alternativas às utilizadas. Todavia, esta análise destaca a importância de considerar abordagens alternativas e

aprimorar a precisão das previsões financeiras, para que investidores e outros interessados possam tomar decisões informadas e eficazes no mercado de ações.

## 5 Análise e Discussão dos Resultados

Realizamos uma análise preliminar através de gráficos lineares das variáveis da taxa de inflação média, taxa de câmbio, preços dos futuros de gás natural e de emissões de carbono e do petróleo Brent, uma vez que estudos anteriores (Adekoya et al., 2022; Chiang & Chen, 2023; Lawal & Ijirshar, 2013; Mensi et al., 2021; Veith et al., 2009), destacaram o efeito destas variáveis na volatilidade dos mercados financeiros. Portanto, qualquer alteração substancial no seu comportamento pode sugerir uma possível mudança na série temporal em estudo.

Partindo da análise dos gráficos lineares apresentados na secção anterior, aparenta existir algum efeito da guerra nas variáveis dos preços dos futuros das *commodities* de emissões de carbono e gás natural. Em relação aos preços do petróleo Brent, aparenta haver um aumento acentuado após a escalada do conflito, sendo que estes já se encontravam em crescimento. Já os valores da inflação e da taxa de câmbio parecem não alterar com o início do conflito entre a Ucrânia e a Rússia.

No que diz respeito à inflação média e à taxa de câmbio, os gráficos não revelaram qualquer impacto direto decorrente do conflito. Ambas as variáveis mantiveram uma tendência de crescimento, com uma ligeira diminuição apenas a partir de novembro de 2022. Isso sugere que esses fatores económicos não foram diretamente influenciados pelo início do conflito, contrariamente às evidências apresentadas nos seus estudos por Chiang & Chen (2023) e Kennedy & Nourzad (2016). No entanto, os preços dos futuros das emissões de carbono mostraram um padrão diferente. Até fevereiro de 2022, houve um crescimento constante, seguido de uma queda acentuada nos meses subsequentes. Essa mudança de comportamento nos preços parece estar relacionada ao conflito russo-ucraniano. Os preços dos futuros de gás natural também apresentaram variações notáveis. Após um período de crescimento até novembro de 2021, houve uma queda, seguida de um aumento acentuado em fevereiro/março de 2022 e uma nova queda em junho/julho do mesmo ano. Esse comportamento, à semelhança da série temporal das emissões de carbono, sugere que o conflito pode ter influenciado os preços dos futuros de gás natural. Em contrapartida, observamos que os preços dos futuros de petróleo Brent exibiram um comportamento interessante ao longo do período analisado. Até à data da invasão, notou-se um aumento gradual desses preços, indicando um crescimento constante. No entanto, após o início da invasão, observou-se uma tendência acentuada desse crescimento. Logo após esse período de elevação, houve uma queda significativa nos preços entre os meses de março e abril de 2022. Entretanto, é igualmente notável que, após essa queda, os preços recuperaram, retomando uma trajetória de crescimento. Este padrão no comportamento desta série temporal suscita questões sobre as influências e implicações da invasão e outros fatores económicos e geopolíticos na dinâmica dos mercados de energia.

Segundo a análise dos gráficos lineares apresentada na secção anterior, a inflação e a taxa de câmbio não aparentam apresentar mudanças após 24 de fevereiro de 2022, assim, o efeito destas

variáveis pode não ser sentido nos retornos dos preços e, assim, justificar os resultados deste estudo que sugerem a ausência de alterações no comportamento dos preços das ações após o início do conflito, ao contrário do que estudos como Cui et al. (2023) Fang & Shao (2022) Mbah & Wasum (2022), Z. Umar et al. (2022) e Xu et al. (2022) referem nas conclusões.

O *Chow test* foi aplicado para identificar um potencial ponto de quebra estrutural, a data da invasão da Rússia à Ucrânia, nos retornos dos preços de fecho das ações das empresas do setor energético na Euronext. Os resultados resultantes deste teste indicaram que apenas em duas das 102 empresas estudadas houve validação da data de 24 de fevereiro de 2022 como um ponto de quebra estrutural. Assim, este resultado indica que, na maioria dos casos, o início do conflito não teve um impacto significativo nos preços das ações.

Em relação às previsões calculadas pelo modelo de aprendizagem computacional, GBDT, não parecem divergir muito entre os dois períodos definidos. Ou seja, o comportamento dos preços não modificou significativamente a partir do momento da invasão russa ao território ucraniano, indicando assim, mais uma vez a ausência da influência deste acontecimento nos preços das ações das empresas do setor energético cotadas na Euronext.

A análise das previsões realizadas e da performance do modelo de aprendizagem computacional *Gradient Boosting Decision Tree*, demonstra a inexistência de uma divergência no cálculo destas entre os dois períodos determinados e identifica um baixo desempenho do modelo. Assim, os resultados sugerem que o comportamento dos dados não é alterado caso o modelo de decisão tenha em consideração o período pré ou pós-guerra. A avaliação da performance do modelo indica uma medida de *Precision* do modelo relativamente baixa para ambos os períodos analisados e para ambos os valores possíveis das variações (-1 e 1). Isto significa que o modelo teve dificuldade em evitar falsos positivos. A medida de *Recall* também apresentou valores baixos, indicando que o modelo não conseguiu identificar eficientemente as variações negativas. Além disso, o *F1-Score*, também indicou uma fraca performance do modelo, com valores abaixo de 0,5. Em contraste aos resultados e análises apresentadas nos estudos de Basak et al. (2019), Krauss et al. (2017) e Q. Zhang et al. (2022) o modelo adotado nesta dissertação não se mostrou robusto na previsão das variações dos retornos das ações, tendo apresentado um baixo desempenho.

Em resumo, embora a literatura indique fortes evidências de efeitos de eventos extremos, como a Segunda Guerra Mundial (Hudson & Urquhart, 2015) e a pandemia Covid-19 (Pandey & Kumari, 2021), nos mercados financeiros, este estudo, contrariamente, apresenta resultados que sugerem a ausência do impacto da guerra e do conjunto de variáveis nos preços das ações. Apesar de terem sido observadas algumas mudanças nos preços dos futuros das emissões de carbono e gás natural em relação ao início do conflito russo-ucraniano, a maioria das variáveis e empresas estudadas não parece ter sido fortemente afetada pelo evento. O modelo de aprendizagem computacional GBDT não se mostrou eficaz na previsão dessas variações, sugerindo que outros

fatores possam ter uma influência mais significativa nos preços das ações do setor energético na Euronext ou que este modelo não é o mais apropriado para este tipo de dados. Assim, os resultados deste estudo não vão de acordo com as conclusões dos autores (Adekoya et al., 2022; Cui et al., 2023; Xu et al., 2022). A partir da análise realizada, os resultados sugerem que existindo um impacto do conflito nas variáveis em estudo, mais especificamente, nos preços dos valores das ações do setor de energia, este não é significativo.

As condições que explicam esta falta de impacto significativo do conflito russo-ucraniano nos mercados financeiros do setor de energia europeu podem ser atribuídas a vários fatores relevantes. É particularmente notável que, embora tenham sido temidos períodos difíceis no inverno de 2022, devido à escalada do conflito, a Europa não apenas evitou uma crise energética, mas também conseguiu diminuir a dependência de importações energéticas (Eurostat, 2023d). Isto pode ser atribuído a motivos como às condições meteorológicas mais amenas (Iberdrola, 2023; McGee, 2023; Traqueia, 2023) e aos esforços coordenados dos países para promover o uso eficiente da energia (Conselho Europeu, 2023c, 2023a, 2023b).

A forte dependência da Europa em importações de recursos energéticos levou a que esta não alterasse drasticamente o seu comportamento de consumo de energia. Face às limitações e dificuldades no abastecimento de recursos energéticos consequentes do conflito russo-ucraniano, a Europa respondeu de uma forma rápida e competente a estes obstáculos, ao procurar alternativas às suas tradicionais fontes de energia. Esta estratégia de busca ativa de outras opções de fornecimento de recursos energéticos fundamentais para responder às necessidades dos países europeus, de forma a diversificar as suas relações nas importações de energia, contribuiu para reduzir o poder de negociação da Rússia em relação à forte dependência europeia no abastecimento de energia. Isto demonstra a forte capacidade de adaptação e resiliência por parte dos governos e cidadãos europeus.

De facto, os dados provenientes da "Eurostat database (Comext) and Eurostat estimates" (Eurostat, 2023d) revelam que, embora as importações de energia da União Europeia à Rússia tenham aumentado consideravelmente de 2021 para 2022, houve uma queda acentuada nos valores destas importações em 2023, como se pode observar na Tabela 6. Esta redução é resultado direto do conflito entre a Rússia e a Ucrânia e das medidas tomadas pelo território europeu. A diminuição das importações de recursos energéticos da Rússia demonstra a eficácia das estratégias europeias de diversificação e de resposta a dificuldades derivadas dos desafios geopolíticos enfrentados.

*Tabela 6-Importações da União Europeia de produtos energéticos da Rússia*

Importações de energia	2019	2020	2021	2022	2023
Petróleo e óleos de gás natural condensado	0,3	0,2	0,5	0,8	0,2
Óleos de petróleo e óleos obtidos de minerais betuminosos, brutos	58,1	31,9	47,6	54,1	3,7
Gás natural líquido	2,3	1,7	5,2	16,1	5
Gás natural em estado gasoso	24,2	15,2	37	50,4	8,4

Fonte: Elaboração própria

No geral, estes fatores combinados provavelmente contribuíram para mitigar o impacto negativo do conflito russo-ucraniano nos mercados financeiros do setor de energia europeus. Os resultados do estudo sugerem que a Europa conseguiu manter a estabilidade no setor energético, apesar das preocupações iniciais, e que a diversificação de fontes e a gestão eficaz dos recursos energéticos desempenharam um papel essencial neste processo.

## 6 Conclusão

Esta dissertação analisou o impacto do recente conflito entre a Rússia e a Ucrânia nos mercados financeiros, com um foco especial nas empresas do setor de energia cotadas na Euronext. Para tal, foram utilizados um conjunto vasto de métodos e técnicas de forma a fazer a recolha, tratamento e análise de dados da forma mais eficaz.

O estudo fornece resultados valiosos sobre a dinâmica dos mercados financeiros do setor energético em situações de tensão geopolítica, sendo relevante tanto para investidores diretos quanto para agentes políticos que dependem das previsões das implicações decorrentes de tensões políticas nestes mercados. O impacto destes eventos extremos não deve ser subestimado e a compreensão de como eles afetam os mercados é essencial para uma gestão eficaz e para uma possível necessidade de resposta rápida consequente às dificuldades resultantes destas situações.

A literatura recente indica que eventos extremos têm a capacidade de influenciar positiva ou negativamente os mercados financeiros, afetando o desempenho dos ativos, resultando em possíveis roturas estruturais nos movimentos de preços e na volatilidade dos retornos das ações. Tendo em conta estas considerações, é razoável antecipar que o recente conflito entre a Rússia e a Ucrânia tenha potencial de provocar impactos e gerar efeitos semelhantes nos mercados financeiros, tal como o 11 de setembro e outras guerras históricas, não apenas nos países diretamente envolvidos, mas também nos restantes mercados globais que mantêm relações comerciais com ambos.

Por este motivo, a análise detalhada deste conflito é crucial para compreender e antecipar potenciais impactos económicos e financeiros daí resultantes.

Tanto o país liderado por Vladimir Putin como o país liderado por Volodymyr Zelensky, têm papéis fundamentais no fornecimento de diversos recursos a nível mundial. A Rússia desempenha um papel vital no fornecimento global de recursos energéticos, principalmente para a União Europeia, tornando essa relação suscetível e sensível a mudanças devido à guerra entre a Rússia e a Ucrânia. Na verdade, a União Europeia é um dos principais consumidores globais de energia e enfrenta desafios significativos devido à sua crescente dependência de importações de energia. Eventos que afetam essas relações representam um risco substancial para os países europeus, podendo afetar as suas economias e, mais especificamente, os mercados financeiros do setor de energia.

Desta forma, tendo em consideração a importância do reconhecimento de possíveis repercussões da invasão russa na Ucrânia, este estudo selecionou 102 empresas do setor energético cotadas na Euronext para examinar se existem, de facto, consequências deste evento nos mercados financeiros europeus, com ênfase na análise do setor de energia.

Neste contexto, o estudo enquadrou a história da Euronext e no que esta consiste, o funcionamento do setor energético na Europa, a explicação do conflito russo-ucraniano e contextos históricos semelhantes e potenciais impactos e fatores decorrentes de eventos extremos.



Este trabalho envolveu uma recolha, exploração e tratamento de dados e uma análise preliminar por meio de gráficos lineares para identificar quaisquer tendências ou mudanças notáveis nas variáveis utilizadas. Em seguida, aplicamos o *Chow test* para verificar a existência de possíveis mudanças estruturais nos dados. Conforme a literatura sugere, identificamos a data de 24 de fevereiro de 2022 como o ponto de possível rotura estrutural, que corresponde ao início do conflito entre a Ucrânia e a Rússia. Posteriormente, utilizamos o modelo *Gradient Boosting Decision Tree* (GBDT), uma técnica de aprendizagem computacional robusta, para prever as variações nos retornos dos preços das ações das 102 empresas que selecionamos para este estudo. Por fim, procedemos à avaliação do desempenho do modelo de aprendizagem computacional. Esta fase envolveu o uso de matrizes de confusão e de métricas, como *Accuracy*, *Precision*, *Recall* e *F1-Score*, que são fundamentais para compreender o desempenho do modelo de classificação.

Ao contrário do esperado, os resultados sugerem que o início do conflito não teve um impacto significativo nos mercados financeiros das empresas de energia. Segundo os gráficos lineares, os preços dos futuros de petróleo de Brent, de emissões de carbono e gás natural parecem ter sido afetados, enquanto as variáveis relacionadas com a inflação média e a taxa de câmbio não apresentam qualquer mudança no seu comportamento consoante a escalada do conflito. Os resultados do *Chow Test* revelam que apenas 2 das 102 empresas do setor energético mostraram uma mudança significativa nos preços das ações, isto significa que o teste indica que o início do conflito não causou um efeito significativo no comportamento da maioria das variáveis e empresas deste estudo. O modelo de aprendizagem computacional GBDT não demonstrou uma divergência notável entre os dois períodos definidos, sugerindo que o início do conflito não afetou substancialmente os preços das ações das empresas do setor energético cotadas na Euronext. Além disso, a avaliação da performance do modelo indicou um desempenho abaixo do ideal, sendo que todas as médias das métricas de performance utilizadas se encontram abaixo de 0,56. Em geral, os resultados deste estudo indicam que o impacto do conflito russo-ucraniano nos mercados financeiros do setor de energia europeu não foi significativo.

Estas conclusões podem ser explicadas por vários fatores. A capacidade de adaptação e resiliência da Europa e a sua rápida resposta face ao desencadear do conflito podem ter desempenhado um papel crucial, permitindo-lhe diversificar as suas fontes de energia e reduzir a sua dependência da Rússia, tirando-lhe o poder de negociação. As ações e tomadas de decisões estratégicas dos países europeus parecem ter atenuado o impacto negativo do conflito no setor energético europeu.

## 7 Limitações e Passos Futuros

Este estudo identificou várias limitações e áreas que requerem investigações adicionais. As variáveis adicionais que foram incorporadas na dissertação foram selecionadas com base na revisão da literatura mais recente. No entanto, é importante destacar que a adição de outras variáveis ou a exploração de alternativas pode potencialmente aprimorar o desempenho do modelo de aprendizagem computacional que foi utilizado. A escolha das variáveis desempenha um papel fundamental na qualidade das previsões e, portanto, merece uma análise detalhada.

Um ponto crítico a ser considerado é o desempenho relativamente baixo do modelo de aprendizagem computacional utilizado para prever as variações nos retornos dos preços de fecho das ações de 102 empresas do setor energético cotadas na Euronext. Modelos de previsão de classificação, como esse, são altamente sensíveis a flutuações extremas nos dados das séries temporais, o que pode resultar em previsões imprecisas. Portanto, é essencial avaliar a possibilidade de adotar outro modelo de previsão que seja mais robusto e adequado às características específicas dos dados analisados.

A falta de acesso a dados intradiários destes mercados financeiros representou uma limitação para o desenvolvimento deste estudo. A utilização de dados de alta frequência, que capturam informações em intervalos de tempo mais curtos, pode tornar a análise mais realista e eficaz. Dessa forma, o estudo poderia beneficiar de uma compreensão mais profunda das dinâmicas do mercado, adicionando valor às conclusões alcançadas.

Por último, o *Chow Test*, que foi usado para identificar potenciais pontos de quebra estrutural nos preços das ações, também apresenta uma limitação significativa. Este teste exige que o autor tenha um conhecimento prévio detalhado sobre a situação em estudo. Isto significa que existem duas opções na escolha do ponto de quebra estrutural: selecionar uma data de quebra candidata de forma arbitrária ou escolher uma data de quebra com base em alguma característica conhecida dos dados. No primeiro caso, o teste pode não ser informativo, pois há a possibilidade de não identificar corretamente a data real da quebra. No segundo caso, o teste pode fornecer resultados enganosos, já que a data de quebra está correlacionada e é influenciada pelos próprios dados. Além disso, como os resultados do teste podem variar consideravelmente com base nestas escolhas arbitrárias, diferentes estudos podem chegar a conclusões divergentes. Portanto, a interpretação dos resultados do *Chow Test* e a escolha do ponto de quebra estrutural devem ser feitas com cautela, dada a sua sensibilidade a estes fatores.

## Referências

- Adekoya, O. B., Asl, M. G., Oliyide, J. A., & Izadi, P. (2023). Multifractality and cross-correlation between the crude oil and the European and non-European stock markets during the Russia-Ukraine war. *Resources Policy*, 80, 103134. <https://doi.org/https://doi.org/10.1016/j.resourpol.2022.103134>
- 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. *Resources Policy*, 77, 102728. <https://doi.org/https://doi.org/10.1016/j.resourpol.2022.102728>
- Adjasi, C., Harvey, S. K., & Agyapong, D. A. (2008). Effect of exchange rate volatility on the Ghana stock exchange. *African Journal of Accounting, Economics, Finance and Banking Research*, 3(3). <https://ssrn.com/abstract=1534178>
- Ahmad, M., Rehman, R., & Raoof, A. (2010). Do interest rate, exchange rate effect stock returns? a pakistani perspective. *International Research Journal of Finance and Economics*, 50, 146–150. <https://www.researchgate.net/publication/288467112>
- Ahmed, S., Hasan, M. M., & Kamal, M. R. (2023). Russia–Ukraine crisis: The effects on the European stock market. *European Financial Management*, 29(4), 1078–1118. <https://doi.org/https://doi.org/10.1111/eufm.12386>
- Ashraf, B. N., & Goodell, J. W. (2022). COVID-19 social distancing measures and economic growth: Distinguishing short- and long-term effects. *Finance Research Letters*, 47, 102639. <https://doi.org/https://doi.org/10.1016/j.frl.2021.102639>
- Assaf, R., Gupta, D., & Kumar, R. (2023). The price of war: Effect of the Russia-Ukraine war on the global financial market. *The Journal of Economic Asymmetries*, 28, e00328. <https://doi.org/https://doi.org/10.1016/j.jeca.2023.e00328>
- Baker, S. R., Bloom, N., Davis, S. J., & Kost, K. J. (2019). *Policy News and Stock Market Volatility* (Working Paper Series, Issue 25720). <https://doi.org/10.3386/w25720>
- Basak, S., Kar, S., Saha, S., Khaidem, L., & Dey, S. R. (2019). Predicting the direction of stock market prices using tree-based classifiers. *The North American Journal of Economics and Finance*, 47, 552–567. <https://doi.org/https://doi.org/10.1016/j.najef.2018.06.013>
- Benos, E., & Johec, M. (2013). Patriotic name bias and stock returns. *Journal of Financial Markets*, 16(3), 550–570. <https://doi.org/https://doi.org/10.1016/j.finmar.2012.10.002>
- Berkman, H., Jacobsen, B., & Lee, J. B. (2011). Time-varying rare disaster risk and stock returns. *Journal of Financial Economics*, 101(2), 313–332. <https://doi.org/https://doi.org/10.1016/j.jfineco.2011.02.019>
- Berument, H., Coskun, M. N., & Sahin, A. (2007). Day of the week effect on foreign exchange market volatility: Evidence from Turkey. *Research in International Business and Finance*, 21(1), 87–97. <https://doi.org/https://doi.org/10.1016/j.ribaf.2006.03.003>
- Bigerna, S., Ceccacci, F., Micheli, S., & Polinori, P. (2023). Between saying and doing for ensuring energy resources supply: The case of Italy in time of crisis. *Resources Policy*, 85, 103782. <https://doi.org/https://doi.org/10.1016/j.resourpol.2023.103782>
- Boldini, D., Grisoni, F., Kuhn, D., Friedrich, L., & Sieber, S. A. (2023). Practical guidelines for the use of gradient boosting for molecular property prediction. *Journal of Cheminformatics*, 15(1), 73. <https://doi.org/https://doi.org/10.1186/s13321-023-00743-7>
- Bollen, B. (2023). *A history of Euronext, the leading pan-European euro exchange*. <https://capital.com/a-history-of-euronext-the-leading-pan-european-euro-exchange>
- Bossmann, A., Owusu Junior, P., & Tiwari, A. K. (2022). Dynamic connectedness and spillovers between Islamic and conventional stock markets: time- and frequency-domain approach in COVID-19 era. *Heliyon*, 8(4), e09215. <https://doi.org/https://doi.org/10.1016/j.heliyon.2022.e09215>
- Boudreaux, D. O., Rao, S., Underwood, J., Rumore, N., & others. (2011). A new and better way to measure the cost of equity capital for small closely held firms. *Journal of Business & Economics Research (JBER)*, 9(1). <https://doi.org/https://doi.org/10.19030/jber.v9i1.945>
- Brounen, D., & Derwall, J. (2010). The Impact of Terrorist Attacks on International Stock Markets. *European Financial Management*, 16(4), 585–598. <https://doi.org/https://doi.org/10.1111/j.1468-036X.2009.00502.x>
- Brune, A., Hens, T., Rieger, M. O., & Wang, M. (2015). The war puzzle: Contradictory effects of international conflicts on stock markets. *International Review of Economics*, 62(1), 1–21. <https://doi.org/https://doi.org/10.1007/s12232-014-0215-7>
- Caporale, G. M., & Zakirova, V. (2017). Calendar anomalies in the Russian stock market. *Russian Journal of Economics*, 3(1), 101–108. <https://doi.org/10.1016/j.ruje.2017.02.007>

- Chesney, M., Reshetar, G., & Karaman, M. (2011). The impact of terrorism on financial markets: An empirical study. *Journal of Banking & Finance*, 35(2), 253–267.  
<https://doi.org/https://doi.org/10.1016/j.jbankfin.2010.07.026>
- Chiang, T. C., & Chen, P.-Y. (2023). Inflation risk and stock returns: Evidence from US aggregate and sectoral markets. *The North American Journal of Economics and Finance*, 68, 101986.  
<https://doi.org/https://doi.org/10.1016/j.najef.2023.101986>
- Choudhry, T. (2010). World War II events and the Dow Jones industrial index. *Journal of Banking & Finance*, 34, 1022–1031. <https://doi.org/10.1016/j.jbankfin.2009.11.004>
- Chow, G. C. (1960). Tests of Equality Between Sets of Coefficients in Two Linear Regressions. *Econometrica*, 28(3), 591–605. <http://www.jstor.org/stable/1910133>
- Conselho Europeu, C. da U. E. (2023a). *Ação da UE para fazer face à crise energética*. [https://commission.europa.eu/strategy-and-policy/priorities-2019-2024/european-green-deal/eu-action-address-energy-crisis\\_pt](https://commission.europa.eu/strategy-and-policy/priorities-2019-2024/european-green-deal/eu-action-address-energy-crisis_pt)
- Conselho Europeu, C. da U. E. (2023b). *Como está a UE a reagir ao impacto que a invasão da Ucrânia pela Rússia está a ter nos mercados?* <https://www.consilium.europa.eu/pt/policies/eu-response-ukraine-invasion/impact-of-russia-s-invasion-of-ukraine-on-the-markets-eu-response/>
- Conselho Europeu, C. da U. E. (2023c). *Infografia – Crise energética: Três medidas coordenadas a nível da UE para reduzir os valores das faturas*. <https://www.consilium.europa.eu/pt/infographics/eu-measures-to-cut-down-energy-bills/>
- Cui, L., Yue, S., Nghiem, X.-H., & Duan, M. (2023). Exploring the risk and economic vulnerability of global energy supply chain interruption in the context of Russo-Ukrainian war. *Resources Policy*, 81, 103373.  
<https://doi.org/https://doi.org/10.1016/j.resourpol.2023.103373>
- Dimic, N., Orlov, V., & Piljak, V. (2015). The political risk factor in emerging, frontier, and developed stock markets. *Finance Research Letters*, 15, 239–245. <https://doi.org/https://doi.org/10.1016/j.frl.2015.10.007>
- Euronext. (2023). *Euronext About Us*. <https://www.euronext.com/en/about>
- Eurostat. (2023a). *Data Browser: Energy imports dependency*. [https://ec.europa.eu/eurostat/databrowser/view/nrg\\_ind\\_id/default/table?lang=en](https://ec.europa.eu/eurostat/databrowser/view/nrg_ind_id/default/table?lang=en)
- Eurostat. (2023b). *Energy statistics - an overview*. [https://ec.europa.eu/eurostat/statistics-explained/index.php?title=Energy\\_statistics\\_-\\_an\\_overview](https://ec.europa.eu/eurostat/statistics-explained/index.php?title=Energy_statistics_-_an_overview)
- Eurostat. (2023c). *EU energy mix and import dependency*. [https://ec.europa.eu/eurostat/statistics-explained/index.php?title=Archive:EU\\_energy\\_mix\\_and\\_import\\_dependency#Energy\\_mix\\_and\\_import\\_dependency](https://ec.europa.eu/eurostat/statistics-explained/index.php?title=Archive:EU_energy_mix_and_import_dependency#Energy_mix_and_import_dependency)
- Eurostat. (2023d). *EU imports of energy products continued to drop in Q2 2023*. <https://ec.europa.eu/eurostat/en/web/products-eurostat-news/w/ddn-20230925-1>
- Fang, Y., & Shao, Z. (2022). The Russia-Ukraine conflict and volatility risk of commodity markets. *Finance Research Letters*, 50, 103264. <https://doi.org/https://doi.org/10.1016/j.frl.2022.103264>
- Gayaker, S., Yalcin, Y., & Berument, M. H. (2020). The day of the week effect and interest rates. *Borsa Istanbul Review*, 20(1), 55–63. <https://doi.org/https://doi.org/10.1016/j.bir.2019.07.010>
- Geng, J.-B., Chen, F.-R., Ji, Q., & Liu, B.-Y. (2021). Network connectedness between natural gas markets, uncertainty and stock markets. *Energy Economics*, 95, 105001.  
<https://doi.org/https://doi.org/10.1016/j.eneco.2020.105001>
- Goodell, J. W., Gurdgiev, C., Paltrinieri, A., & Piserà, S. (2023). Global energy supply risk: Evidence from the reactions of European natural gas futures to Nord Stream announcements. *Energy Economics*, 125, 106838. <https://doi.org/https://doi.org/10.1016/j.eneco.2023.106838>
- Guidolin, M., & La Ferrara, E. (2010). The economic effects of violent conflict: Evidence from asset market reactions. *Journal of Peace Research*, 47(6), 671–684.  
<https://doi.org/https://doi.org/10.1177/0022343310381853>
- Hansen, L., & Sargent, T. J. (2001). Robust Control and Model Uncertainty. *American Economic Review*, 91(2), 60–66. <https://doi.org/10.1257/aer.91.2.60>
- Hassan, M. K., Boubaker, S., Kumari, V., & Pandey, D. K. (2022). Border disputes and heterogeneous sectoral returns: An event study approach. *Finance Research Letters*, 50, 103277.  
<https://doi.org/https://doi.org/10.1016/j.frl.2022.103277>
- Ho, K.-C., Huang, H.-Y., Pan, Z., & Gu, Y. (2023). Modern pandemic crises and default risk: Worldwide evidence. *Journal of International Financial Management & Accounting*, 34(2), 211–242.  
<https://doi.org/https://doi.org/10.1111/jifm.12172>
- Hudson, R., & Urquhart, A. (2015). War and stock markets: The effect of World War Two on the British stock market. *International Review of Financial Analysis*, 40, 166–177.  
<https://doi.org/https://doi.org/10.1016/j.irfa.2015.05.015>

- Iberdrola. (2023). *O clima ameno salvou a Europa neste inverno. Isto é o que precisamos fazer para evitar futuras crises energéticas*. <https://www.iberdrola.com/sala-comunicacao/noticia/detalhe/o-clima-ameno-salvou-europa-neste-inverno-isto-precisamos-fazer-para-evitar-futuras-criSES-energeticas>
- Jebabli, I., Kouaissah, N., & Arouri, M. (2022). Volatility Spillovers between Stock and Energy Markets during Crises: A Comparative Assessment between the 2008 Global Financial Crisis and the Covid-19 Pandemic Crisis. *Finance Research Letters*, 46, 102363. <https://doi.org/https://doi.org/10.1016/j.frl.2021.102363>
- Johnston, R. B., & Nedelescu, O. M. (2006). The impact of terrorism on financial markets. *Journal of Financial Crime*, 13(1), 7–25. <https://www.emerald.com/insight/content/doi/10.1108/13590790610641233/full/html>
- Kapar, B., & Buigut, S. (2020). Effect of Qatar diplomatic and economic isolation on Qatar stock market volatility: an event study approach. *Applied Economics*, 52(55), 6022–6030. <https://doi.org/10.1080/00036846.2020.1781776>
- Kennedy, K., & Nourzad, F. (2016). Exchange rate volatility and its effect on stock market volatility. *International Journal of Human Capital in Urban Management*. <https://doi.org/https://doi.org/10.7508/ijhcum.2016.01.005>
- Khan, K., Khurshid, A., & Cifuentes-Faura, J. (2023). Investigating the relationship between geopolitical risks and economic security: Empirical evidence from central and Eastern European countries. *Resources Policy*, 85, 103872. <https://doi.org/https://doi.org/10.1016/j.resourpol.2023.103872>
- Kinader, H., Campbell, R., & Choudhury, T. (2021). Safe haven in GFC versus COVID-19: 100 turbulent days in the financial markets. *Finance Research Letters*, 43, 101951. <https://doi.org/https://doi.org/10.1016/j.frl.2021.101951>
- Kollias C. Papadamou S., S. A. (2010). Armed conflicts and capital markets: The case of the Israeli military offensive in the Gaza Strip. *Defence and Peace Economics*, 357–365. <https://doi.org/10.1080/10242694.2010.491712>
- Kong, H., Yun, W., & Kim, W. C. (2023). Tracking customer risk aversion. *Finance Research Letters*, 54, 103698. <https://doi.org/https://doi.org/10.1016/j.frl.2023.103698>
- Korkmaz, Ö. (2022). Do oil, coal, and natural gas consumption and rents impact economic growth? An empirical analysis of the Russian Federation. *Resources Policy*, 77, 102739. <https://doi.org/https://doi.org/10.1016/j.resourpol.2022.102739>
- Krauss, C., Do, X. A., & Huck, N. (2017). Deep neural networks, gradient-boosted trees, random forests: Statistical arbitrage on the S&P 500. *European Journal of Operational Research*, 259(2), 689–702. <https://doi.org/https://doi.org/10.1016/j.ejor.2016.10.031>
- Kumar, S., Jain, R., Narain, Balli, F., & Billah, M. (2023). Interconnectivity and investment strategies among commodity prices, cryptocurrencies, and G-20 capital markets: A comparative analysis during COVID-19 and Russian-Ukraine war. *International Review of Economics & Finance*, 88, 547–593. <https://doi.org/https://doi.org/10.1016/j.iref.2023.06.039>
- Lawal, M., & Ijirshar, V. U. (2013). Empirical analysis of exchange rate volatility and Nigeria stock market performance. *International Journal of Scientific and Research*, 4(4), 1592–1600. [https://www.researchgate.net/profile/Victor-Ijirshar-2/publication/331843301\\_Empirical\\_Analysis\\_of\\_Exchange\\_Rate\\_Volatility\\_and\\_Nigeria\\_Stock\\_Market\\_Performance/links/5c8fee1e45851564fae6c00d/Empirical-Analysis-of-Exchange-Rate-Volatility-and-Nigeria-Stock-Market-Performance.pdf](https://www.researchgate.net/profile/Victor-Ijirshar-2/publication/331843301_Empirical_Analysis_of_Exchange_Rate_Volatility_and_Nigeria_Stock_Market_Performance/links/5c8fee1e45851564fae6c00d/Empirical-Analysis-of-Exchange-Rate-Volatility-and-Nigeria-Stock-Market-Performance.pdf)
- Lee, Y., Shin, D., Kim, J.-H., Hong, S., Choi, D., Kim, Y.-J., Kwak, M.-K., & Jung, Y. (2010). Caffeic acid phenethyl ester-mediated Nrf2 activation and IκB kinase inhibition are involved in NFκB inhibitory effect: Structural analysis for NFκB inhibition. *European Journal of Pharmacology*, 643(1), 21–28. <https://doi.org/https://doi.org/10.1016/j.ejphar.2010.06.016>
- Lehkonen, H., & Heimonen, K. (2015). Democracy, political risks and stock market performance. *Journal of International Money and Finance*, 59, 77–99. <https://doi.org/https://doi.org/10.1016/j.jimonfin.2015.06.002>
- Liu, Z., Dai, P.-F., Huynh, T. L. D., Zhang, T., & Zhang, G. (2023). Industries' heterogeneous reactions during the COVID-19 outbreak: Evidence from Chinese stock markets. *Journal of International Financial Management & Accounting*, 34(2), 243–278. <https://doi.org/https://doi.org/10.1111/jifm.12166>
- Mbah, R. E., & Wasum, D. (2022). Russian-Ukraine 2022 War: A Review of the Economic Impact of Russian-Ukraine Crisis on the USA, UK, Canada, and Europe. *Advances in Social Sciences Research Journal*, 9(3), 144–153. <https://doi.org/10.14738/assrj.93.12005>
- McGee, L. (2023). *Desta vez, o General Inverno não está a ajudar a Rússia – e essa “pura sorte” dá-nos mais um ano*. <https://cnnportugal.iol.pt/ucrania/guerra/desta-vez-o-general-inverno-nao-esta-a-ajudar-a-russia-e-essa-pura-sorte-da-nos-mais-um-ano/20230116/63c5286f0cf2cf9224f47b0b>

- Mensi, W., Rehman, M. U., Maitra, D., Al-Yahyaee, K. H., & Vo, X. V. (2021). Oil, natural gas and BRICS stock markets: Evidence of systemic risks and co-movements in the time-frequency domain. *Resources Policy*, 72, 102062. <https://doi.org/https://doi.org/10.1016/j.resourpol.2021.102062>
- 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, 101829. <https://doi.org/https://doi.org/10.1016/j.resourpol.2020.101829>
- Nikkinen, J., Omran, M. M., Sahlström, P., & Äijö, J. (2008). Stock returns and volatility following the September 11 attacks: Evidence from 53 equity markets. *International Review of Financial Analysis*, 17(1), 27–46. <https://doi.org/https://doi.org/10.1016/j.irfa.2006.12.002>
- Oberndorfer, U. (2009). EU Emission Allowances and the stock market: Evidence from the electricity industry. *Ecological Economics*, 68(4), 1116–1126. <https://doi.org/https://doi.org/10.1016/j.ecolecon.2008.07.026>
- Pan Tang, X. T., & Yu, W. (2023). Intraday trend prediction of stock indices with machine learning approaches. *The Engineering Economist*, 68(2), 60–81. <https://doi.org/https://doi.org/10.1080/0013791X.2023.2205841>
- Pancera, A. de Q. A. A., & Alves, A. F. (2020). Testando a hipótese do mercado central: uma análise dos preços do boi gordo na presença de quebras estruturais. *Revista de Economia e Sociologia Rural*, 58. <https://doi.org/10.1590/1806-9479.2020.206751>
- Pandey, D. K., & Kumari, V. (2021). Event study on the reaction of the developed and emerging stock markets to the 2019-nCoV outbreak. *International Review of Economics & Finance*, 71, 467–483. <https://doi.org/https://doi.org/10.1016/j.iref.2020.09.014>
- Qadan, M., & Nama, H. (2018). Investor sentiment and the price of oil. *Energy Economics*, 69, 42–58. <https://doi.org/https://doi.org/10.1016/j.eneco.2017.10.035>
- Rao, P., Goyal, N., Kumar, S., Hassan, M. K., & Shahimi, S. (2021). Vulnerability of financial markets in India: The contagious effect of COVID-19. *Research in International Business and Finance*, 58, 101462. <https://doi.org/https://doi.org/10.1016/j.ribaf.2021.101462>
- Rizvi, S. K. A., Naqvi, B., Boubaker, S., & Mirza, N. (2022). The power play of natural gas and crude oil in the move towards the financialization of the energy market. *Energy Economics*, 112, 106131. <https://doi.org/https://doi.org/10.1016/j.eneco.2022.106131>
- Sarkhanov, T., & Muradzada, I. (2023). The Place of Gulf Basin Energy Resources in EU Energy Security. *International Journal of Energy Economics and Policy*, 13(4), 68–75. <https://doi.org/10.32479/ijee.14327>
- Schwert, G. W. (2003). Chapter 15 Anomalies and market efficiency. In *Financial Markets and Asset Pricing* (Vol. 1, pp. 939–974). Elsevier. [https://doi.org/https://doi.org/10.1016/S1574-0102\(03\)01024-0](https://doi.org/https://doi.org/10.1016/S1574-0102(03)01024-0)
- Shahzad, S. J. H., Bouri, E., Raza, N., & Roubaud, D. (2019). Asymmetric impacts of disaggregated oil price shocks on uncertainties and investor sentiment. *Review of Quantitative Finance and Accounting*, 52, 901–921. <https://doi.org/https://doi.org/10.1007/s11156-018-0730-9>
- Sharma, G. D., Shahbaz, M., Singh, S., Chopra, R., & Cifuentes-Faura, J. (2023). Investigating the nexus between green economy, sustainability, bitcoin and oil prices: Contextual evidence from the United States. *Resources Policy*, 80, 103168. <https://doi.org/https://doi.org/10.1016/j.resourpol.2022.103168>
- Si Mohammed, K., Khalfaoui, R., Doğan, B., Sharma, G. D., & Mentel, U. (2023). The reaction of the metal and gold resource planning in the post-COVID-19 era and Russia-Ukrainian conflict: Role of fossil fuel markets for portfolio hedging strategies. *Resources Policy*, 83, 103654. <https://doi.org/https://doi.org/10.1016/j.resourpol.2023.103654>
- Tong, E. (2024). Repercussions of the Russia–Ukraine war. *International Review of Economics & Finance*, 89, 366–390. <https://doi.org/https://doi.org/10.1016/j.iref.2023.07.064>
- Traqueia, F. (2023). *Inverno quente na Europa: o que está a fazer os termómetros dispararem?* <https://sicnoticias.pt/meteorologia/2023-01-07-Inverno-quente-na-Europa-o-que-esta-a-fazer-os-termometros-dispararem-20d3e509>
- Umar, M., Riaz, Y., & Yousaf, I. (2022). Impact of Russian-Ukraine war on clean energy, conventional energy, and metal markets: Evidence from event study approach. *Resources Policy*, 79, 102966. <https://doi.org/https://doi.org/10.1016/j.resourpol.2022.102966>
- Umar, Z., Polat, O., Choi, S.-Y., & Teplova, T. (2022). The impact of the Russia-Ukraine conflict on the connectedness of financial markets. *Finance Research Letters*, 48, 102976. <https://doi.org/https://doi.org/10.1016/j.frl.2022.102976>
- Vasileiou E. Samitas, A. (2015). Does the financial crisis influence the month and the trading month effects?: Evidence from the Athens Stock Exchange. *Studies in Economics and Finance Volume*, 32, 181–203. <https://doi.org/10.1108/SEF-01-2014-0002>
- Veith, S., Werner, J. R., & Zimmermann, J. (2009). Capital market response to emission rights returns: Evidence from the European power sector. *Energy Economics*, 31(4), 605–613. <https://doi.org/https://doi.org/10.1016/j.eneco.2009.01.004>

- Wu, F., Zhan, X., Zhou, J., & Wang, M. (2023). Stock market volatility and Russia–Ukraine conflict. *Finance Research Letters*, 55, 103919. <https://doi.org/https://doi.org/10.1016/j.frl.2023.103919>
- Xu, L., Wu, C., Qin, Q., & Lin, X. (2022). Spillover effects and nonlinear correlations between carbon emissions and stock markets: An empirical analysis of China’s carbon-intensive industries. *Energy Economics*, 111, 106071. <https://doi.org/https://doi.org/10.1016/j.eneco.2022.106071>
- Yang, Y., Hu, X., & Jiang, H. (2022). Group penalized logistic regressions predict up and down trends for stock prices. *The North American Journal of Economics and Finance*, 59, 101564. <https://doi.org/https://doi.org/10.1016/j.najef.2021.101564>
- Zaiane, S., & others. (2018). The impact of political instability driven by the Tunisian revolution on stock market volatility: Evidence from sectorial indices. *Journal of Applied Business Research (JABR)*, 34(2), 339–354. <https://doi.org/https://doi.org/10.19030/jabr.v34i2.10135>
- Zhang, Q., Zhang, P., & Zhou, F. (2022). Intraday and interday features in the high-frequency data: Pre- and post-Crisis evidence in China’s stock market. *Expert Systems with Applications*, 209, 118321. <https://doi.org/https://doi.org/10.1016/j.eswa.2022.118321>
- Zhang, Z., Wang, Y., & Li, B. (2023). Asymmetric spillover of geopolitical risk and oil price volatility: A global perspective. *Resources Policy*, 83, 103701. <https://doi.org/https://doi.org/10.1016/j.resourpol.2023.103701>

## Anexo A Resultado Chow Test

```

Período: Total
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      292.0  0.019523      0.0      NaN      NaN      NaN
1      237.0  0.029105      55.0 -0.009582 -1.418606      1.0
Período: 1 semana
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      299.0  0.023152      0.0      NaN      NaN      NaN
1      244.0  0.030210      55.0 -0.007058 -1.036483      1.0
Período: 2 semanas
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      306.0  0.027815      0.0      NaN      NaN      NaN
1      251.0  0.030869      55.0 -0.003054 -0.45152      1.0
Período: 3 semanas
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      313.0  0.028098      0.0      NaN      NaN      NaN
1      258.0  0.031270      55.0 -0.003172 -0.475828      1.0
Período: 1 mês
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      320.0  0.028738      0.0      NaN      NaN      NaN
1      265.0  0.032679      55.0 -0.003941 -0.581106      1.0
Período: 2 meses
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      348.0  0.031666      0.0      NaN      NaN      NaN
1      293.0  0.033755      55.0 -0.002089 -0.329724      1.0
Período: 4 meses
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      404.0  0.038860      0.0      NaN      NaN      NaN
1      349.0  0.037396      55.0  0.001464  0.24839      1.0

```

Figura A. 1-Resultados Chow Test Eli

Fonte: Elaboração própria

```

Período: Total
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      291.0  0.015899      0.0      NaN      NaN      NaN
1      235.0  0.026919      56.0 -0.011019 -1.717817      1.0
Período: 1 semana
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      298.0  0.019048      0.0      NaN      NaN      NaN
1      242.0  0.027746      56.0 -0.008697 -1.354632      1.0
Período: 2 semanas
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      305.0  0.024272      0.0      NaN      NaN      NaN
1      249.0  0.028799      56.0 -0.004527 -0.698914      1.0
Período: 3 semanas
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      312.0  0.024968      0.0      NaN      NaN      NaN
1      256.0  0.029534      56.0 -0.004566 -0.706816      1.0
Período: 1 mês
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      319.0  0.025577      0.0      NaN      NaN      NaN
1      263.0  0.030736      56.0 -0.005159 -0.788323      1.0
Período: 2 meses
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      347.0  0.027648      0.0      NaN      NaN      NaN
1      291.0  0.031415      56.0 -0.003767 -0.623128      1.0
Período: 4 meses
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      402.0  0.032229      0.0      NaN      NaN      NaN
1      348.0  0.034130      54.0 -0.001902 -0.359119      1.0

```

Figura A. 2-Resultados Chow Test Eni.mi

Fonte: Elaboração própria



```

Período: Total
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      292.0  0.020880      0.0      NaN      NaN      NaN
1      237.0  0.032062     55.0 -0.011182 -1.502808      1.0
Período: 1 semana
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      299.0  0.024928      0.0      NaN      NaN      NaN
1      244.0  0.032949     55.0 -0.008022 -1.080045      1.0
Período: 2 semanas
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      306.0  0.029643      0.0      NaN      NaN      NaN
1      251.0  0.033847     55.0 -0.004204 -0.56683      1.0
Período: 3 semanas
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      313.0  0.029977      0.0      NaN      NaN      NaN
1      258.0  0.034652     55.0 -0.004675 -0.632873      1.0
Período: 1 mês
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      320.0  0.030474      0.0      NaN      NaN      NaN
1      265.0  0.036618     55.0 -0.006144 -0.808457      1.0
Período: 2 meses
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      348.0  0.034164      0.0      NaN      NaN      NaN
1      293.0  0.037629     55.0 -0.003465 -0.490593      1.0
Período: 4 meses
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      404.0  0.040589      0.0      NaN      NaN      NaN
1      349.0  0.041079     55.0 -0.00049 -0.075713      1.0

```

Figura A. 3-Resultados Chow Test Flux

Fonte: Elaboração própria

```

Período: Total
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      288.0  0.039111      0.0      NaN      NaN      NaN
1      232.0  0.055451     56.0 -0.01634 -1.220807      1.0
Período: 1 semana
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      295.0  0.046445      0.0      NaN      NaN      NaN
1      239.0  0.058299     56.0 -0.011854 -0.867782      1.0
Período: 2 semanas
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      302.0  0.052952      0.0      NaN      NaN      NaN
1      246.0  0.059392     56.0 -0.00644 -0.47635      1.0
Período: 3 semanas
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      309.0  0.053946      0.0      NaN      NaN      NaN
1      253.0  0.060304     56.0 -0.006358 -0.476363      1.0
Período: 1 mês
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      316.0  0.056727      0.0      NaN      NaN      NaN
1      260.0  0.063572     56.0 -0.006845 -0.499883      1.0
Período: 2 meses
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      344.0  0.063521      0.0      NaN      NaN      NaN
1      288.0  0.067861     56.0 -0.00434 -0.32889      1.0
Período: 4 meses
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      400.0  0.073822      0.0      NaN      NaN      NaN
1      344.0  0.073131     56.0  0.000691  0.058031      1.0

```

Figura A. 4-Resultados Chow Test Grpg

Fonte: Elaboração própria

Período: Total						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	285.0	0.019237	0.0	NaN	NaN	NaN
1	230.0	0.030183	55.0	-0.010946	-1.51661	1.0
Período: 1 semana						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	292.0	0.023381	0.0	NaN	NaN	NaN
1	237.0	0.031489	55.0	-0.008107	-1.109453	1.0
Período: 2 semanas						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	299.0	0.028453	0.0	NaN	NaN	NaN
1	244.0	0.032361	55.0	-0.003908	-0.5357	1.0
Período: 3 semanas						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	306.0	0.028852	0.0	NaN	NaN	NaN
1	251.0	0.032984	55.0	-0.004132	-0.571744	1.0
Período: 1 mês						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	313.0	0.029353	0.0	NaN	NaN	NaN
1	258.0	0.034766	55.0	-0.005413	-0.730349	1.0
Período: 2 meses						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	341.0	0.032267	0.0	NaN	NaN	NaN
1	286.0	0.035719	55.0	-0.003452	-0.502578	1.0
Período: 4 meses						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	396.0	0.037806	0.0	NaN	NaN	NaN
1	343.0	0.038788	53.0	-0.000982	-0.163913	1.0

Figura A. 5-Resultados Chow Test Mro

Fonte: Elaboração própria

Período: Total						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	287.0	0.027219	0.0	NaN	NaN	NaN
1	208.0	0.040250	79.0	-0.013031	-0.852409	1.0
Período: 1 semana						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	294.0	0.031459	0.0	NaN	NaN	NaN
1	215.0	0.041559	79.0	-0.0101	-0.661393	1.0
Período: 2 semanas						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	301.0	0.034266	0.0	NaN	NaN	NaN
1	222.0	0.042543	79.0	-0.008277	-0.546736	1.0
Período: 3 semanas						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	308.0	0.034975	0.0	NaN	NaN	NaN
1	229.0	0.043609	79.0	-0.008634	-0.573927	1.0
Período: 1 mês						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	315.0	0.035955	0.0	NaN	NaN	NaN
1	236.0	0.045552	79.0	-0.009597	-0.629378	1.0
Período: 2 meses						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	343.0	0.041160	0.0	NaN	NaN	NaN
1	264.0	0.049256	79.0	-0.008095	-0.549233	1.0
Período: 4 meses						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	399.0	0.054099	0.0	NaN	NaN	NaN
1	320.0	0.054813	79.0	-0.000714	-0.052748	1.0

Figura A. 6-Resultados Chow Test Nsen

Fonte: Elaboração própria

```

Período: Total
  df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      285.0  0.019172      0.0      NaN      NaN      NaN
1      230.0  0.031482     55.0 -0.012309 -1.635087      1.0
Período: 1 semana
  df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      292.0  0.023965      0.0      NaN      NaN      NaN
1      237.0  0.032758     55.0 -0.008793 -1.156694      1.0
Período: 2 semanas
  df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      299.0  0.028597      0.0      NaN      NaN      NaN
1      244.0  0.033629     55.0 -0.005032 -0.663847      1.0
Período: 3 semanas
  df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      306.0  0.028964      0.0      NaN      NaN      NaN
1      251.0  0.034320     55.0 -0.005356 -0.712163      1.0
Período: 1 mês
  df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      313.0  0.029450      0.0      NaN      NaN      NaN
1      258.0  0.036084     55.0 -0.006633 -0.862353      1.0
Período: 2 meses
  df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      341.0  0.032698      0.0      NaN      NaN      NaN
1      286.0  0.037112     55.0 -0.004414 -0.618535      1.0
Período: 4 meses
  df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      396.0  0.038674      0.0      NaN      NaN      NaN
1      343.0  0.040177     53.0 -0.001503 -0.242104      1.0

```

Figura A. 7-Resultados Chow Test Oyx

Fonte: elaboração própria

```

Período: Total
  df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      292.0  0.023772      0.0      NaN      NaN      NaN
1      237.0  0.031562     55.0 -0.007791 -1.063616      1.0
Período: 1 semana
  df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      299.0  0.026977      0.0      NaN      NaN      NaN
1      244.0  0.032411     55.0 -0.005434 -0.743806      1.0
Período: 2 semanas
  df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      306.0  0.030992      0.0      NaN      NaN      NaN
1      251.0  0.032972     55.0 -0.00198  -0.274073      1.0
Período: 3 semanas
  df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      313.0  0.031358      0.0      NaN      NaN      NaN
1      258.0  0.033608     55.0 -0.00225  -0.314027      1.0
Período: 1 mês
  df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      320.0  0.031981      0.0      NaN      NaN      NaN
1      265.0  0.034230     55.0 -0.002249 -0.316534      1.0
Período: 2 meses
  df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      348.0  0.036311      0.0      NaN      NaN      NaN
1      293.0  0.036392     55.0 -0.000081 -0.011835      1.0
Período: 4 meses
  df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      404.0  0.046459      0.0      NaN      NaN      NaN
1      349.0  0.043946     55.0  0.002514  0.36295  0.999992

```

Figura A. 8-Resultados Chow Test Rwi

Fonte: elaboração própria

```

Período: Total
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      292.0  0.023316      0.0      NaN      NaN      NaN
1      237.0  0.033771     55.0 -0.010455 -1.334055      1.0
Período: 1 semana
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      299.0  0.026857      0.0      NaN      NaN      NaN
1      244.0  0.034455     55.0 -0.007598 -0.978333      1.0
Período: 2 semanas
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      306.0  0.031479      0.0      NaN      NaN      NaN
1      251.0  0.035357     55.0 -0.003878 -0.500589      1.0
Período: 3 semanas
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      313.0  0.031913      0.0      NaN      NaN      NaN
1      258.0  0.036651     55.0 -0.004738 -0.606384      1.0
Período: 1 mês
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      320.0  0.033035      0.0      NaN      NaN      NaN
1      265.0  0.037346     55.0 -0.004311 -0.556166      1.0
Período: 2 meses
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      348.0  0.037522      0.0      NaN      NaN      NaN
1      293.0  0.039538     55.0 -0.002016 -0.271601      1.0
Período: 4 meses
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      404.0  0.045101      0.0      NaN      NaN      NaN
1      349.0  0.045352     55.0 -0.000251 -0.035085      1.0

```

Figura A. 9-Resultados Chow Test Sbmo

Fonte: elaboração própria

```

Período: Total
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      292.0  0.022341      0.0      NaN      NaN      NaN
1      237.0  0.035338     55.0 -0.012997 -1.584819      1.0
Período: 1 semana
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      299.0  0.025264      0.0      NaN      NaN      NaN
1      244.0  0.036626     55.0 -0.011362 -1.376258      1.0
Período: 2 semanas
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      306.0  0.031001      0.0      NaN      NaN      NaN
1      251.0  0.037468     55.0 -0.006467 -0.787685      1.0
Período: 3 semanas
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      313.0  0.031729      0.0      NaN      NaN      NaN
1      258.0  0.038528     55.0 -0.006799 -0.82775      1.0
Período: 1 mês
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      320.0  0.032864      0.0      NaN      NaN      NaN
1      265.0  0.039776     55.0 -0.006912 -0.837287      1.0
Período: 2 meses
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      348.0  0.036281      0.0      NaN      NaN      NaN
1      293.0  0.041421     55.0 -0.005139 -0.661007      1.0
Período: 4 meses
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      404.0  0.043949      0.0      NaN      NaN      NaN
1      349.0  0.046741     55.0 -0.002793 -0.379127      1.0

```

Figura A. 10-Resultados Chow Test Shel

Fonte: elaboração própria

```

Período: Total
df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      292.0  0.022460      0.0      NaN      NaN      NaN
1      237.0  0.037986     55.0 -0.015526 -1.761284      1.0
Período: 1 semana
df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      299.0  0.026081      0.0      NaN      NaN      NaN
1      244.0  0.039013     55.0 -0.012931 -1.470508      1.0
Período: 2 semanas
df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      306.0  0.030336      0.0      NaN      NaN      NaN
1      251.0  0.039547     55.0 -0.009211 -1.06294      1.0
Período: 3 semanas
df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      313.0  0.030946      0.0      NaN      NaN      NaN
1      258.0  0.040062     55.0 -0.009116 -1.067363      1.0
Período: 1 mês
df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      320.0  0.031765      0.0      NaN      NaN      NaN
1      265.0  0.041141     55.0 -0.009376 -1.098088      1.0
Período: 2 meses
df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      348.0  0.036740      0.0      NaN      NaN      NaN
1      293.0  0.042525     55.0 -0.005784 -0.724649      1.0
Período: 4 meses
df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      404.0  0.047966      0.0      NaN      NaN      NaN
1      349.0  0.048603     55.0 -0.000637 -0.083131      1.0

```

Figura A. 11-Resultados Chow Test Sifg

Fonte: elaboração própria

```

Período: Total
df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      292.0  0.017257      0.0      NaN      NaN      NaN
1      237.0  0.015099     55.0 0.002158 0.615983 0.983214
Período: 1 semana
df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      299.0  0.018124      0.0      NaN      NaN      NaN
1      244.0  0.017200     55.0 0.000924 0.238279      1.0
Período: 2 semanas
df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      306.0  0.018604      0.0      NaN      NaN      NaN
1      251.0  0.017715     55.0 0.000889 0.228983      1.0
Período: 3 semanas
df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      313.0  0.019003      0.0      NaN      NaN      NaN
1      258.0  0.018178     55.0 0.000825 0.213008      1.0
Período: 1 mês
df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      320.0  0.019105      0.0      NaN      NaN      NaN
1      265.0  0.018837     55.0 0.000269 0.068775      1.0
Período: 2 meses
df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      348.0  0.020602      0.0      NaN      NaN      NaN
1      293.0  0.019547     55.0 0.001055 0.287562      1.0
Período: 4 meses
df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      404.0  0.026007      0.0      NaN      NaN      NaN
1      349.0  0.022444     55.0 0.003563 1.007316 0.466001

```

Figura A. 12-Resultados Chow Test Edp

Fonte: elaboração própria

Período: Total							
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)	
0	292.0	0.016768	0.0	NaN	NaN	NaN	
1	237.0	0.017023	55.0	-0.000256	-0.064724	1.0	
Período: 1 semana							
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)	
0	299.0	0.018272	0.0	NaN	NaN	NaN	
1	244.0	0.019553	55.0	-0.001281	-0.290623	1.0	
Período: 2 semanas							
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)	
0	306.0	0.019061	0.0	NaN	NaN	NaN	
1	251.0	0.020008	55.0	-0.000946	-0.215846	1.0	
Período: 3 semanas							
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)	
0	313.0	0.019552	0.0	NaN	NaN	NaN	
1	258.0	0.020198	55.0	-0.000646	-0.150125	1.0	
Período: 1 mês							
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)	
0	320.0	0.019766	0.0	NaN	NaN	NaN	
1	265.0	0.020863	55.0	-0.001097	-0.253246	1.0	
Período: 2 meses							
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)	
0	348.0	0.021228	0.0	NaN	NaN	NaN	
1	293.0	0.021719	55.0	-0.000492	-0.120572	1.0	
Período: 4 meses							
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)	
0	404.0	0.027257	0.0	NaN	NaN	NaN	
1	349.0	0.025309	55.0	0.001949	0.488539	0.999168	

Figura A. 13-Resultados Chow Test Edpr

Fonte: elaboração própria

Período: Total							
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)	
0	292.0	0.016768	0.0	NaN	NaN	NaN	
1	237.0	0.017023	55.0	-0.000256	-0.064724	1.0	
Período: 1 semana							
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)	
0	299.0	0.018272	0.0	NaN	NaN	NaN	
1	244.0	0.019553	55.0	-0.001281	-0.290623	1.0	
Período: 2 semanas							
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)	
0	306.0	0.019061	0.0	NaN	NaN	NaN	
1	251.0	0.020008	55.0	-0.000946	-0.215846	1.0	
Período: 3 semanas							
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)	
0	313.0	0.019552	0.0	NaN	NaN	NaN	
1	258.0	0.020198	55.0	-0.000646	-0.150125	1.0	
Período: 1 mês							
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)	
0	320.0	0.019766	0.0	NaN	NaN	NaN	
1	265.0	0.020863	55.0	-0.001097	-0.253246	1.0	
Período: 2 meses							
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)	
0	348.0	0.021228	0.0	NaN	NaN	NaN	
1	293.0	0.021719	55.0	-0.000492	-0.120572	1.0	
Período: 4 meses							
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)	
0	404.0	0.027257	0.0	NaN	NaN	NaN	
1	349.0	0.025309	55.0	0.001949	0.488539	0.999168	

Figura A. 14-Resultados Chow Test Galp

Fonte: elaboração própria

```

Período: Total
df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      292.0  0.023769      0.0      NaN      NaN      NaN
1      237.0  0.020090     55.0  0.003679  0.789121  0.851969
Período: 1 semana
df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      299.0  0.025333      0.0      NaN      NaN      NaN
1      244.0  0.021094     55.0  0.004239  0.89146  0.688637
Período: 2 semanas
df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      306.0  0.026500      0.0      NaN      NaN      NaN
1      251.0  0.021937     55.0  0.004563  0.949357  0.579228
Período: 3 semanas
df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      313.0  0.027095      0.0      NaN      NaN      NaN
1      258.0  0.022218     55.0  0.004878  1.029896  0.426274
Período: 1 mês
df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      320.0  0.027444      0.0      NaN      NaN      NaN
1      265.0  0.023499     55.0  0.003945  0.808953  0.826495
Período: 2 meses
df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      348.0  0.030782      0.0      NaN      NaN      NaN
1      293.0  0.024497     55.0  0.006285  1.366816  0.054624
Período: 4 meses
df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      404.0  0.036647      0.0      NaN      NaN      NaN
1      349.0  0.028595     55.0  0.008052  1.786788  0.001053

```

Figura A. 15-Resultados Chow Test Rene

Fonte: elaboração própria

```

Período: Total
df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      287.0  0.017303      0.0      NaN      NaN      NaN
1      233.0  0.029592     54.0 -0.012288 -1.791766  1.0
Período: 1 semana
df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      294.0  0.018837      0.0      NaN      NaN      NaN
1      240.0  0.029825     54.0 -0.010988 -1.637411  1.0
Período: 2 semanas
df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      301.0  0.019961      0.0      NaN      NaN      NaN
1      247.0  0.030261     54.0 -0.0103 -1.556828  1.0
Período: 3 semanas
df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      308.0  0.020627      0.0      NaN      NaN      NaN
1      254.0  0.030875     54.0 -0.010248 -1.561305  1.0
Período: 1 mês
df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      315.0  0.021450      0.0      NaN      NaN      NaN
1      261.0  0.031975     54.0 -0.010524 -1.590884  1.0
Período: 2 meses
df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      343.0  0.025425      0.0      NaN      NaN      NaN
1      289.0  0.033561     54.0 -0.008135 -1.297319  1.0
Período: 4 meses
df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      399.0  0.035080      0.0      NaN      NaN      NaN
1      345.0  0.036956     54.0 -0.001877 -0.324469  1.0

```

Figura A. 16-Resultados Chow Test Acca

Fonte: elaboração própria

```

Período: Total
  df_resid    ssr  df_diff  ss_diff      F  Pr(>F)
0      287.0  0.021753      0.0      NaN      NaN      NaN
1      233.0  0.033176     54.0 -0.011423 -1.485676      1.0
Período: 1 semana
  df_resid    ssr  df_diff  ss_diff      F  Pr(>F)
0      294.0  0.022733      0.0      NaN      NaN      NaN
1      240.0  0.033384     54.0 -0.010651 -1.418004      1.0
Período: 2 semanas
  df_resid    ssr  df_diff  ss_diff      F  Pr(>F)
0      301.0  0.023890      0.0      NaN      NaN      NaN
1      247.0  0.033823     54.0 -0.009933 -1.343269      1.0
Período: 3 semanas
  df_resid    ssr  df_diff  ss_diff      F  Pr(>F)
0      308.0  0.024566      0.0      NaN      NaN      NaN
1      254.0  0.034361     54.0 -0.009796 -1.340907      1.0
Período: 1 mês
  df_resid    ssr  df_diff  ss_diff      F  Pr(>F)
0      315.0  0.025488      0.0      NaN      NaN      NaN
1      261.0  0.036152     54.0 -0.010664 -1.425734      1.0
Período: 2 meses
  df_resid    ssr  df_diff  ss_diff      F  Pr(>F)
0      343.0  0.029826      0.0      NaN      NaN      NaN
1      289.0  0.038853     54.0 -0.009028 -1.243507      1.0
Período: 4 meses
  df_resid    ssr  df_diff  ss_diff      F  Pr(>F)
0      399.0  0.041275      0.0      NaN      NaN      NaN
1      345.0  0.043096     54.0 -0.001821 -0.269939      1.0

```

Figura A. 17-Resultados Chow Test Aglx

Fonte: elaboração própria

```

Período: Total
  df_resid    ssr  df_diff  ss_diff      F  Pr(>F)
0      287.0  0.021069      0.0      NaN      NaN      NaN
1      232.0  0.027935     55.0 -0.006867 -1.036846      1.0
Período: 1 semana
  df_resid    ssr  df_diff  ss_diff      F  Pr(>F)
0      294.0  0.021996      0.0      NaN      NaN      NaN
1      239.0  0.028599     55.0 -0.006603 -1.003297      1.0
Período: 2 semanas
  df_resid    ssr  df_diff  ss_diff      F  Pr(>F)
0      301.0  0.023007      0.0      NaN      NaN      NaN
1      246.0  0.029547     55.0 -0.006539 -0.989915      1.0
Período: 3 semanas
  df_resid    ssr  df_diff  ss_diff      F  Pr(>F)
0      308.0  0.023578      0.0      NaN      NaN      NaN
1      253.0  0.029948     55.0 -0.00637 -0.978438      1.0
Período: 1 mês
  df_resid    ssr  df_diff  ss_diff      F  Pr(>F)
0      315.0  0.024207      0.0      NaN      NaN      NaN
1      260.0  0.031561     55.0 -0.007353 -1.101407      1.0
Período: 2 meses
  df_resid    ssr  df_diff  ss_diff      F  Pr(>F)
0      343.0  0.028141      0.0      NaN      NaN      NaN
1      288.0  0.033876     55.0 -0.005735 -0.886473      1.0
Período: 4 meses
  df_resid    ssr  df_diff  ss_diff      F  Pr(>F)
0      399.0  0.038361      0.0      NaN      NaN      NaN
1      344.0  0.038305     55.0  0.000056  0.009149      1.0

```

Figura A. 18-Resultados Chow Test Akast

Fonte: elaboração própria



Período: Total						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	266.0	0.017736	0.0	NaN	NaN	NaN
1	233.0	0.028729	33.0	-0.010993	-2.701616	1.0
Período: 1 semana						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	273.0	0.018443	0.0	NaN	NaN	NaN
1	240.0	0.029053	33.0	-0.01061	-2.655921	1.0
Período: 2 semanas						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	280.0	0.019234	0.0	NaN	NaN	NaN
1	247.0	0.029514	33.0	-0.01028	-2.607106	1.0
Período: 3 semanas						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	287.0	0.020405	0.0	NaN	NaN	NaN
1	254.0	0.030009	33.0	-0.009604	-2.463315	1.0
Período: 1 mês						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	294.0	0.020986	0.0	NaN	NaN	NaN
1	261.0	0.031341	33.0	-0.010356	-2.613275	1.0
Período: 2 meses						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	322.0	0.024417	0.0	NaN	NaN	NaN
1	289.0	0.033378	33.0	-0.008961	-2.351135	1.0
Período: 4 meses						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	378.0	0.033843	0.0	NaN	NaN	NaN
1	345.0	0.036874	33.0	-0.00303	-0.859107	1.0

Figura A. 19-Resultados Chow Test Akh

Fonte: elaboração própria

Período: Total						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	287.0	0.015884	0.0	NaN	NaN	NaN
1	233.0	0.018602	54.0	-0.002718	-0.63039	1.0
Período: 1 semana						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	294.0	0.017236	0.0	NaN	NaN	NaN
1	240.0	0.020043	54.0	-0.002807	-0.622433	1.0
Período: 2 semanas						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	301.0	0.018646	0.0	NaN	NaN	NaN
1	247.0	0.020671	54.0	-0.002025	-0.448109	1.0
Período: 3 semanas						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	308.0	0.018966	0.0	NaN	NaN	NaN
1	254.0	0.021452	54.0	-0.002486	-0.545063	1.0
Período: 1 mês						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	315.0	0.019288	0.0	NaN	NaN	NaN
1	261.0	0.022806	54.0	-0.003519	-0.745707	1.0
Período: 2 meses						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	343.0	0.021702	0.0	NaN	NaN	NaN
1	289.0	0.024443	54.0	-0.002741	-0.600162	1.0
Período: 4 meses						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	399.0	0.027854	0.0	NaN	NaN	NaN
1	345.0	0.028079	54.0	-0.000226	-0.051312	1.0

Figura A. 20-Resultados Chow Test Akrbp

Fonte: elaboração própria

Período: Total						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	287.0	0.017590	0.0	NaN	NaN	NaN
1	233.0	0.024375	54.0	-0.006785	-1.200994	1.0
Período: 1 semana						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	294.0	0.018709	0.0	NaN	NaN	NaN
1	240.0	0.024702	54.0	-0.005993	-1.078264	1.0
Período: 2 semanas						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	301.0	0.019828	0.0	NaN	NaN	NaN
1	247.0	0.025902	54.0	-0.006074	-1.072623	1.0
Período: 3 semanas						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	308.0	0.020309	0.0	NaN	NaN	NaN
1	254.0	0.026387	54.0	-0.006077	-1.083385	1.0
Período: 1 mês						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	315.0	0.020903	0.0	NaN	NaN	NaN
1	261.0	0.027118	54.0	-0.006215	-1.107707	1.0
Período: 2 meses						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	343.0	0.024173	0.0	NaN	NaN	NaN
1	289.0	0.029042	54.0	-0.004869	-0.897254	1.0
Período: 4 meses						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	399.0	0.031444	0.0	NaN	NaN	NaN
1	345.0	0.032561	54.0	-0.001117	-0.219137	1.0

Figura A. 21-Resultados Chow Test Aksoa

Fonte: elaboração própria

Período: Total						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	287.0	0.021202	0.0	NaN	NaN	NaN
1	233.0	0.032330	54.0	-0.011128	-1.485167	1.0
Período: 1 semana						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	294.0	0.022777	0.0	NaN	NaN	NaN
1	240.0	0.032610	54.0	-0.009833	-1.340091	1.0
Período: 2 semanas						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	301.0	0.023833	0.0	NaN	NaN	NaN
1	247.0	0.033100	54.0	-0.009266	-1.280488	1.0
Período: 3 semanas						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	308.0	0.024413	0.0	NaN	NaN	NaN
1	254.0	0.033505	54.0	-0.009092	-1.276437	1.0
Período: 1 mês						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	315.0	0.025192	0.0	NaN	NaN	NaN
1	261.0	0.035409	54.0	-0.010217	-1.394562	1.0
Período: 2 meses						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	343.0	0.029397	0.0	NaN	NaN	NaN
1	289.0	0.037957	54.0	-0.00856	-1.206914	1.0
Período: 4 meses						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	399.0	0.040614	0.0	NaN	NaN	NaN
1	345.0	0.042249	54.0	-0.001635	-0.24718	1.0

Figura A. 22-Resultados Chow Test Archa

Fonte: elaboração própria

```

Período: Total
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      285.0  0.021998      0.0      NaN      NaN      NaN
1      230.0  0.034543     55.0 -0.012546 -1.518767      1.0
Período: 1 semana
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      292.0  0.023431      0.0      NaN      NaN      NaN
1      237.0  0.034935     55.0 -0.011504 -1.418974      1.0
Período: 2 semanas
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      299.0  0.024446      0.0      NaN      NaN      NaN
1      244.0  0.035491     55.0 -0.011045 -1.380665      1.0
Período: 3 semanas
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      306.0  0.025094      0.0      NaN      NaN      NaN
1      251.0  0.036681     55.0 -0.011586 -1.441514      1.0
Período: 1 mês
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      313.0  0.025903      0.0      NaN      NaN      NaN
1      258.0  0.038369     55.0 -0.012466 -1.524085      1.0
Período: 2 meses
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      341.0  0.030936      0.0      NaN      NaN      NaN
1      286.0  0.041126     55.0 -0.01019 -1.288469      1.0
Período: 4 meses
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      397.0  0.042186      0.0      NaN      NaN      NaN
1      342.0  0.045351     55.0 -0.003165 -0.433958      1.0

```

Figura A. 23-Resultados Chow Test Awdr

Fonte: elaboração própria

```

Período: Total
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      287.0  0.018413      0.0      NaN      NaN      NaN
1      233.0  0.027093     54.0 -0.008681 -1.382474      1.0
Período: 1 semana
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      294.0  0.020408      0.0      NaN      NaN      NaN
1      240.0  0.027335     54.0 -0.006927 -1.126303      1.0
Período: 2 semanas
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      301.0  0.021381      0.0      NaN      NaN      NaN
1      247.0  0.027827     54.0 -0.006446 -1.059581      1.0
Período: 3 semanas
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      308.0  0.021740      0.0      NaN      NaN      NaN
1      254.0  0.028017     54.0 -0.006277 -1.053838      1.0
Período: 1 mês
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      315.0  0.022499      0.0      NaN      NaN      NaN
1      261.0  0.029057     54.0 -0.006558 -1.090925      1.0
Período: 2 meses
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      343.0  0.025959      0.0      NaN      NaN      NaN
1      289.0  0.031421     54.0 -0.005462 -0.930345      1.0
Período: 4 meses
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      399.0  0.035228      0.0      NaN      NaN      NaN
1      345.0  0.034792     54.0  0.000436  0.080087      1.0

```

Figura A. 24-Resultados Chow Test Borr

Fonte: elaboração própria

```

Período: Total
  df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      287.0  0.018345      0.0      NaN      NaN      NaN
1      233.0  0.022019      54.0 -0.003674 -0.720048      1.0
Período: 1 semana
  df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      294.0  0.019462      0.0      NaN      NaN      NaN
1      240.0  0.022783      54.0 -0.003321 -0.647931      1.0
Período: 2 semanas
  df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      301.0  0.020335      0.0      NaN      NaN      NaN
1      247.0  0.023035      54.0 -0.0027 -0.536162      1.0
Período: 3 semanas
  df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      308.0  0.020823      0.0      NaN      NaN      NaN
1      254.0  0.023346      54.0 -0.002523 -0.508325      1.0
Período: 1 mês
  df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      315.0  0.021393      0.0      NaN      NaN      NaN
1      261.0  0.023788      54.0 -0.002395 -0.486594      1.0
Período: 2 meses
  df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      343.0  0.024568      0.0      NaN      NaN      NaN
1      289.0  0.025304      54.0 -0.000736 -0.155691      1.0
Período: 4 meses
  df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      399.0  0.031996      0.0      NaN      NaN      NaN
1      345.0  0.030587      54.0  0.001408  0.294192      1.0

```

Figura A. 25-Resultados Chow Test Bwe

Fonte: elaboração própria

```

Período: Total
  df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      287.0  0.016185      0.0      NaN      NaN      NaN
1      233.0  0.016859      54.0 -0.000674 -0.172438      1.0
Período: 1 semana
  df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      294.0  0.017241      0.0      NaN      NaN      NaN
1      240.0  0.016972      54.0  0.00027  0.070604      1.0
Período: 2 semanas
  df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      301.0  0.018428      0.0      NaN      NaN      NaN
1      247.0  0.017165      54.0  0.001263  0.336546  0.999996
Período: 3 semanas
  df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      308.0  0.018663      0.0      NaN      NaN      NaN
1      254.0  0.017579      54.0  0.001084  0.290108      1.0
Período: 1 mês
  df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      315.0  0.019278      0.0      NaN      NaN      NaN
1      261.0  0.018106      54.0  0.001172  0.31275  0.999999
Período: 2 meses
  df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      343.0  0.021885      0.0      NaN      NaN      NaN
1      289.0  0.020355      54.0  0.001529  0.402042  0.999942
Período: 4 meses
  df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      399.0  0.026853      0.0      NaN      NaN      NaN
1      345.0  0.025159      54.0  0.001694  0.430287  0.999853

```

Figura A. 26-Resultados Chow Test Bwo

Fonte: elaboração própria

```

Período: Total
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      287.0  0.022921      0.0      NaN      NaN      NaN
1      233.0  0.032330      54.0 -0.009409 -1.25573      1.0
Período: 1 semana
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      294.0  0.024068      0.0      NaN      NaN      NaN
1      240.0  0.032483      54.0 -0.008415 -1.151365      1.0
Período: 2 semanas
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      301.0  0.025102      0.0      NaN      NaN      NaN
1      247.0  0.033126      54.0 -0.008024 -1.10793      1.0
Período: 3 semanas
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      308.0  0.025777      0.0      NaN      NaN      NaN
1      254.0  0.033610      54.0 -0.007834 -1.096288      1.0
Período: 1 mês
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      315.0  0.026545      0.0      NaN      NaN      NaN
1      261.0  0.035002      54.0 -0.008457 -1.167777      1.0
Período: 2 meses
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      343.0  0.031386      0.0      NaN      NaN      NaN
1      289.0  0.038029      54.0 -0.006643 -0.934824      1.0
Período: 4 meses
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      399.0  0.043035      0.0      NaN      NaN      NaN
1      345.0  0.042480      54.0  0.000554  0.083384      1.0

```

Figura A. 27-Resultados Chow Test Carbn

Fonte: elaboração própria

```

Período: Total
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      287.0  0.020598      0.0      NaN      NaN      NaN
1      233.0  0.030180      54.0 -0.009582 -1.369978      1.0
Período: 1 semana
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      294.0  0.021313      0.0      NaN      NaN      NaN
1      240.0  0.030601      54.0 -0.009288 -1.348963      1.0
Período: 2 semanas
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      301.0  0.022331      0.0      NaN      NaN      NaN
1      247.0  0.031087      54.0 -0.008756 -1.288303      1.0
Período: 3 semanas
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      308.0  0.023034      0.0      NaN      NaN      NaN
1      254.0  0.031475      54.0 -0.00844  -1.261333      1.0
Período: 1 mês
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      315.0  0.023798      0.0      NaN      NaN      NaN
1      261.0  0.033770      54.0 -0.009972 -1.427261      1.0
Período: 2 meses
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      343.0  0.028487      0.0      NaN      NaN      NaN
1      289.0  0.036395      54.0 -0.007908 -1.162832      1.0
Período: 4 meses
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      399.0  0.039211      0.0      NaN      NaN      NaN
1      345.0  0.039879      54.0 -0.000668 -0.107065      1.0

```

Figura A. 28-Resultados Chow Test Cloud

Fonte: elaboração própria

```

Período: Total
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      287.0  0.017107      0.0      NaN      NaN      NaN
1      233.0  0.021268     54.0 -0.004161 -0.84412      1.0
Período: 1 semana
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      294.0  0.018571      0.0      NaN      NaN      NaN
1      240.0  0.021757     54.0 -0.003186 -0.65083      1.0
Período: 2 semanas
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      301.0  0.020025      0.0      NaN      NaN      NaN
1      247.0  0.022525     54.0 -0.002499 -0.507537     1.0
Período: 3 semanas
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      308.0  0.020341      0.0      NaN      NaN      NaN
1      254.0  0.023313     54.0 -0.002972 -0.599656     1.0
Período: 1 mês
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      315.0  0.02066      0.0      NaN      NaN      NaN
1      261.0  0.02505     54.0 -0.00439 -0.847123     1.0
Período: 2 meses
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      343.0  0.023126      0.0      NaN      NaN      NaN
1      289.0  0.026945     54.0 -0.003819 -0.758596     1.0
Período: 4 meses
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      399.0  0.029970      0.0      NaN      NaN      NaN
1      345.0  0.030154     54.0 -0.000184 -0.038956     1.0

```

Figura A. 29-Resultados Chow Test Dno

Fonte: elaboração própria

```

Período: Total
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      287.0  0.023005      0.0      NaN      NaN      NaN
1      233.0  0.032934     54.0 -0.009928 -1.300778     1.0
Período: 1 semana
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      294.0  0.024426      0.0      NaN      NaN      NaN
1      240.0  0.033313     54.0 -0.008886 -1.185595     1.0
Período: 2 semanas
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      301.0  0.025482      0.0      NaN      NaN      NaN
1      247.0  0.033877     54.0 -0.008395 -1.13348     1.0
Período: 3 semanas
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      308.0  0.026142      0.0      NaN      NaN      NaN
1      254.0  0.034317     54.0 -0.008175 -1.120501     1.0
Período: 1 mês
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      315.0  0.026906      0.0      NaN      NaN      NaN
1      261.0  0.036684     54.0 -0.009778 -1.288276     1.0
Período: 2 meses
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      343.0  0.031730      0.0      NaN      NaN      NaN
1      289.0  0.039475     54.0 -0.007745 -1.050057     1.0
Período: 4 meses
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      399.0  0.042151      0.0      NaN      NaN      NaN
1      345.0  0.043739     54.0 -0.001587 -0.231828     1.0

```

Figura A. 30-Resultados Chow Test Dof

Fonte: elaboração própria

```

Período: Total
  df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      287.0  0.021675      0.0      NaN      NaN      NaN
1      233.0  0.031267      54.0 -0.009591 -1.323612      1.0
Período: 1 semana
  df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      294.0  0.022660      0.0      NaN      NaN      NaN
1      240.0  0.031564      54.0 -0.008905 -1.253812      1.0
Período: 2 semanas
  df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      301.0  0.023484      0.0      NaN      NaN      NaN
1      247.0  0.032064      54.0 -0.00858 -1.224014      1.0
Período: 3 semanas
  df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      308.0  0.024048      0.0      NaN      NaN      NaN
1      254.0  0.032749      54.0 -0.008702 -1.24978      1.0
Período: 1 mês
  df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      315.0  0.024785      0.0      NaN      NaN      NaN
1      261.0  0.034116      54.0 -0.009331 -1.321956      1.0
Período: 2 meses
  df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      343.0  0.029059      0.0      NaN      NaN      NaN
1      289.0  0.036600      54.0 -0.00754 -1.102603      1.0
Período: 4 meses
  df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      399.0  0.039831      0.0      NaN      NaN      NaN
1      345.0  0.041194      54.0 -0.001363 -0.211324      1.0

```

Figura A. 31-Resultados Chow Test Efuel

Fonte: elaboração própria

```

Período: Total
  df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      287.0  0.022035      0.0      NaN      NaN      NaN
1      233.0  0.031094      54.0 -0.00906 -1.257161      1.0
Período: 1 semana
  df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      294.0  0.023340      0.0      NaN      NaN      NaN
1      240.0  0.031514      54.0 -0.008174 -1.152757      1.0
Período: 2 semanas
  df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      301.0  0.024170      0.0      NaN      NaN      NaN
1      247.0  0.032084      54.0 -0.007914 -1.128289      1.0
Período: 3 semanas
  df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      308.0  0.024862      0.0      NaN      NaN      NaN
1      254.0  0.032605      54.0 -0.007743 -1.117041      1.0
Período: 1 mês
  df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      315.0  0.025569      0.0      NaN      NaN      NaN
1      261.0  0.034366      54.0 -0.008796 -1.237138      1.0
Período: 2 meses
  df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      343.0  0.030363      0.0      NaN      NaN      NaN
1      289.0  0.036919      54.0 -0.006556 -0.950428      1.0
Período: 4 meses
  df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      399.0  0.041158      0.0      NaN      NaN      NaN
1      345.0  0.041558      54.0 -0.000399 -0.06137      1.0

```

Figura A. 32-Resultados Chow Test Eiof

Fonte: elaboração própria

```

Período: Total
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      287.0  0.019939      0.0      NaN      NaN      NaN
1      233.0  0.031964      54.0 -0.012025 -1.623303      1.0
Período: 1 semana
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      294.0  0.021035      0.0      NaN      NaN      NaN
1      240.0  0.032327      54.0 -0.011291 -1.552395      1.0
Período: 2 semanas
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      301.0  0.021898      0.0      NaN      NaN      NaN
1      247.0  0.032818      54.0 -0.01092 -1.522014      1.0
Período: 3 semanas
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      308.0  0.022541      0.0      NaN      NaN      NaN
1      254.0  0.033267      54.0 -0.010727 -1.516638      1.0
Período: 1 mês
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      315.0  0.023324      0.0      NaN      NaN      NaN
1      261.0  0.034877      54.0 -0.011553 -1.601028      1.0
Período: 2 meses
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      343.0  0.029675      0.0      NaN      NaN      NaN
1      289.0  0.037407      54.0 -0.007732 -1.106231      1.0
Período: 4 meses
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      399.0  0.040285      0.0      NaN      NaN      NaN
1      345.0  0.041328      54.0 -0.001043 -0.161259      1.0

```

Figura A. 33-Resultados Chow Test Elmra

Fonte: elaboração própria

```

Período: Total
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      287.0  0.022553      0.0      NaN      NaN      NaN
1      233.0  0.032174      54.0 -0.009621 -1.290294      1.0
Período: 1 semana
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      294.0  0.024053      0.0      NaN      NaN      NaN
1      240.0  0.032548      54.0 -0.008496 -1.160062      1.0
Período: 2 semanas
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      301.0  0.025096      0.0      NaN      NaN      NaN
1      247.0  0.033033      54.0 -0.007936 -1.098958      1.0
Período: 3 semanas
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      308.0  0.025738      0.0      NaN      NaN      NaN
1      254.0  0.033543      54.0 -0.007804 -1.094417      1.0
Período: 1 mês
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      315.0  0.026511      0.0      NaN      NaN      NaN
1      261.0  0.035641      54.0 -0.00913 -1.238097      1.0
Período: 2 meses
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      343.0  0.031147      0.0      NaN      NaN      NaN
1      289.0  0.037983      54.0 -0.006836 -0.963265      1.0
Período: 4 meses
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      399.0  0.041872      0.0      NaN      NaN      NaN
1      345.0  0.042156      54.0 -0.000283 -0.042955      1.0

```

Figura A. 34-Resultados Chow Test Emgs

Fonte: elaboração própria



Período: Total						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	287.0	0.014837	0.0	NaN	NaN	NaN
1	233.0	0.017152	54.0	-0.002315	-0.582249	1.0
Período: 1 semana						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	294.0	0.016339	0.0	NaN	NaN	NaN
1	240.0	0.018148	54.0	-0.001808	-0.442863	1.0
Período: 2 semanas						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	301.0	0.017738	0.0	NaN	NaN	NaN
1	247.0	0.018699	54.0	-0.000961	-0.235098	1.0
Período: 3 semanas						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	308.0	0.017929	0.0	NaN	NaN	NaN
1	254.0	0.019201	54.0	-0.001272	-0.311616	1.0
Período: 1 mês						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	315.0	0.018225	0.0	NaN	NaN	NaN
1	261.0	0.020941	54.0	-0.002716	-0.626783	1.0
Período: 2 meses						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	343.0	0.020570	0.0	NaN	NaN	NaN
1	289.0	0.022824	54.0	-0.002254	-0.528452	1.0
Período: 4 meses						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	399.0	0.024793	0.0	NaN	NaN	NaN
1	345.0	0.025952	54.0	-0.001159	-0.285252	1.0

Figura A. 35-Resultados Chow Test Eqnr

Fonte: elaboração própria

Período: Total						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	270.0	0.023896	0.0	NaN	NaN	NaN
1	232.0	0.033833	38.0	-0.009937	-1.793101	1.0
Período: 1 semana						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	277.0	0.025104	0.0	NaN	NaN	NaN
1	239.0	0.034207	38.0	-0.009103	-1.67376	1.0
Período: 2 semanas						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	284.0	0.026142	0.0	NaN	NaN	NaN
1	246.0	0.034758	38.0	-0.008616	-1.604749	1.0
Período: 3 semanas						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	291.0	0.026811	0.0	NaN	NaN	NaN
1	253.0	0.035283	38.0	-0.008472	-1.598671	1.0
Período: 1 mês						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	298.0	0.027562	0.0	NaN	NaN	NaN
1	260.0	0.037684	38.0	-0.010121	-1.837736	1.0
Período: 2 meses						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	326.0	0.032464	0.0	NaN	NaN	NaN
1	288.0	0.040312	38.0	-0.007848	-1.475469	1.0
Período: 4 meses						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	382.0	0.043992	0.0	NaN	NaN	NaN
1	344.0	0.045347	38.0	-0.001355	-0.270422	1.0

Figura A. 36-Resultados Chow Test Geos

Fonte: elaboração própria

```

Período: Total
df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      287.0  0.022971      0.0      NaN      NaN      NaN
1      233.0  0.032436      54.0 -0.009465 -1.259129      1.0
Período: 1 semana
df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      294.0  0.024249      0.0      NaN      NaN      NaN
1      240.0  0.032747      54.0 -0.008498 -1.153399      1.0
Período: 2 semanas
df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      301.0  0.025282      0.0      NaN      NaN      NaN
1      247.0  0.033331      54.0 -0.008048 -1.104512      1.0
Período: 3 semanas
df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      308.0  0.025956      0.0      NaN      NaN      NaN
1      254.0  0.033858      54.0 -0.007902 -1.097821      1.0
Período: 1 mês
df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      315.0  0.026735      0.0      NaN      NaN      NaN
1      261.0  0.036250      54.0 -0.009515 -1.268644      1.0
Período: 2 meses
df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      343.0  0.031694      0.0      NaN      NaN      NaN
1      289.0  0.038829      54.0 -0.007135 -0.983481      1.0
Período: 4 meses
df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      399.0  0.042762      0.0      NaN      NaN      NaN
1      345.0  0.043130      54.0 -0.000368 -0.054555      1.0

```

Figura A. 37-Resultados Chow Test Havi

Fonte: elaboração própria

```

Período: Total
df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      268.0  0.021592      0.0      NaN      NaN      NaN
1      232.0  0.032364      36.0 -0.010772 -2.145018      1.0
Período: 1 semana
df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      275.0  0.022739      0.0      NaN      NaN      NaN
1      239.0  0.032490      36.0 -0.009752 -1.992579      1.0
Período: 2 semanas
df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      282.0  0.023789      0.0      NaN      NaN      NaN
1      246.0  0.033163      36.0 -0.009374 -1.931593      1.0
Período: 3 semanas
df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      289.0  0.024443      0.0      NaN      NaN      NaN
1      253.0  0.033587      36.0 -0.009144 -1.913385      1.0
Período: 1 mês
df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      296.0  0.025183      0.0      NaN      NaN      NaN
1      260.0  0.034869      36.0 -0.009686 -2.006187      1.0
Período: 2 meses
df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      324.0  0.030061      0.0      NaN      NaN      NaN
1      288.0  0.039748      36.0 -0.009687 -1.949632      1.0
Período: 4 meses
df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      380.0  0.041796      0.0      NaN      NaN      NaN
1      344.0  0.043935      36.0 -0.002139 -0.46529      1.0

```

Figura A. 38-Resultados Chow Test Hrgi

Fonte: elaboração própria

```

Período: Total
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      287.0  0.019374      0.0      NaN      NaN      NaN
1      233.0  0.034232     54.0 -0.014859 -1.872859      1.0
Período: 1 semana
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      294.0  0.020291      0.0      NaN      NaN      NaN
1      240.0  0.034582     54.0 -0.014291 -1.836681      1.0
Período: 2 semanas
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      301.0  0.021026      0.0      NaN      NaN      NaN
1      247.0  0.035162     54.0 -0.014136 -1.838869      1.0
Período: 3 semanas
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      308.0  0.021754      0.0      NaN      NaN      NaN
1      254.0  0.035632     54.0 -0.013878 -1.832052      1.0
Período: 1 mês
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      315.0  0.022261      0.0      NaN      NaN      NaN
1      261.0  0.038104     54.0 -0.015843 -2.009579      1.0
Período: 2 meses
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      343.0  0.024787      0.0      NaN      NaN      NaN
1      289.0  0.040938     54.0 -0.016151 -2.111452      1.0
Período: 4 meses
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      399.0  0.035386      0.0      NaN      NaN      NaN
1      345.0  0.045190     54.0 -0.009804 -1.386027      1.0

```

Figura A. 39-Resultados Chow Test Hunt

Fonte: elaboração própria

```

Período: Total
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      287.0  0.020410      0.0      NaN      NaN      NaN
1      233.0  0.031933     54.0 -0.011522 -1.556919      1.0
Período: 1 semana
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      294.0  0.021317      0.0      NaN      NaN      NaN
1      240.0  0.032339     54.0 -0.011022 -1.514791      1.0
Período: 2 semanas
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      301.0  0.022151      0.0      NaN      NaN      NaN
1      247.0  0.032805     54.0 -0.010654 -1.485495      1.0
Período: 3 semanas
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      308.0  0.022861      0.0      NaN      NaN      NaN
1      254.0  0.033490     54.0 -0.01063  -1.49293      1.0
Período: 1 mês
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      315.0  0.024104      0.0      NaN      NaN      NaN
1      261.0  0.035229     54.0 -0.011125 -1.526283      1.0
Período: 2 meses
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      343.0  0.027933      0.0      NaN      NaN      NaN
1      289.0  0.037661     54.0 -0.009728 -1.382446      1.0
Período: 4 meses
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      399.0  0.039765      0.0      NaN      NaN      NaN
1      345.0  0.041484     54.0 -0.001718 -0.264652      1.0

```

Figura A. 40-Resultados Chow Test Hypro

Fonte: elaboração própria

Período: Total						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	287.0	0.022625	0.0	NaN	NaN	NaN
1	233.0	0.032243	54.0	-0.009617	-1.287036	1.0
Período: 1 semana						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	294.0	0.024248	0.0	NaN	NaN	NaN
1	240.0	0.032749	54.0	-0.008501	-1.15371	1.0
Período: 2 semanas						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	301.0	0.025318	0.0	NaN	NaN	NaN
1	247.0	0.033514	54.0	-0.008196	-1.118565	1.0
Período: 3 semanas						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	308.0	0.025856	0.0	NaN	NaN	NaN
1	254.0	0.033951	54.0	-0.008095	-1.121498	1.0
Período: 1 mês						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	315.0	0.026589	0.0	NaN	NaN	NaN
1	261.0	0.036116	54.0	-0.009527	-1.274968	1.0
Período: 2 meses						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	343.0	0.031062	0.0	NaN	NaN	NaN
1	289.0	0.038836	54.0	-0.007774	-1.071277	1.0
Período: 4 meses						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	399.0	0.041886	0.0	NaN	NaN	NaN
1	345.0	0.042806	54.0	-0.00092	-0.13732	1.0

Figura A. 41-Resultados Chow Test Iox

Fonte: elaboração própria

Período: Total						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	287.0	0.019549	0.0	NaN	NaN	NaN
1	233.0	0.025231	54.0	-0.005682	-0.97166	1.0
Período: 1 semana						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	294.0	0.020365	0.0	NaN	NaN	NaN
1	240.0	0.025519	54.0	-0.005153	-0.897532	1.0
Período: 2 semanas						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	301.0	0.021178	0.0	NaN	NaN	NaN
1	247.0	0.025848	54.0	-0.00467	-0.826426	1.0
Período: 3 semanas						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	308.0	0.021652	0.0	NaN	NaN	NaN
1	254.0	0.026132	54.0	-0.00448	-0.806432	1.0
Período: 1 mês						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	315.0	0.022307	0.0	NaN	NaN	NaN
1	261.0	0.027473	54.0	-0.005166	-0.908839	1.0
Período: 2 meses						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	343.0	0.025689	0.0	NaN	NaN	NaN
1	289.0	0.030633	54.0	-0.004944	-0.863689	1.0
Período: 4 meses						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	399.0	0.035270	0.0	NaN	NaN	NaN
1	345.0	0.033957	54.0	0.001312	0.246936	1.0

Figura A. 42-Resultados Chow Test Mng

Fonte: elaboração própria

Período: Total						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	272.0	0.019874	0.0	NaN	NaN	NaN
1	231.0	0.032222	41.0	-0.012347	-2.158965	1.0
Período: 1 semana						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	279.0	0.020765	0.0	NaN	NaN	NaN
1	238.0	0.032486	41.0	-0.011721	-2.094384	1.0
Período: 2 semanas						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	286.0	0.021763	0.0	NaN	NaN	NaN
1	245.0	0.033040	41.0	-0.011278	-2.039674	1.0
Período: 3 semanas						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	293.0	0.022070	0.0	NaN	NaN	NaN
1	252.0	0.033377	41.0	-0.011307	-2.082188	1.0
Período: 1 mês						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	300.0	0.022638	0.0	NaN	NaN	NaN
1	259.0	0.035157	41.0	-0.012518	-2.249338	1.0
Período: 2 meses						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	328.0	0.027406	0.0	NaN	NaN	NaN
1	287.0	0.038033	41.0	-0.010628	-1.955996	1.0
Período: 4 meses						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	384.0	0.037744	0.0	NaN	NaN	NaN
1	343.0	0.042189	41.0	-0.004445	-0.881421	1.0

Figura A. 43-Resultados Chow Test Mpces

Fonte: elaboração própria

Período: Total						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	287.0	0.022708	0.0	NaN	NaN	NaN
1	233.0	0.032221	54.0	-0.009513	-1.273964	1.0
Período: 1 semana						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	294.0	0.023869	0.0	NaN	NaN	NaN
1	240.0	0.032542	54.0	-0.008674	-1.184588	1.0
Período: 2 semanas						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	301.0	0.024810	0.0	NaN	NaN	NaN
1	247.0	0.033005	54.0	-0.008195	-1.135681	1.0
Período: 3 semanas						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	308.0	0.025500	0.0	NaN	NaN	NaN
1	254.0	0.033577	54.0	-0.008077	-1.131434	1.0
Período: 1 mês						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	315.0	0.026275	0.0	NaN	NaN	NaN
1	261.0	0.036143	54.0	-0.009868	-1.319614	1.0
Período: 2 meses						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	343.0	0.030917	0.0	NaN	NaN	NaN
1	289.0	0.038910	54.0	-0.007993	-1.099407	1.0
Período: 4 meses						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	399.0	0.042048	0.0	NaN	NaN	NaN
1	345.0	0.043170	54.0	-0.001122	-0.165982	1.0

Figura A. 44-Resultados Chow Test Ndol

Fonte: elaboração própria

```

Período: Total
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      287.0  0.019252      0.0      NaN      NaN      NaN
1      233.0  0.028726     54.0 -0.009474 -1.42308      1.0
Período: 1 semana
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      294.0  0.020231      0.0      NaN      NaN      NaN
1      240.0  0.029368     54.0 -0.009137 -1.382791     1.0
Período: 2 semanas
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      301.0  0.021075      0.0      NaN      NaN      NaN
1      247.0  0.029746     54.0 -0.008671 -1.333381     1.0
Período: 3 semanas
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      308.0  0.021797      0.0      NaN      NaN      NaN
1      254.0  0.030016     54.0 -0.008219 -1.288024     1.0
Período: 1 mês
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      315.0  0.022471      0.0      NaN      NaN      NaN
1      261.0  0.031816     54.0 -0.009346 -1.419734     1.0
Período: 2 meses
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      343.0  0.026099      0.0      NaN      NaN      NaN
1      289.0  0.033826     54.0 -0.007727 -1.222525     1.0
Período: 4 meses
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      399.0  0.036322      0.0      NaN      NaN      NaN
1      345.0  0.038377     54.0 -0.002055 -0.34213      1.0

```

Figura A. 45-Resultados Chow Test Nel

Fonte: elaboração própria

```

Período: Total
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      287.0  0.022746      0.0      NaN      NaN      NaN
1      233.0  0.028967     54.0 -0.006221 -0.926669     1.0
Período: 1 semana
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      294.0  0.023968      0.0      NaN      NaN      NaN
1      240.0  0.029383     54.0 -0.005415 -0.819017     1.0
Período: 2 semanas
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      301.0  0.024975      0.0      NaN      NaN      NaN
1      247.0  0.030188     54.0 -0.005213 -0.789892     1.0
Período: 3 semanas
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      308.0  0.025642      0.0      NaN      NaN      NaN
1      254.0  0.030593     54.0 -0.004951 -0.761296     1.0
Período: 1 mês
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      315.0  0.026305      0.0      NaN      NaN      NaN
1      261.0  0.032257     54.0 -0.005952 -0.8918      1.0
Período: 2 meses
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      343.0  0.030716      0.0      NaN      NaN      NaN
1      289.0  0.036252     54.0 -0.005536 -0.817229     1.0
Período: 4 meses
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      399.0  0.041366      0.0      NaN      NaN      NaN
1      345.0  0.040232     54.0  0.001135  0.180217     1.0

```

Figura A. 46-Resultados Chow Test Nol

Fonte: elaboração própria

Período: Total						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	287.0	0.021367	0.0	NaN	NaN	NaN
1	233.0	0.027636	54.0	-0.006268	-0.978675	1.0
Período: 1 semana						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	294.0	0.023093	0.0	NaN	NaN	NaN
1	240.0	0.028202	54.0	-0.005109	-0.80509	1.0
Período: 2 semanas						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	301.0	0.023968	0.0	NaN	NaN	NaN
1	247.0	0.028518	54.0	-0.00455	-0.729809	1.0
Período: 3 semanas						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	308.0	0.024462	0.0	NaN	NaN	NaN
1	254.0	0.029142	54.0	-0.00468	-0.755445	1.0
Período: 1 mês						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	315.0	0.025160	0.0	NaN	NaN	NaN
1	261.0	0.031435	54.0	-0.006275	-0.96485	1.0
Período: 2 meses						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	343.0	0.028905	0.0	NaN	NaN	NaN
1	289.0	0.033998	54.0	-0.005093	-0.801756	1.0
Período: 4 meses						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	399.0	0.039049	0.0	NaN	NaN	NaN
1	345.0	0.038093	54.0	0.000956	0.160415	1.0

Figura A. 47-Resultados Chow Test Nor

Fonte: elaboração própria

Período: Total						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	287.0	0.022302	0.0	NaN	NaN	NaN
1	233.0	0.032249	54.0	-0.009947	-1.330878	1.0
Período: 1 semana						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	294.0	0.023337	0.0	NaN	NaN	NaN
1	240.0	0.032468	54.0	-0.009131	-1.249957	1.0
Período: 2 semanas						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	301.0	0.024442	0.0	NaN	NaN	NaN
1	247.0	0.033183	54.0	-0.008741	-1.204865	1.0
Período: 3 semanas						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	308.0	0.025214	0.0	NaN	NaN	NaN
1	254.0	0.033593	54.0	-0.008379	-1.173251	1.0
Período: 1 mês						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	315.0	0.026017	0.0	NaN	NaN	NaN
1	261.0	0.035768	54.0	-0.009751	-1.317676	1.0
Período: 2 meses						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	343.0	0.029837	0.0	NaN	NaN	NaN
1	289.0	0.038281	54.0	-0.008444	-1.180528	1.0
Período: 4 meses						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	399.0	0.041053	0.0	NaN	NaN	NaN
1	345.0	0.042781	54.0	-0.001728	-0.258014	1.0

Figura A. 48-Resultados Chow Test North

Fonte: elaboração própria

```

Período: Total
  df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      287.0  0.017170      0.0      NaN      NaN      NaN
1      233.0  0.022858      54.0 -0.005688 -1.073753      1.0
Período: 1 semana
  df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      294.0  0.018187      0.0      NaN      NaN      NaN
1      240.0  0.023296      54.0 -0.005109 -0.974698      1.0
Período: 2 semanas
  df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      301.0  0.019374      0.0      NaN      NaN      NaN
1      247.0  0.023684      54.0 -0.004311 -0.832483      1.0
Período: 3 semanas
  df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      308.0  0.019788      0.0      NaN      NaN      NaN
1      254.0  0.024304      54.0 -0.004516 -0.873996      1.0
Período: 1 mês
  df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      315.0  0.020683      0.0      NaN      NaN      NaN
1      261.0  0.024793      54.0 -0.004111 -0.801251      1.0
Período: 2 meses
  df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      343.0  0.024169      0.0      NaN      NaN      NaN
1      289.0  0.026857      54.0 -0.002688 -0.535632      1.0
Período: 4 meses
  df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      399.0  0.030732      0.0      NaN      NaN      NaN
1      345.0  0.030561      54.0  0.000171  0.035745      1.0

```

Figura A. 49-Resultados Chow Test Odlo

Fonte: elaboração própria

```

Período: Total
  df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      287.0  0.020203      0.0      NaN      NaN      NaN
1      233.0  0.023155      54.0 -0.002952 -0.550155      1.0
Período: 1 semana
  df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      294.0  0.021391      0.0      NaN      NaN      NaN
1      240.0  0.023750      54.0 -0.002359 -0.441475      1.0
Período: 2 semanas
  df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      301.0  0.022333      0.0      NaN      NaN      NaN
1      247.0  0.024169      54.0 -0.001837 -0.347598      1.0
Período: 3 semanas
  df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      308.0  0.022679      0.0      NaN      NaN      NaN
1      254.0  0.024990      54.0 -0.002311 -0.434956      1.0
Período: 1 mês
  df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      315.0  0.023344      0.0      NaN      NaN      NaN
1      261.0  0.026445      54.0 -0.003102 -0.566879      1.0
Período: 2 meses
  df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      343.0  0.026902      0.0      NaN      NaN      NaN
1      289.0  0.028716      54.0 -0.001814 -0.338081      1.0
Período: 4 meses
  df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      399.0  0.034958      0.0      NaN      NaN      NaN
1      345.0  0.033627      54.0  0.00133  0.252766      1.0

```

Figura A. 50-Resultados Chow Test Okea

Fonte: elaboração própria



```

Período: Total
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      287.0  0.022904      0.0      NaN      NaN      NaN
1      233.0  0.033870     54.0 -0.010966 -1.396978      1.0
Período: 1 semana
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      294.0  0.024183      0.0      NaN      NaN      NaN
1      240.0  0.034173     54.0 -0.009999 -1.299297      1.0
Período: 2 semanas
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      301.0  0.025202      0.0      NaN      NaN      NaN
1      247.0  0.034765     54.0 -0.009563 -1.25818      1.0
Período: 3 semanas
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      308.0  0.025911      0.0      NaN      NaN      NaN
1      254.0  0.035216     54.0 -0.009305 -1.242873      1.0
Período: 1 mês
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      315.0  0.026703      0.0      NaN      NaN      NaN
1      261.0  0.037773     54.0 -0.011069 -1.416419      1.0
Período: 2 meses
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      343.0  0.031653      0.0      NaN      NaN      NaN
1      289.0  0.040557     54.0 -0.008903 -1.174884      1.0
Período: 4 meses
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      399.0  0.043043      0.0      NaN      NaN      NaN
1      345.0  0.045038     54.0 -0.001995 -0.282951      1.0

```

Figura A. 51-Resultados Chow Test Osun

Fonte: elaboração própria

```

Período: Total
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      275.0  0.021600      0.0      NaN      NaN      NaN
1      232.0  0.033394     43.0 -0.011794 -1.905469      1.0
Período: 1 semana
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      282.0  0.022797      0.0      NaN      NaN      NaN
1      239.0  0.033791     43.0 -0.010995 -1.808434      1.0
Período: 2 semanas
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      289.0  0.023893      0.0      NaN      NaN      NaN
1      246.0  0.034145     43.0 -0.010252 -1.717709      1.0
Período: 3 semanas
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      296.0  0.024803      0.0      NaN      NaN      NaN
1      253.0  0.035527     43.0 -0.010724 -1.776035      1.0
Período: 1 mês
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      303.0  0.025124      0.0      NaN      NaN      NaN
1      260.0  0.037088     43.0 -0.011964 -1.950542      1.0
Período: 2 meses
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      331.0  0.03014      0.0      NaN      NaN      NaN
1      288.0  0.03987     43.0 -0.009729 -1.634412      1.0
Período: 4 meses
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      387.0  0.041688      0.0      NaN      NaN      NaN
1      344.0  0.043984     43.0 -0.002297 -0.417716      1.0

```

Figura A. 52-Resultados Chow Test Ots

Fonte: elaboração própria

```

Período: Total
  df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      287.0  0.021243      0.0      NaN      NaN      NaN
1      233.0  0.030604     54.0 -0.009362 -1.31988      1.0
Período: 1 semana
  df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      294.0  0.022459      0.0      NaN      NaN      NaN
1      240.0  0.030804     54.0 -0.008344 -1.203949      1.0
Período: 2 semanas
  df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      301.0  0.023394      0.0      NaN      NaN      NaN
1      247.0  0.031461     54.0 -0.008067 -1.172795      1.0
Período: 3 semanas
  df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      308.0  0.023986      0.0      NaN      NaN      NaN
1      254.0  0.033289     54.0 -0.009303 -1.314556      1.0
Período: 1 mês
  df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      315.0  0.024718      0.0      NaN      NaN      NaN
1      261.0  0.035272     54.0 -0.010554 -1.446256      1.0
Período: 2 meses
  df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      343.0  0.029217      0.0      NaN      NaN      NaN
1      289.0  0.038084     54.0 -0.008867 -1.246041      1.0
Período: 4 meses
  df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      399.0  0.040279      0.0      NaN      NaN      NaN
1      345.0  0.041905     54.0 -0.001626 -0.247965      1.0

```

Figura A. 53-Resultados Chow Test Pgs

Fonte: elaboração própria

```

Período: Total
  df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      287.0  0.016955      0.0      NaN      NaN      NaN
1      233.0  0.020593     54.0 -0.003638 -0.762251      1.0
Período: 1 semana
  df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      294.0  0.017961      0.0      NaN      NaN      NaN
1      240.0  0.021139     54.0 -0.003178 -0.668128      1.0
Período: 2 semanas
  df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      301.0  0.018920      0.0      NaN      NaN      NaN
1      247.0  0.021477     54.0 -0.002557 -0.544657      1.0
Período: 3 semanas
  df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      308.0  0.019459      0.0      NaN      NaN      NaN
1      254.0  0.022344     54.0 -0.002885 -0.607408      1.0
Período: 1 mês
  df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      315.0  0.020003      0.0      NaN      NaN      NaN
1      261.0  0.023013     54.0 -0.00301 -0.632208      1.0
Período: 2 meses
  df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      343.0  0.023003      0.0      NaN      NaN      NaN
1      289.0  0.024875     54.0 -0.001873 -0.402917      1.0
Período: 4 meses
  df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      399.0  0.030835      0.0      NaN      NaN      NaN
1      345.0  0.027858     54.0  0.002977  0.682773  0.956018

```

Figura A. 54-Resultados Chow Test Pner

Fonte: elaboração própria

```

Período: Total
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      287.0  0.023234      0.0      NaN      NaN      NaN
1      233.0  0.032280     54.0 -0.009047 -1.209226      1.0
Período: 1 semana
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      294.0  0.024404      0.0      NaN      NaN      NaN
1      240.0  0.032637     54.0 -0.008233 -1.121172      1.0
Período: 2 semanas
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      301.0  0.025451      0.0      NaN      NaN      NaN
1      247.0  0.033150     54.0 -0.007699 -1.062266      1.0
Período: 3 semanas
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      308.0  0.026128      0.0      NaN      NaN      NaN
1      254.0  0.033618     54.0 -0.007491 -1.048055      1.0
Período: 1 mês
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      315.0  0.026871      0.0      NaN      NaN      NaN
1      261.0  0.035636     54.0 -0.008765 -1.188792      1.0
Período: 2 meses
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      343.0  0.031807      0.0      NaN      NaN      NaN
1      289.0  0.040555     54.0 -0.008748 -1.154393      1.0
Período: 4 meses
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      399.0  0.043326      0.0      NaN      NaN      NaN
1      345.0  0.044635     54.0 -0.001309 -0.187388      1.0

```

Figura A. 55-Resultados Chow Test Prso

Fonte: elaboração própria

```

Período: Total
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      287.0  0.022609      0.0      NaN      NaN      NaN
1      228.0  0.033295     59.0 -0.010686 -1.240244      1.0
Período: 1 semana
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      294.0  0.023719      0.0      NaN      NaN      NaN
1      235.0  0.033636     59.0 -0.009917 -1.174361      1.0
Período: 2 semanas
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      301.0  0.024586      0.0      NaN      NaN      NaN
1      242.0  0.034227     59.0 -0.009641 -1.155363      1.0
Período: 3 semanas
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      308.0  0.025131      0.0      NaN      NaN      NaN
1      249.0  0.034702     59.0 -0.009571 -1.164029      1.0
Período: 1 mês
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      315.0  0.025906      0.0      NaN      NaN      NaN
1      256.0  0.037011     59.0 -0.011105 -1.301892      1.0
Período: 2 meses
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      343.0  0.030234      0.0      NaN      NaN      NaN
1      284.0  0.039934     59.0 -0.0097 -1.169227      1.0
Período: 4 meses
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      399.0  0.042388      0.0      NaN      NaN      NaN
1      340.0  0.044081     59.0 -0.001693 -0.221368      1.0

```

Figura A. 56-Resultados Chow Test PSE

Fonte: elaboração própria

Período: Total							
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)	
0	287.0	0.022789	0.0	NaN	NaN	NaN	
1	233.0	0.031411	54.0	-0.008622	-1.184357	1.0	
Período: 1 semana							
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)	
0	294.0	0.023996	0.0	NaN	NaN	NaN	
1	240.0	0.032171	54.0	-0.008174	-1.129297	1.0	
Período: 2 semanas							
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)	
0	301.0	0.024980	0.0	NaN	NaN	NaN	
1	247.0	0.032867	54.0	-0.007887	-1.09759	1.0	
Período: 3 semanas							
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)	
0	308.0	0.025637	0.0	NaN	NaN	NaN	
1	254.0	0.033313	54.0	-0.007676	-1.083811	1.0	
Período: 1 mês							
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)	
0	315.0	0.026365	0.0	NaN	NaN	NaN	
1	261.0	0.035589	54.0	-0.009224	-1.252682	1.0	
Período: 2 meses							
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)	
0	343.0	0.030977	0.0	NaN	NaN	NaN	
1	289.0	0.039273	54.0	-0.008296	-1.130489	1.0	
Período: 4 meses							
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)	
0	399.0	0.042119	0.0	NaN	NaN	NaN	
1	345.0	0.043517	54.0	-0.001397	-0.205111	1.0	

Figura A. 57-Resultados Chow Test  $Q_{ec}$

Fonte: elaboração própria

Período: Total							
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)	
0	287.0	0.020873	0.0	NaN	NaN	NaN	
1	233.0	0.031883	54.0	-0.01101	-1.490012	1.0	
Período: 1 semana							
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)	
0	294.0	0.021828	0.0	NaN	NaN	NaN	
1	240.0	0.032254	54.0	-0.010426	-1.436685	1.0	
Período: 2 semanas							
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)	
0	301.0	0.022842	0.0	NaN	NaN	NaN	
1	247.0	0.033373	54.0	-0.010531	-1.443368	1.0	
Período: 3 semanas							
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)	
0	308.0	0.023675	0.0	NaN	NaN	NaN	
1	254.0	0.033890	54.0	-0.010215	-1.417719	1.0	
Período: 1 mês							
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)	
0	315.0	0.024629	0.0	NaN	NaN	NaN	
1	261.0	0.035948	54.0	-0.011319	-1.521869	1.0	
Período: 2 meses							
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)	
0	343.0	0.029392	0.0	NaN	NaN	NaN	
1	289.0	0.038170	54.0	-0.008777	-1.230676	1.0	
Período: 4 meses							
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)	
0	399.0	0.039610	0.0	NaN	NaN	NaN	
1	345.0	0.042118	54.0	-0.002508	-0.380402	1.0	

Figura A. 58-Resultados Chow Test  $Q_{fuel}$

Fonte: elaboração própria

Período: Total						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	287.0	0.021293	0.0	NaN	NaN	NaN
1	233.0	0.031998	54.0	-0.010705	-1.443521	1.0
Período: 1 semana						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	294.0	0.022503	0.0	NaN	NaN	NaN
1	240.0	0.032784	54.0	-0.010281	-1.393817	1.0
Período: 2 semanas						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	301.0	0.023560	0.0	NaN	NaN	NaN
1	247.0	0.033603	54.0	-0.010042	-1.367002	1.0
Período: 3 semanas						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	308.0	0.024346	0.0	NaN	NaN	NaN
1	254.0	0.034245	54.0	-0.009899	-1.359674	1.0
Período: 1 mês						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	315.0	0.025289	0.0	NaN	NaN	NaN
1	261.0	0.035926	54.0	-0.010637	-1.431035	1.0
Período: 2 meses						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	343.0	0.029157	0.0	NaN	NaN	NaN
1	289.0	0.038560	54.0	-0.009404	-1.30516	1.0
Período: 4 meses						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	399.0	0.039873	0.0	NaN	NaN	NaN
1	345.0	0.042523	54.0	-0.00265	-0.398223	1.0

Figura A. 59-Resultados Chow Test Reach

Fonte: elaboração própria

Período: Total						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	287.0	0.016048	0.0	NaN	NaN	NaN
1	233.0	0.023567	54.0	-0.007519	-1.376611	1.0
Período: 1 semana						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	294.0	0.018685	0.0	NaN	NaN	NaN
1	240.0	0.023756	54.0	-0.005072	-0.948799	1.0
Período: 2 semanas						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	301.0	0.019814	0.0	NaN	NaN	NaN
1	247.0	0.024347	54.0	-0.004533	-0.851679	1.0
Período: 3 semanas						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	308.0	0.020233	0.0	NaN	NaN	NaN
1	254.0	0.024881	54.0	-0.004648	-0.878673	1.0
Período: 1 mês						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	315.0	0.020812	0.0	NaN	NaN	NaN
1	261.0	0.025559	54.0	-0.004746	-0.897559	1.0
Período: 2 meses						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	343.0	0.024416	0.0	NaN	NaN	NaN
1	289.0	0.027099	54.0	-0.002683	-0.529911	1.0
Período: 4 meses						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	399.0	0.030626	0.0	NaN	NaN	NaN
1	345.0	0.030317	54.0	0.000309	0.065117	1.0

Figura A. 60-Resultados Chow Test Sbuc

Fonte: elaboração própria

Período: Total						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	287.0	0.023089	0.0	NaN	NaN	NaN
1	233.0	0.031348	54.0	-0.008259	-1.136785	1.0
Período: 1 semana						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	294.0	0.024256	0.0	NaN	NaN	NaN
1	240.0	0.031716	54.0	-0.00746	-1.04534	1.0
Período: 2 semanas						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	301.0	0.025325	0.0	NaN	NaN	NaN
1	247.0	0.032486	54.0	-0.007162	-1.008344	1.0
Período: 3 semanas						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	308.0	0.026005	0.0	NaN	NaN	NaN
1	254.0	0.033072	54.0	-0.007067	-1.005076	1.0
Período: 1 mês						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	315.0	0.02676	0.0	NaN	NaN	NaN
1	261.0	0.03448	54.0	-0.00772	-1.082163	1.0
Período: 2 meses						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	343.0	0.031607	0.0	NaN	NaN	NaN
1	289.0	0.038472	54.0	-0.006865	-0.95499	1.0
Período: 4 meses						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	399.0	0.042386	0.0	NaN	NaN	NaN
1	345.0	0.042762	54.0	-0.000376	-0.056117	1.0

Figura A. 61-Resultados Chow Test Sbx

Fonte: elaboração própria

Período: Total						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	287.0	0.022672	0.0	NaN	NaN	NaN
1	233.0	0.033371	54.0	-0.010699	-1.383408	1.0
Período: 1 semana						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	294.0	0.023640	0.0	NaN	NaN	NaN
1	240.0	0.033694	54.0	-0.010054	-1.326126	1.0
Período: 2 semanas						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	301.0	0.024603	0.0	NaN	NaN	NaN
1	247.0	0.034333	54.0	-0.009729	-1.296238	1.0
Período: 3 semanas						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	308.0	0.025297	0.0	NaN	NaN	NaN
1	254.0	0.034907	54.0	-0.00961	-1.294926	1.0
Período: 1 mês						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	315.0	0.026047	0.0	NaN	NaN	NaN
1	261.0	0.037235	54.0	-0.011188	-1.45228	1.0
Período: 2 meses						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	343.0	0.030933	0.0	NaN	NaN	NaN
1	289.0	0.040133	54.0	-0.0092	-1.22687	1.0
Período: 4 meses						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	399.0	0.042227	0.0	NaN	NaN	NaN
1	345.0	0.044475	54.0	-0.002248	-0.322928	1.0

Figura A. 62-Resultados Chow Test Scana

Fonte: elaboração própria

```

Período: Total
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      287.0  0.019356      0.0      NaN      NaN      NaN
1      233.0  0.029048     54.0 -0.009692 -1.439616      1.0
Período: 1 semana
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      294.0  0.020233      0.0      NaN      NaN      NaN
1      240.0  0.029495     54.0 -0.009262 -1.395688      1.0
Período: 2 semanas
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      301.0  0.021361      0.0      NaN      NaN      NaN
1      247.0  0.029848     54.0 -0.008487 -1.300648      1.0
Período: 3 semanas
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      308.0  0.022067      0.0      NaN      NaN      NaN
1      254.0  0.030264     54.0 -0.008197 -1.274017      1.0
Período: 1 mês
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      315.0  0.022632      0.0      NaN      NaN      NaN
1      261.0  0.031824     54.0 -0.009191 -1.395979      1.0
Período: 2 meses
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      343.0  0.026564      0.0      NaN      NaN      NaN
1      289.0  0.033986     54.0 -0.007422 -1.168806      1.0
Período: 4 meses
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      399.0  0.036158      0.0      NaN      NaN      NaN
1      345.0  0.038419     54.0 -0.002261 -0.375994      1.0

```

Figura A. 63-Resultados Chow Test Scact

Fonte: elaboração própria

```

Período: Total
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      287.0  0.019920      0.0      NaN      NaN      NaN
1      233.0  0.029102     54.0 -0.009182 -1.361424      1.0
Período: 1 semana
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      294.0  0.021281      0.0      NaN      NaN      NaN
1      240.0  0.029729     54.0 -0.008448 -1.262977      1.0
Período: 2 semanas
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      301.0  0.02213      0.0      NaN      NaN      NaN
1      247.0  0.03023     54.0 -0.008099 -1.225524      1.0
Período: 3 semanas
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      308.0  0.022616      0.0      NaN      NaN      NaN
1      254.0  0.030694     54.0 -0.008078 -1.237908      1.0
Período: 1 mês
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      315.0  0.023061      0.0      NaN      NaN      NaN
1      261.0  0.032483     54.0 -0.009422 -1.401977      1.0
Período: 2 meses
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      343.0  0.027988      0.0      NaN      NaN      NaN
1      289.0  0.034648     54.0 -0.00666 -1.028774      1.0
Período: 4 meses
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      399.0  0.036899      0.0      NaN      NaN      NaN
1      345.0  0.038303     54.0 -0.001404 -0.234229      1.0

```

Figura A. 64-Resultados Chow Test Sdsd

Fonte: elaboração própria

```

Período: Total
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      287.0  0.021887      0.0      NaN      NaN      NaN
1      232.0  0.032716     55.0 -0.010828 -1.396147      1.0
Período: 1 semana
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      294.0  0.022423      0.0      NaN      NaN      NaN
1      239.0  0.033023     55.0 -0.010601 -1.394894      1.0
Período: 2 semanas
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      301.0  0.023438      0.0      NaN      NaN      NaN
1      246.0  0.033532     55.0 -0.010094 -1.346351      1.0
Período: 3 semanas
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      308.0  0.02424      0.0      NaN      NaN      NaN
1      253.0  0.03399     55.0 -0.009749 -1.319443      1.0
Período: 1 mês
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      315.0  0.025083      0.0      NaN      NaN      NaN
1      260.0  0.036260     55.0 -0.011177 -1.457131      1.0
Período: 2 meses
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      343.0  0.029099      0.0      NaN      NaN      NaN
1      288.0  0.039023     55.0 -0.009924 -1.331651      1.0
Período: 4 meses
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      399.0  0.040439      0.0      NaN      NaN      NaN
1      344.0  0.042954     55.0 -0.002515 -0.366157      1.0

```

Figura A. 65-Resultados Chow Test Seaw7

Fonte: elaboração própria

```

Período: Total
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      287.0  0.020238      0.0      NaN      NaN      NaN
1      233.0  0.029152     54.0 -0.008914 -1.319366      1.0
Período: 1 semana
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      294.0  0.021327      0.0      NaN      NaN      NaN
1      240.0  0.029487     54.0 -0.00816 -1.229913      1.0
Período: 2 semanas
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      301.0  0.021889      0.0      NaN      NaN      NaN
1      247.0  0.030129     54.0 -0.00824 -1.250956      1.0
Período: 3 semanas
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      308.0  0.022101      0.0      NaN      NaN      NaN
1      254.0  0.030540     54.0 -0.008439 -1.299782      1.0
Período: 1 mês
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      315.0  0.022700      0.0      NaN      NaN      NaN
1      261.0  0.032443     54.0 -0.009743 -1.451505      1.0
Período: 2 meses
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      343.0  0.026990      0.0      NaN      NaN      NaN
1      289.0  0.035007     54.0 -0.008017 -1.225669      1.0
Período: 4 meses
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      399.0  0.036989      0.0      NaN      NaN      NaN
1      345.0  0.038565     54.0 -0.001575 -0.260972      1.0

```

Figura A. 66-Resultados Chow Test Shlf

Fonte: elaboração própria



```

Período: Total
df_resid    ssr  df_diff  ss_diff    F  Pr(>F)
0      287.0  0.023256    0.0      NaN    NaN    NaN
1      233.0  0.028281   54.0 -0.005026 -0.766769  1.0
Período: 1 semana
df_resid    ssr  df_diff  ss_diff    F  Pr(>F)
0      294.0  0.024429    0.0      NaN    NaN    NaN
1      240.0  0.028683   54.0 -0.004254 -0.659195  1.0
Período: 2 semanas
df_resid    ssr  df_diff  ss_diff    F  Pr(>F)
0      301.0  0.025463    0.0      NaN    NaN    NaN
1      247.0  0.029315   54.0 -0.003852 -0.601037  1.0
Período: 3 semanas
df_resid    ssr  df_diff  ss_diff    F  Pr(>F)
0      308.0  0.026148    0.0      NaN    NaN    NaN
1      254.0  0.029709   54.0 -0.003561 -0.563818  1.0
Período: 1 mês
df_resid    ssr  df_diff  ss_diff    F  Pr(>F)
0      315.0  0.026913    0.0      NaN    NaN    NaN
1      261.0  0.031388   54.0 -0.004475 -0.689071  1.0
Período: 2 meses
df_resid    ssr  df_diff  ss_diff    F  Pr(>F)
0      343.0  0.031798    0.0      NaN    NaN    NaN
1      289.0  0.033823   54.0 -0.002025 -0.320412  1.0
Período: 4 meses
df_resid    ssr  df_diff  ss_diff    F  Pr(>F)
0      399.0  0.043178    0.0      NaN    NaN    NaN
1      345.0  0.037734   54.0  0.005444  0.921688  0.632702

```

Figura A. 67-Resultados Chow Test Sioff

Fonte: elaboração própria

```

Período: Total
df_resid    ssr  df_diff  ss_diff    F  Pr(>F)
0      287.0  0.022517    0.0      NaN    NaN    NaN
1      233.0  0.028595   54.0 -0.006078 -0.91714  1.0
Período: 1 semana
df_resid    ssr  df_diff  ss_diff    F  Pr(>F)
0      294.0  0.023874    0.0      NaN    NaN    NaN
1      240.0  0.029395   54.0 -0.005521 -0.83482  1.0
Período: 2 semanas
df_resid    ssr  df_diff  ss_diff    F  Pr(>F)
0      301.0  0.024962    0.0      NaN    NaN    NaN
1      247.0  0.030257   54.0 -0.005296 -0.800567  1.0
Período: 3 semanas
df_resid    ssr  df_diff  ss_diff    F  Pr(>F)
0      308.0  0.025464    0.0      NaN    NaN    NaN
1      254.0  0.030689   54.0 -0.005226 -0.800907  1.0
Período: 1 mês
df_resid    ssr  df_diff  ss_diff    F  Pr(>F)
0      315.0  0.026244    0.0      NaN    NaN    NaN
1      261.0  0.032368   54.0 -0.006124 -0.914414  1.0
Período: 2 meses
df_resid    ssr  df_diff  ss_diff    F  Pr(>F)
0      343.0  0.030538    0.0      NaN    NaN    NaN
1      289.0  0.035357   54.0 -0.004819 -0.72939  1.0
Período: 4 meses
df_resid    ssr  df_diff  ss_diff    F  Pr(>F)
0      399.0  0.040671    0.0      NaN    NaN    NaN
1      345.0  0.039741   54.0  0.00093  0.149458  1.0

```

Figura A. 68-Resultados Chow Test Sioff

Fonte: elaboração própria

```

Período: Total
  df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      287.0  0.021820      0.0      NaN      NaN      NaN
1      233.0  0.034005      54.0 -0.012184 -1.546063      1.0
Período: 1 semana
  df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      294.0  0.023003      0.0      NaN      NaN      NaN
1      240.0  0.034331      54.0 -0.011328 -1.466534      1.0
Período: 2 semanas
  df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      301.0  0.023937      0.0      NaN      NaN      NaN
1      247.0  0.034868      54.0 -0.010931 -1.433929      1.0
Período: 3 semanas
  df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      308.0  0.024698      0.0      NaN      NaN      NaN
1      254.0  0.035321      54.0 -0.010622 -1.414602      1.0
Período: 1 mês
  df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      315.0  0.025562      0.0      NaN      NaN      NaN
1      261.0  0.037384      54.0 -0.011822 -1.528437      1.0
Período: 2 meses
  df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      343.0  0.030049      0.0      NaN      NaN      NaN
1      289.0  0.040435      54.0 -0.010386 -1.374681      1.0
Período: 4 meses
  df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      399.0  0.041115      0.0      NaN      NaN      NaN
1      345.0  0.044444      54.0 -0.003329 -0.478478      1.0

```

Figura A. 69-Resultados Chow Test Teco

Fonte: elaboração própria

```

Período: Total
  df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      287.0  0.018184      0.0      NaN      NaN      NaN
1      233.0  0.024311      54.0 -0.006126 -1.087349      1.0
Período: 1 semana
  df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      294.0  0.019485      0.0      NaN      NaN      NaN
1      240.0  0.024586      54.0 -0.005101 -0.922193      1.0
Período: 2 semanas
  df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      301.0  0.020502      0.0      NaN      NaN      NaN
1      247.0  0.025396      54.0 -0.004894 -0.88147      1.0
Período: 3 semanas
  df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      308.0  0.020819      0.0      NaN      NaN      NaN
1      254.0  0.025768      54.0 -0.004949 -0.903408      1.0
Período: 1 mês
  df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      315.0  0.021452      0.0      NaN      NaN      NaN
1      261.0  0.026896      54.0 -0.005444 -0.978306      1.0
Período: 2 meses
  df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      343.0  0.025083      0.0      NaN      NaN      NaN
1      289.0  0.030300      54.0 -0.005217 -0.92142      1.0
Período: 4 meses
  df_resid      ssr df_diff  ss_diff      F Pr(>F)
0      399.0  0.033277      0.0      NaN      NaN      NaN
1      345.0  0.033053      54.0  0.000224  0.043293      1.0

```

Figura A. 70-Resultados Chow Test Tgs

Fonte: elaboração própria

```

Período: Total
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      287.0  0.022743      0.0      NaN      NaN      NaN
1      233.0  0.033192     54.0 -0.010449 -1.358321  1.0
Período: 1 semana
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      294.0  0.024030      0.0      NaN      NaN      NaN
1      240.0  0.033537     54.0 -0.009507 -1.259842  1.0
Período: 2 semanas
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      301.0  0.025078      0.0      NaN      NaN      NaN
1      247.0  0.034193     54.0 -0.009115 -1.219286  1.0
Período: 3 semanas
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      308.0  0.025707      0.0      NaN      NaN      NaN
1      254.0  0.034663     54.0 -0.008956 -1.215295  1.0
Período: 1 mês
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      315.0  0.026447      0.0      NaN      NaN      NaN
1      261.0  0.036716     54.0 -0.010269 -1.351843  1.0
Período: 2 meses
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      343.0  0.030938      0.0      NaN      NaN      NaN
1      289.0  0.039294     54.0 -0.008355 -1.138016  1.0
Período: 4 meses
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      399.0  0.042639      0.0      NaN      NaN      NaN
1      345.0  0.043453     54.0 -0.008814 -0.11969   1.0

```

Figura A. 71-Resultados Chow Test Zena

Fonte: elaboração própria

```

Período: Total
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      292.0  0.027037      0.0      NaN      NaN      NaN
1      237.0  0.044547     55.0 -0.01751  -1.693766  1.0
Período: 1 semana
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      299.0  0.033193      0.0      NaN      NaN      NaN
1      244.0  0.046388     55.0 -0.013195 -1.26191   1.0
Período: 2 semanas
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      306.0  0.040736      0.0      NaN      NaN      NaN
1      251.0  0.047793     55.0 -0.007057 -0.673883  1.0
Período: 3 semanas
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      313.0  0.041049      0.0      NaN      NaN      NaN
1      258.0  0.048302     55.0 -0.007252 -0.704319  1.0
Período: 1 mês
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      320.0  0.042395      0.0      NaN      NaN      NaN
1      265.0  0.050712     55.0 -0.008317 -0.79018   1.0
Período: 2 meses
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      348.0  0.047930      0.0      NaN      NaN      NaN
1      293.0  0.052982     55.0 -0.005052 -0.507975  1.0
Período: 4 meses
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      404.0  0.057507      0.0      NaN      NaN      NaN
1      349.0  0.060057     55.0 -0.00255  -0.269425  1.0

```

Figura A. 72-Resultados Chow Test Akmet

Fonte: elaboração própria

```

Período: Total
df_resid    ssr df_diff  ss_diff      F Pr(>F)
0      292.0  0.025716      0.0      NaN      NaN      NaN
1      237.0  0.043554     55.0 -0.017839 -1.764882    1.0
Período: 1 semana
df_resid    ssr df_diff  ss_diff      F Pr(>F)
0      299.0  0.033162      0.0      NaN      NaN      NaN
1      244.0  0.045200     55.0 -0.012038 -1.1815     1.0
Período: 2 semanas
df_resid    ssr df_diff  ss_diff      F Pr(>F)
0      306.0  0.039421      0.0      NaN      NaN      NaN
1      251.0  0.046532     55.0 -0.00711  -0.697342    1.0
Período: 3 semanas
df_resid    ssr df_diff  ss_diff      F Pr(>F)
0      313.0  0.039753      0.0      NaN      NaN      NaN
1      258.0  0.047122     55.0 -0.00737  -0.733623    1.0
Período: 1 mês
df_resid    ssr df_diff  ss_diff      F Pr(>F)
0      320.0  0.041082      0.0      NaN      NaN      NaN
1      265.0  0.049637     55.0 -0.008556 -0.830485    1.0
Período: 2 meses
df_resid    ssr df_diff  ss_diff      F Pr(>F)
0      348.0  0.046602      0.0      NaN      NaN      NaN
1      293.0  0.051890     55.0 -0.005288 -0.542881    1.0
Período: 4 meses
df_resid    ssr df_diff  ss_diff      F Pr(>F)
0      404.0  0.055412      0.0      NaN      NaN      NaN
1      349.0  0.058575     55.0 -0.003163 -0.342616    1.0

```

Figura A. 73-Resultados Chow Test Alagp

Fonte: elaboração própria

```

Período: Total
df_resid    ssr df_diff  ss_diff      F Pr(>F)
0      292.0  0.026346      0.0      NaN      NaN      NaN
1      234.0  0.041497     58.0 -0.015151 -1.47306     1.0
Período: 1 semana
df_resid    ssr df_diff  ss_diff      F Pr(>F)
0      299.0  0.031131      0.0      NaN      NaN      NaN
1      241.0  0.042576     58.0 -0.011445 -1.116969    1.0
Período: 2 semanas
df_resid    ssr df_diff  ss_diff      F Pr(>F)
0      306.0  0.037196      0.0      NaN      NaN      NaN
1      248.0  0.044523     58.0 -0.007327 -0.703628    1.0
Período: 3 semanas
df_resid    ssr df_diff  ss_diff      F Pr(>F)
0      313.0  0.037629      0.0      NaN      NaN      NaN
1      255.0  0.045017     58.0 -0.007388 -0.721528    1.0
Período: 1 mês
df_resid    ssr df_diff  ss_diff      F Pr(>F)
0      320.0  0.038784      0.0      NaN      NaN      NaN
1      262.0  0.046878     58.0 -0.008094 -0.779929    1.0
Período: 2 meses
df_resid    ssr df_diff  ss_diff      F Pr(>F)
0      348.0  0.043960      0.0      NaN      NaN      NaN
1      290.0  0.049054     58.0 -0.005094 -0.5192     1.0
Período: 4 meses
df_resid    ssr df_diff  ss_diff      F Pr(>F)
0      404.0  0.053573      0.0      NaN      NaN      NaN
1      346.0  0.056440     58.0 -0.002868 -0.303099    1.0

```

Figura A. 74-Resultados Chow Test Albud

Fonte: elaboração própria

Período: Total						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	292.0	0.026137	0.0	NaN	NaN	NaN
1	237.0	0.044596	55.0	-0.018459	-1.78358	1.0
Período: 1 semana						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	299.0	0.032079	0.0	NaN	NaN	NaN
1	244.0	0.046517	55.0	-0.014438	-1.376992	1.0
Período: 2 semanas						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	306.0	0.038308	0.0	NaN	NaN	NaN
1	251.0	0.047871	55.0	-0.009563	-0.911669	1.0
Período: 3 semanas						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	313.0	0.038950	0.0	NaN	NaN	NaN
1	258.0	0.048504	55.0	-0.009553	-0.923934	1.0
Período: 1 mês						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	320.0	0.040314	0.0	NaN	NaN	NaN
1	265.0	0.051009	55.0	-0.010695	-1.010205	1.0
Período: 2 meses						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	348.0	0.044723	0.0	NaN	NaN	NaN
1	293.0	0.053112	55.0	-0.008389	-0.841442	1.0
Período: 4 meses						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	404.0	0.055539	0.0	NaN	NaN	NaN
1	349.0	0.060119	55.0	-0.00458	-0.483382	1.0

Figura A. 75-Resultados Chow Test Aldol

Fonte: elaboração própria

Período: Total						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	292.0	0.024601	0.0	NaN	NaN	NaN
1	237.0	0.040440	55.0	-0.015839	-1.687742	1.0
Período: 1 semana						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	299.0	0.030506	0.0	NaN	NaN	NaN
1	244.0	0.042284	55.0	-0.011778	-1.235759	1.0
Período: 2 semanas						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	306.0	0.036315	0.0	NaN	NaN	NaN
1	251.0	0.043123	55.0	-0.006807	-0.720395	1.0
Período: 3 semanas						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	313.0	0.036607	0.0	NaN	NaN	NaN
1	258.0	0.043729	55.0	-0.007122	-0.764038	1.0
Período: 1 mês						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	320.0	0.038019	0.0	NaN	NaN	NaN
1	265.0	0.045478	55.0	-0.007458	-0.790186	1.0
Período: 2 meses						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	348.0	0.043214	0.0	NaN	NaN	NaN
1	293.0	0.047243	55.0	-0.004029	-0.454307	1.0
Período: 4 meses						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	404.0	0.051541	0.0	NaN	NaN	NaN
1	349.0	0.053614	55.0	-0.002072	-0.245267	1.0

Figura A. 76-Resultados Chow Test Alene

Fonte: elaboração própria

```

Período: Total
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      292.0  0.027135      0.0      NaN      NaN      NaN
1      237.0  0.044382     55.0 -0.017247 -1.674522      1.0
Período: 1 semana
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      299.0  0.033426      0.0      NaN      NaN      NaN
1      244.0  0.046213     55.0 -0.012787 -1.22752      1.0
Período: 2 semanas
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      306.0  0.040383      0.0      NaN      NaN      NaN
1      251.0  0.047541     55.0 -0.007158 -0.687109      1.0
Período: 3 semanas
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      313.0  0.040793      0.0      NaN      NaN      NaN
1      258.0  0.048111     55.0 -0.007319 -0.713574      1.0
Período: 1 mês
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      320.0  0.042120      0.0      NaN      NaN      NaN
1      265.0  0.050628     55.0 -0.008508 -0.809654      1.0
Período: 2 meses
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      348.0  0.047457      0.0      NaN      NaN      NaN
1      293.0  0.052687     55.0 -0.00523 -0.528777      1.0
Período: 4 meses
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      404.0  0.056941      0.0      NaN      NaN      NaN
1      349.0  0.059793     55.0 -0.002852 -0.302711      1.0

```

Figura A. 77-Resultados Chow Test Aloe2

Fonte: elaboração própria

```

Período: Total
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      292.0  0.026931      0.0      NaN      NaN      NaN
1      237.0  0.043145     55.0 -0.016214 -1.619404      1.0
Período: 1 semana
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      299.0  0.033017      0.0      NaN      NaN      NaN
1      244.0  0.044791     55.0 -0.011774 -1.166183      1.0
Período: 2 semanas
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      306.0  0.040302      0.0      NaN      NaN      NaN
1      251.0  0.046170     55.0 -0.005868 -0.580027      1.0
Período: 3 semanas
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      313.0  0.040870      0.0      NaN      NaN      NaN
1      258.0  0.046715     55.0 -0.005846 -0.586978      1.0
Período: 1 mês
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      320.0  0.042315      0.0      NaN      NaN      NaN
1      265.0  0.048637     55.0 -0.006322 -0.626295      1.0
Período: 2 meses
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      348.0  0.047491      0.0      NaN      NaN      NaN
1      293.0  0.050768     55.0 -0.003277 -0.343893      1.0
Período: 4 meses
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      404.0  0.056665      0.0      NaN      NaN      NaN
1      349.0  0.058051     55.0 -0.001387 -0.151563      1.0

```

Figura A. 78-Resultados Chow Test Alesa

Fonte: elaboração própria

```

Período: Total
df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      292.0  0.025698      0.0      NaN      NaN      NaN
1      237.0  0.041420     55.0 -0.015722 -1.635614      1.0
Período: 1 semana
df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      299.0  0.031365      0.0      NaN      NaN      NaN
1      244.0  0.042373     55.0 -0.011008 -1.15247      1.0
Período: 2 semanas
df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      306.0  0.037925      0.0      NaN      NaN      NaN
1      251.0  0.043508     55.0 -0.005583 -0.585601      1.0
Período: 3 semanas
df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      313.0  0.038344      0.0      NaN      NaN      NaN
1      258.0  0.043866     55.0 -0.005522 -0.590463      1.0
Período: 1 mês
df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      320.0  0.039632      0.0      NaN      NaN      NaN
1      265.0  0.045684     55.0 -0.006051 -0.638203      1.0
Período: 2 meses
df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      348.0  0.044488      0.0      NaN      NaN      NaN
1      293.0  0.048210     55.0 -0.003722 -0.411302      1.0
Período: 4 meses
df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      404.0  0.053482      0.0      NaN      NaN      NaN
1      349.0  0.056216     55.0 -0.002735 -0.308681      1.0

```

Figura A. 79-Resultados Chow Test Algbe

Fonte: elaboração própria

```

Período: Total
df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      292.0  0.026240      0.0      NaN      NaN      NaN
1      236.0  0.044554     56.0 -0.018314 -1.732267      1.0
Período: 1 semana
df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      299.0  0.032039      0.0      NaN      NaN      NaN
1      243.0  0.046522     56.0 -0.014484 -1.350931      1.0
Período: 2 semanas
df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      306.0  0.038028      0.0      NaN      NaN      NaN
1      250.0  0.047840     56.0 -0.009812 -0.915629      1.0
Período: 3 semanas
df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      313.0  0.038455      0.0      NaN      NaN      NaN
1      257.0  0.048455     56.0 -0.01 -0.947113      1.0
Período: 1 mês
df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      320.0  0.039959      0.0      NaN      NaN      NaN
1      264.0  0.050972     56.0 -0.011013 -1.018597      1.0
Período: 2 meses
df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      348.0  0.045976      0.0      NaN      NaN      NaN
1      292.0  0.053111     56.0 -0.007135 -0.70048      1.0
Período: 4 meses
df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      404.0  0.054655      0.0      NaN      NaN      NaN
1      348.0  0.060132     56.0 -0.005477 -0.565992      1.0

```

Figura A. 80-Resultados Chow Test Alver

Fonte: elaboração própria

```

Período: Total
df_resid    ssr    df_diff    ss_diff    F    Pr(>F)
0    292.0    0.027464    0.0    NaN    NaN    NaN
1    237.0    0.043833    55.0    -0.016369    -1.609216    1.0
Período: 1 semana
df_resid    ssr    df_diff    ss_diff    F    Pr(>F)
0    299.0    0.033891    0.0    NaN    NaN    NaN
1    244.0    0.046027    55.0    -0.012136    -1.169714    1.0
Período: 2 semanas
df_resid    ssr    df_diff    ss_diff    F    Pr(>F)
0    306.0    0.040966    0.0    NaN    NaN    NaN
1    251.0    0.047350    55.0    -0.006384    -0.615256    1.0
Período: 3 semanas
df_resid    ssr    df_diff    ss_diff    F    Pr(>F)
0    313.0    0.041347    0.0    NaN    NaN    NaN
1    258.0    0.048085    55.0    -0.006737    -0.657245    1.0
Período: 1 mês
df_resid    ssr    df_diff    ss_diff    F    Pr(>F)
0    320.0    0.042726    0.0    NaN    NaN    NaN
1    265.0    0.050514    55.0    -0.007788    -0.74286    1.0
Período: 2 meses
df_resid    ssr    df_diff    ss_diff    F    Pr(>F)
0    348.0    0.048078    0.0    NaN    NaN    NaN
1    293.0    0.052618    55.0    -0.004539    -0.459588    1.0
Período: 4 meses
df_resid    ssr    df_diff    ss_diff    F    Pr(>F)
0    404.0    0.057401    0.0    NaN    NaN    NaN
1    349.0    0.059893    55.0    -0.002493    -0.264075    1.0

```

Figura A. 81-Resultados Chow Test Auer

Fonte: elaboração própria

```

Período: Total
df_resid    ssr    df_diff    ss_diff    F    Pr(>F)
0    292.0    0.026007    0.0    NaN    NaN    NaN
1    237.0    0.035223    55.0    -0.009216    -1.127446    1.0
Período: 1 semana
df_resid    ssr    df_diff    ss_diff    F    Pr(>F)
0    299.0    0.031145    0.0    NaN    NaN    NaN
1    244.0    0.035940    55.0    -0.004796    -0.591967    1.0
Período: 2 semanas
df_resid    ssr    df_diff    ss_diff    F    Pr(>F)
0    306.0    0.036728    0.0    NaN    NaN    NaN
1    251.0    0.036816    55.0    -0.000088    -0.01087    1.0
Período: 3 semanas
df_resid    ssr    df_diff    ss_diff    F    Pr(>F)
0    313.0    0.037096    0.0    NaN    NaN    NaN
1    258.0    0.037228    55.0    -0.000132    -0.016642    1.0
Período: 1 mês
df_resid    ssr    df_diff    ss_diff    F    Pr(>F)
0    320.0    0.03817    0.0    NaN    NaN    NaN
1    265.0    0.03806    55.0    0.00011    0.013936    1.0
Período: 2 meses
df_resid    ssr    df_diff    ss_diff    F    Pr(>F)
0    348.0    0.042935    0.0    NaN    NaN    NaN
1    293.0    0.040287    55.0    0.002648    0.350196    0.999995
Período: 4 meses
df_resid    ssr    df_diff    ss_diff    F    Pr(>F)
0    404.0    0.050538    0.0    NaN    NaN    NaN
1    349.0    0.049223    55.0    0.001315    0.169557    1.0

```

Figura A. 82-Resultados Chow Test Cche

Fonte: elaboração própria



```

Período: Total
df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      292.0  0.020416      0.0      NaN      NaN      NaN
1      237.0  0.021512     55.0 -0.001096 -0.219604      1.0
Período: 1 semana
df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      299.0  0.023364      0.0      NaN      NaN      NaN
1      244.0  0.022184     55.0  0.00118  0.235901      1.0
Período: 2 semanas
df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      306.0  0.026908      0.0      NaN      NaN      NaN
1      251.0  0.022787     55.0  0.004122  0.825448  0.801087
Período: 3 semanas
df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      313.0  0.02718      0.0      NaN      NaN      NaN
1      258.0  0.02314     55.0  0.00404  0.81905  0.811234
Período: 1 mês
df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      320.0  0.027846      0.0      NaN      NaN      NaN
1      265.0  0.023907     55.0  0.00394  0.793998  0.847314
Período: 2 meses
df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      348.0  0.030793      0.0      NaN      NaN      NaN
1      293.0  0.026171     55.0  0.004622  0.940835  0.596155
Período: 4 meses
df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      404.0  0.035964      0.0      NaN      NaN      NaN
1      349.0  0.030527     55.0  0.005436  1.130026  0.256754

```

Figura A. 83-Resultados Chow Test Dbg

Fonte: elaboração própria

```

Período: Total
df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      292.0  0.024798      0.0      NaN      NaN      NaN
1      233.0  0.035940     59.0 -0.011142 -1.224319      1.0
Período: 1 semana
df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      299.0  0.030194      0.0      NaN      NaN      NaN
1      240.0  0.036907     59.0 -0.006713 -0.739841      1.0
Período: 2 semanas
df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      306.0  0.035925      0.0      NaN      NaN      NaN
1      247.0  0.037350     59.0 -0.001425 -0.159671      1.0
Período: 3 semanas
df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      313.0  0.036084      0.0      NaN      NaN      NaN
1      254.0  0.038034     59.0 -0.00195 -0.220674      1.0
Período: 1 mês
df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      320.0  0.037031      0.0      NaN      NaN      NaN
1      261.0  0.040392     59.0 -0.003361 -0.368075      1.0
Período: 2 meses
df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      348.0  0.041574      0.0      NaN      NaN      NaN
1      289.0  0.045721     59.0 -0.004147 -0.444246      1.0
Período: 4 meses
df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      404.0  0.048170      0.0      NaN      NaN      NaN
1      345.0  0.051455     59.0 -0.003284 -0.373229      1.0

```

Figura A. 84-Resultados Chow Test Edf

Fonte: elaboração própria

```

Período: Total
df_resid    ssr  df_diff  ss_diff      F  Pr(>F)
0    287.0  0.026875    0.0      NaN      NaN      NaN
1    235.0  0.043860    52.0 -0.016985 -1.750135    1.0
Período: 1 semana
df_resid    ssr  df_diff  ss_diff      F  Pr(>F)
0    294.0  0.032967    0.0      NaN      NaN      NaN
1    242.0  0.045718    52.0 -0.012751 -1.298006    1.0
Período: 2 semanas
df_resid    ssr  df_diff  ss_diff      F  Pr(>F)
0    301.0  0.039690    0.0      NaN      NaN      NaN
1    249.0  0.047005    52.0 -0.007315 -0.745224    1.0
Período: 3 semanas
df_resid    ssr  df_diff  ss_diff      F  Pr(>F)
0    308.0  0.039979    0.0      NaN      NaN      NaN
1    256.0  0.047659    52.0 -0.00768  -0.793295    1.0
Período: 1 mês
df_resid    ssr  df_diff  ss_diff      F  Pr(>F)
0    315.0  0.041355    0.0      NaN      NaN      NaN
1    263.0  0.050150    52.0 -0.008795 -0.887001    1.0
Período: 2 meses
df_resid    ssr  df_diff  ss_diff      F  Pr(>F)
0    343.0  0.046312    0.0      NaN      NaN      NaN
1    291.0  0.052201    52.0 -0.005889 -0.631318    1.0
Período: 4 meses
df_resid    ssr  df_diff  ss_diff      F  Pr(>F)
0    399.0  0.056179    0.0      NaN      NaN      NaN
1    347.0  0.059696    52.0 -0.003517 -0.393121    1.0

```

Figura A. 85-Resultados Chow Test Edsp

Fonte: elaboração própria

```

Período: Total
df_resid    ssr  df_diff  ss_diff      F  Pr(>F)
0    292.0  0.026398    0.0      NaN      NaN      NaN
1    237.0  0.044642    55.0 -0.018244 -1.761017    1.0
Período: 1 semana
df_resid    ssr  df_diff  ss_diff      F  Pr(>F)
0    299.0  0.032995    0.0      NaN      NaN      NaN
1    244.0  0.046650    55.0 -0.013655 -1.298559    1.0
Período: 2 semanas
df_resid    ssr  df_diff  ss_diff      F  Pr(>F)
0    306.0  0.040991    0.0      NaN      NaN      NaN
1    251.0  0.047966    55.0 -0.006975 -0.663629    1.0
Período: 3 semanas
df_resid    ssr  df_diff  ss_diff      F  Pr(>F)
0    313.0  0.041360    0.0      NaN      NaN      NaN
1    258.0  0.048593    55.0 -0.007234 -0.698289    1.0
Período: 1 mês
df_resid    ssr  df_diff  ss_diff      F  Pr(>F)
0    320.0  0.042798    0.0      NaN      NaN      NaN
1    265.0  0.051121    55.0 -0.008323 -0.784425    1.0
Período: 2 meses
df_resid    ssr  df_diff  ss_diff      F  Pr(>F)
0    348.0  0.048065    0.0      NaN      NaN      NaN
1    293.0  0.053266    55.0 -0.005201 -0.520182    1.0
Período: 4 meses
df_resid    ssr  df_diff  ss_diff      F  Pr(>F)
0    404.0  0.056860    0.0      NaN      NaN      NaN
1    349.0  0.060185    55.0 -0.003326 -0.350622    1.0

```

Figura A. 86-Resultados Chow Test Egab

Fonte: elaboração própria

```

Período: Total
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      292.0  0.020690      0.0      NaN      NaN      NaN
1      237.0  0.028276     55.0 -0.007586 -1.156111     1.0
Período: 1 semana
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      299.0  0.022931      0.0      NaN      NaN      NaN
1      244.0  0.029076     55.0 -0.006145 -0.937615     1.0
Período: 2 semanas
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      306.0  0.026228      0.0      NaN      NaN      NaN
1      251.0  0.030285     55.0 -0.004057 -0.611345     1.0
Período: 3 semanas
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      313.0  0.026338      0.0      NaN      NaN      NaN
1      258.0  0.030978     55.0 -0.00464 -0.702683     1.0
Período: 1 mês
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      320.0  0.026947      0.0      NaN      NaN      NaN
1      265.0  0.032438     55.0 -0.005491 -0.8156     1.0
Período: 2 meses
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      348.0  0.030129      0.0      NaN      NaN      NaN
1      293.0  0.034070     55.0 -0.003941 -0.616152     1.0
Período: 4 meses
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      404.0  0.037266      0.0      NaN      NaN      NaN
1      349.0  0.039050     55.0 -0.001783 -0.289778     1.0

```

Figura A. 87-Resultados Chow Test Engie

Fonte: elaboração própria

```

Período: Total
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      292.0  0.027038      0.0      NaN      NaN      NaN
1      237.0  0.043918     55.0 -0.01688 -1.656208     1.0
Período: 1 semana
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      299.0  0.033796      0.0      NaN      NaN      NaN
1      244.0  0.045798     55.0 -0.012002 -1.162631     1.0
Período: 2 semanas
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      306.0  0.041227      0.0      NaN      NaN      NaN
1      251.0  0.047016     55.0 -0.005789 -0.561954     1.0
Período: 3 semanas
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      313.0  0.041565      0.0      NaN      NaN      NaN
1      258.0  0.047732     55.0 -0.006167 -0.606094     1.0
Período: 1 mês
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      320.0  0.042922      0.0      NaN      NaN      NaN
1      265.0  0.050340     55.0 -0.007418 -0.709998     1.0
Período: 2 meses
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      348.0  0.048172      0.0      NaN      NaN      NaN
1      293.0  0.052414     55.0 -0.004241 -0.431089     1.0
Período: 4 meses
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      404.0  0.057209      0.0      NaN      NaN      NaN
1      349.0  0.059545     55.0 -0.002335 -0.248883     1.0

```

Figura A. 88-Resultados Chow Test Essf

Fonte: elaboração própria

```

Período: Total
  df_resid    ssr  df_diff  ss_diff      F  Pr(>F)
0      292.0  0.026850      0.0      NaN      NaN      NaN
1      237.0  0.043327     55.0 -0.016477 -1.638745     1.0
Período: 1 semana
  df_resid    ssr  df_diff  ss_diff      F  Pr(>F)
0      299.0  0.033170      0.0      NaN      NaN      NaN
1      244.0  0.045441     55.0 -0.012272 -1.198056     1.0
Período: 2 semanas
  df_resid    ssr  df_diff  ss_diff      F  Pr(>F)
0      306.0  0.040714      0.0      NaN      NaN      NaN
1      251.0  0.046535     55.0 -0.00582  -0.570786     1.0
Período: 3 semanas
  df_resid    ssr  df_diff  ss_diff      F  Pr(>F)
0      313.0  0.041058      0.0      NaN      NaN      NaN
1      258.0  0.047222     55.0 -0.006163 -0.612254     1.0
Período: 1 mês
  df_resid    ssr  df_diff  ss_diff      F  Pr(>F)
0      320.0  0.042575      0.0      NaN      NaN      NaN
1      265.0  0.049626     55.0 -0.007051 -0.684613     1.0
Período: 2 meses
  df_resid    ssr  df_diff  ss_diff      F  Pr(>F)
0      348.0  0.047426      0.0      NaN      NaN      NaN
1      293.0  0.051560     55.0 -0.004134 -0.427151     1.0
Período: 4 meses
  df_resid    ssr  df_diff  ss_diff      F  Pr(>F)
0      404.0  0.056054      0.0      NaN      NaN      NaN
1      349.0  0.058794     55.0 -0.002741 -0.29581     1.0

```

Figura A. 89-Resultados Chow Test Fdel

Fonte: elaboração própria

```

Período: Total
  df_resid    ssr  df_diff  ss_diff      F  Pr(>F)
0      292.0  0.024123      0.0      NaN      NaN      NaN
1      237.0  0.042455     55.0 -0.018332 -1.860683     1.0
Período: 1 semana
  df_resid    ssr  df_diff  ss_diff      F  Pr(>F)
0      299.0  0.030767      0.0      NaN      NaN      NaN
1      244.0  0.044322     55.0 -0.013556 -1.356843     1.0
Período: 2 semanas
  df_resid    ssr  df_diff  ss_diff      F  Pr(>F)
0      306.0  0.038704      0.0      NaN      NaN      NaN
1      251.0  0.045711     55.0 -0.007007 -0.699573     1.0
Período: 3 semanas
  df_resid    ssr  df_diff  ss_diff      F  Pr(>F)
0      313.0  0.039259      0.0      NaN      NaN      NaN
1      258.0  0.046225     55.0 -0.006966 -0.706871     1.0
Período: 1 mês
  df_resid    ssr  df_diff  ss_diff      F  Pr(>F)
0      320.0  0.040830      0.0      NaN      NaN      NaN
1      265.0  0.048009     55.0 -0.007178 -0.720436     1.0
Período: 2 meses
  df_resid    ssr  df_diff  ss_diff      F  Pr(>F)
0      348.0  0.045707      0.0      NaN      NaN      NaN
1      293.0  0.049896     55.0 -0.004189 -0.447298     1.0
Período: 4 meses
  df_resid    ssr  df_diff  ss_diff      F  Pr(>F)
0      404.0  0.053641      0.0      NaN      NaN      NaN
1      349.0  0.056698     55.0 -0.003057 -0.342115     1.0

```

Figura A. 90-Resultados Chow Test Geph

Fonte: elaboração própria

Período: Total						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	292.0	0.026980	0.0	NaN	NaN	NaN
1	237.0	0.044253	55.0	-0.017274	-1.681985	1.0
Período: 1 semana						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	299.0	0.032570	0.0	NaN	NaN	NaN
1	244.0	0.045816	55.0	-0.013246	-1.282639	1.0
Período: 2 semanas						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	306.0	0.040005	0.0	NaN	NaN	NaN
1	251.0	0.046770	55.0	-0.006765	-0.660092	1.0
Período: 3 semanas						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	313.0	0.040361	0.0	NaN	NaN	NaN
1	258.0	0.047350	55.0	-0.00699	-0.692443	1.0
Período: 1 mês						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	320.0	0.041630	0.0	NaN	NaN	NaN
1	265.0	0.049919	55.0	-0.008289	-0.800042	1.0
Período: 2 meses						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	348.0	0.046781	0.0	NaN	NaN	NaN
1	293.0	0.052362	55.0	-0.005582	-0.56786	1.0
Período: 4 meses						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	404.0	0.056981	0.0	NaN	NaN	NaN
1	349.0	0.058843	55.0	-0.001862	-0.200824	1.0

Figura A. 91-Resultados Chow Test Gpep

Fonte: elaboração própria

Período: Total						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	292.0	0.024552	0.0	NaN	NaN	NaN
1	237.0	0.043639	55.0	-0.019087	-1.884739	1.0
Período: 1 semana						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	299.0	0.031712	0.0	NaN	NaN	NaN
1	244.0	0.045639	55.0	-0.013927	-1.353789	1.0
Período: 2 semanas						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	306.0	0.038387	0.0	NaN	NaN	NaN
1	251.0	0.046755	55.0	-0.008367	-0.816734	1.0
Período: 3 semanas						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	313.0	0.038754	0.0	NaN	NaN	NaN
1	258.0	0.047330	55.0	-0.008576	-0.850002	1.0
Período: 1 mês						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	320.0	0.040328	0.0	NaN	NaN	NaN
1	265.0	0.049373	55.0	-0.009045	-0.882667	1.0
Período: 2 meses						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	348.0	0.045029	0.0	NaN	NaN	NaN
1	293.0	0.050968	55.0	-0.005939	-0.620706	1.0
Período: 4 meses						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	404.0	0.054702	0.0	NaN	NaN	NaN
1	349.0	0.057558	55.0	-0.002857	-0.314919	1.0

Figura A. 92-Resultados Chow Test Gtt

Fonte: elaboração própria

Período: Total						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	292.0	0.024200	0.0	NaN	NaN	NaN
1	237.0	0.044129	55.0	-0.019929	-1.946027	1.0
Período: 1 semana						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	299.0	0.031527	0.0	NaN	NaN	NaN
1	244.0	0.046226	55.0	-0.0147	-1.410729	1.0
Período: 2 semanas						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	306.0	0.039541	0.0	NaN	NaN	NaN
1	251.0	0.047605	55.0	-0.008065	-0.77311	1.0
Período: 3 semanas						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	313.0	0.040065	0.0	NaN	NaN	NaN
1	258.0	0.048262	55.0	-0.008197	-0.796691	1.0
Período: 1 mês						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	320.0	0.041854	0.0	NaN	NaN	NaN
1	265.0	0.050475	55.0	-0.008622	-0.822986	1.0
Período: 2 meses						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	348.0	0.046809	0.0	NaN	NaN	NaN
1	293.0	0.052413	55.0	-0.005605	-0.569642	1.0
Período: 4 meses						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	404.0	0.055452	0.0	NaN	NaN	NaN
1	349.0	0.058784	55.0	-0.003332	-0.359655	1.0

Figura A. 93-Resultados Chow Test Maup

Fonte: elaboração própria

Período: Total						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	292.0	0.025208	0.0	NaN	NaN	NaN
1	237.0	0.035979	55.0	-0.010771	-1.28996	1.0
Período: 1 semana						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	299.0	0.030781	0.0	NaN	NaN	NaN
1	244.0	0.037973	55.0	-0.007192	-0.840201	1.0
Período: 2 semanas						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	306.0	0.037213	0.0	NaN	NaN	NaN
1	251.0	0.038781	55.0	-0.001568	-0.184459	1.0
Período: 3 semanas						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	313.0	0.037483	0.0	NaN	NaN	NaN
1	258.0	0.039194	55.0	-0.001712	-0.204848	1.0
Período: 1 mês						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	320.0	0.038830	0.0	NaN	NaN	NaN
1	265.0	0.041892	55.0	-0.003062	-0.352225	1.0
Período: 2 meses						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	348.0	0.043120	0.0	NaN	NaN	NaN
1	293.0	0.043403	55.0	-0.000283	-0.03479	1.0
Período: 4 meses						
	df_resid	ssr	df_diff	ss_diff	F	Pr(>F)
0	404.0	0.050524	0.0	NaN	NaN	NaN
1	349.0	0.050480	55.0	0.000043	0.005466	1.0

Figura A. 94-Resultados Chow Test Mcphy

Fonte: elaboração própria

```

Período: Total
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      292.0  0.027589      0.0      NaN      NaN      NaN
1      214.0  0.041271      78.0 -0.013682 -0.909547      1.0
Período: 1 semana
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      299.0  0.033794      0.0      NaN      NaN      NaN
1      221.0  0.043286      78.0 -0.009492 -0.621331      1.0
Período: 2 semanas
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      306.0  0.041227      0.0      NaN      NaN      NaN
1      228.0  0.044627      78.0 -0.0034 -0.222685      1.0
Período: 3 semanas
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      313.0  0.041568      0.0      NaN      NaN      NaN
1      235.0  0.045264      78.0 -0.003696 -0.246018      1.0
Período: 1 mês
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      320.0  0.042942      0.0      NaN      NaN      NaN
1      242.0  0.047834      78.0 -0.004892 -0.317325      1.0
Período: 2 meses
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      348.0  0.048285      0.0      NaN      NaN      NaN
1      270.0  0.049967      78.0 -0.001682 -0.116509      1.0
Período: 4 meses
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      404.0  0.057875      0.0      NaN      NaN      NaN
1      326.0  0.057047      78.0  0.000828  0.060682      1.0

```

Figura A. 95-Resultados Chow Test Mlseq

Fonte: elaboração própria

```

Período: Total
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      292.0  0.026059      0.0      NaN      NaN      NaN
1      237.0  0.042211      55.0 -0.016152 -1.648897      1.0
Período: 1 semana
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      299.0  0.032629      0.0      NaN      NaN      NaN
1      244.0  0.044852      55.0 -0.012224 -1.209065      1.0
Período: 2 semanas
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      306.0  0.040370      0.0      NaN      NaN      NaN
1      251.0  0.045944      55.0 -0.005574 -0.553674      1.0
Período: 3 semanas
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      313.0  0.040676      0.0      NaN      NaN      NaN
1      258.0  0.046307      55.0 -0.005632 -0.570501      1.0
Período: 1 mês
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      320.0  0.042217      0.0      NaN      NaN      NaN
1      265.0  0.047967      55.0 -0.005575 -0.57754      1.0
Período: 2 meses
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      348.0  0.046943      0.0      NaN      NaN      NaN
1      293.0  0.049880      55.0 -0.002937 -0.313644      1.0
Período: 4 meses
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      404.0  0.055823      0.0      NaN      NaN      NaN
1      349.0  0.056127      55.0 -0.000303 -0.034303      1.0

```

Figura A. 96-Resultados Chow Test Neoen

Fonte: elaboração própria

```

Período: Total
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      291.0  0.025826      0.0      NaN      NaN      NaN
1      237.0  0.044005      54.0 -0.018179 -1.813112      1.0
Período: 1 semana
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      298.0  0.031896      0.0      NaN      NaN      NaN
1      244.0  0.045751      54.0 -0.013855 -1.368352      1.0
Período: 2 semanas
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      305.0  0.038986      0.0      NaN      NaN      NaN
1      251.0  0.046866      54.0 -0.007888 -0.781537      1.0
Período: 3 semanas
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      312.0  0.039325      0.0      NaN      NaN      NaN
1      258.0  0.047365      54.0 -0.008004 -0.811021      1.0
Período: 1 mês
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      319.0  0.040809      0.0      NaN      NaN      NaN
1      265.0  0.049644      54.0 -0.008835 -0.873344      1.0
Período: 2 meses
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      347.0  0.046220      0.0      NaN      NaN      NaN
1      293.0  0.051601      54.0 -0.005381 -0.565814      1.0
Período: 4 meses
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      403.0  0.055568      0.0      NaN      NaN      NaN
1      349.0  0.059224      54.0 -0.003656 -0.399004      1.0

```

Figura A. 97-Resultados Chow Test Nhoa

Fonte: elaboração própria

```

Período: Total
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      292.0  0.026644      0.0      NaN      NaN      NaN
1      237.0  0.044367      55.0 -0.017723 -1.721355      1.0
Período: 1 semana
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      299.0  0.032878      0.0      NaN      NaN      NaN
1      244.0  0.046127      55.0 -0.013249 -1.274251      1.0
Período: 2 semanas
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      306.0  0.039743      0.0      NaN      NaN      NaN
1      251.0  0.047510      55.0 -0.007767 -0.746047      1.0
Período: 3 semanas
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      313.0  0.040198      0.0      NaN      NaN      NaN
1      258.0  0.048166      55.0 -0.007968 -0.776023      1.0
Período: 1 mês
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      320.0  0.041624      0.0      NaN      NaN      NaN
1      265.0  0.050203      55.0 -0.008579 -0.823398      1.0
Período: 2 meses
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      348.0  0.047014      0.0      NaN      NaN      NaN
1      293.0  0.052654      55.0 -0.005639 -0.570562      1.0
Período: 4 meses
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      404.0  0.056209      0.0      NaN      NaN      NaN
1      349.0  0.059681      55.0 -0.003472 -0.369166      1.0

```

Figura A. 98-Resultados Chow Test Orege

Fonte: elaboração própria



```

Período: Total
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      292.0  0.021890      0.0      NaN      NaN      NaN
1      237.0  0.042654     55.0 -0.020764 -2.097623      1.0
Período: 1 semana
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      299.0  0.029045      0.0      NaN      NaN      NaN
1      244.0  0.044507     55.0 -0.015462 -1.541199      1.0
Período: 2 semanas
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      306.0  0.037976      0.0      NaN      NaN      NaN
1      251.0  0.045762     55.0 -0.007786 -0.776479      1.0
Período: 3 semanas
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      313.0  0.038525      0.0      NaN      NaN      NaN
1      258.0  0.046348     55.0 -0.007823 -0.791815      1.0
Período: 1 mês
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      320.0  0.040145      0.0      NaN      NaN      NaN
1      265.0  0.048359     55.0 -0.008214 -0.818433      1.0
Período: 2 meses
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      348.0  0.044275      0.0      NaN      NaN      NaN
1      293.0  0.050051     55.0 -0.005776 -0.614815      1.0
Período: 4 meses
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      404.0  0.051643      0.0      NaN      NaN      NaN
1      349.0  0.055859     55.0 -0.004216 -0.478948      1.0

```

Figura A. 99-Resultados Chow Test Slbp

Fonte: elaboração própria

```

Período: Total
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      292.0  0.017913      0.0      NaN      NaN      NaN
1      237.0  0.035636     55.0 -0.017723 -2.143008      1.0
Período: 1 semana
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      299.0  0.021567      0.0      NaN      NaN      NaN
1      244.0  0.036642     55.0 -0.015075 -1.825178      1.0
Período: 2 semanas
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      306.0  0.028237      0.0      NaN      NaN      NaN
1      251.0  0.037596     55.0 -0.009359 -1.136075      1.0
Período: 3 semanas
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      313.0  0.028773      0.0      NaN      NaN      NaN
1      258.0  0.038282     55.0 -0.00951 -1.165258      1.0
Período: 1 mês
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      320.0  0.030844      0.0      NaN      NaN      NaN
1      265.0  0.039548     55.0 -0.008703 -1.060326      1.0
Período: 2 meses
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      348.0  0.033829      0.0      NaN      NaN      NaN
1      293.0  0.041071     55.0 -0.007242 -0.93936      1.0
Período: 4 meses
  df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      404.0  0.040762      0.0      NaN      NaN      NaN
1      349.0  0.046054     55.0 -0.005292 -0.729123      1.0

```

Figura A. 100-Resultados Chow Test Tref

Fonte: elaboração própria

```

Período: Total
df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      292.0  0.020185      0.0      NaN      NaN      NaN
1      237.0  0.016191     55.0  0.003993  1.062707  0.369736
Período: 1 semana
df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      299.0  0.022710      0.0      NaN      NaN      NaN
1      244.0  0.016475     55.0  0.006235  1.679034  0.004327
Período: 2 semanas
df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      306.0  0.024560      0.0      NaN      NaN      NaN
1      251.0  0.017038     55.0  0.007522  2.014792  0.000155
Período: 3 semanas
df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      313.0  0.024803      0.0      NaN      NaN      NaN
1      258.0  0.017410     55.0  0.007393  1.991889  0.000187
Período: 1 mês
df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      320.0  0.025272      0.0      NaN      NaN      NaN
1      265.0  0.018156     55.0  0.007116  1.888426  0.000518
Período: 2 meses
df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      348.0  0.027340      0.0      NaN      NaN      NaN
1      293.0  0.020617     55.0  0.006723  1.737105  0.002079
Período: 4 meses
df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      404.0  0.030769      0.0      NaN      NaN      NaN
1      349.0  0.024917     55.0  0.005851  1.490077  0.018533

```

Figura A. 101-Resultados Chow Test Vie

Fonte: elaboração própria

```

Período: Total
df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      292.0  0.026075      0.0      NaN      NaN      NaN
1      237.0  0.042617     55.0 -0.016542 -1.672588  1.0
Período: 1 semana
df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      299.0  0.032812      0.0      NaN      NaN      NaN
1      244.0  0.044838     55.0 -0.012026 -1.189863  1.0
Período: 2 semanas
df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      306.0  0.039652      0.0      NaN      NaN      NaN
1      251.0  0.045813     55.0 -0.006161 -0.613745  1.0
Período: 3 semanas
df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      313.0  0.040068      0.0      NaN      NaN      NaN
1      258.0  0.046188     55.0 -0.006121 -0.621646  1.0
Período: 1 mês
df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      320.0  0.041534      0.0      NaN      NaN      NaN
1      265.0  0.048418     55.0 -0.006885 -0.685103  1.0
Período: 2 meses
df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      348.0  0.046813      0.0      NaN      NaN      NaN
1      293.0  0.050587     55.0 -0.003774 -0.397478  1.0
Período: 4 meses
df_resid      ssr  df_diff  ss_diff      F  Pr(>F)
0      404.0  0.055845      0.0      NaN      NaN      NaN
1      349.0  0.057307     55.0 -0.001461 -0.161803  1.0

```

Figura A. 102-Resultados Chow Test Vltsa

Fonte: elaboração própria

## Anexo B Medidas de Performance

Tabela B. 1-Medidas de Performance das 102 empresas

Company	City	Csv	Pre Accuracy	Pre Precision (-1)	Pre Recall (-1)	Pre F1-score (-1)	Pre Precision (1)	Pre Recall (1)	Pre F1-score (1)	Pos Accuracy	Pos Precision (-1)	Pos Recall (-1)	Pos F1-score (-1)	Pos Precision (1)	Pos Recall (1)	Pos F1-score (1)
SIF HOLDING	Amsterdam	<a href="#">SIFG</a>	0,45	0,45	1	0,62	0	0	0	0,6	0,6	1	0,75	0	0	0
SBM OFFSHORE	Amsterdam	<a href="#">SBMO</a>	0,45	0,35	1	0,52	1	0,21	0,35	0,37	0,34	1	0,51	1	0,05	0,1
SHELL PLC	Amsterdam	<a href="#">SHEL</a>	0,6	0,56	0,9	0,69	0,75	0,3	0,43	0,7	0,62	0,77	0,69	0,79	0,65	0,71
NEW SOURCES ENERGY	Amsterdam	<a href="#">NSEN</a>	0,44	0,47	0,89	0,62	0	0	0	0,4	0,4	1	0,57	0	0	0
RENEWI	Amsterdam	<a href="#">RWI</a>	0,3	0,24	0,8	0,36	0,67	0,13	0,22	0,47	0,4	0,91	0,56	0,8	0,21	0,33
MARATHON OIL CORP	Brussels	<a href="#">MRO</a>	0,5	0,33	0,11	0,17	0,53	0,82	0,64	0,5	1	0,06	0,12	0,48	1	0,65
OCCIDENTAL PETROL.	Brussels	<a href="#">OXY</a>	0,55	1	0,1	0,18	0,53	1	0,69	0,5	0	0	0	0,5	1	0,67
ENI	Brussels	<a href="#">ENLMI</a>	0,55	0,53	1	0,69	1	0,1	0,18	0,53	0,5	1	0,67	1	0,12	0,22
FLUXYS BELGIUM D	Brussels	<a href="#">FLUX</a>	0,6	0,8	0,36	0,5	0,53	0,89	0,67	0,47	0,48	0,8	0,6	0,4	0,13	0,2
ELIA GROUP	Brussels	<a href="#">ELI</a>	0,55	0	0	0	0,55	1	0,71	0,53	0,38	0,45	0,42	0,65	0,58	0,61
GREENCOAT REN.	Dublin	<a href="#">GRPG</a>	0,6	0,39	0,8	0,5	0,89	0,53	0,67	0,27	0,22	0,86	0,35	0,67	0,09	0,15
GALP ENERGIA-NOM	Lisbon	<a href="#">GALP</a>	0,55	0,33	0,8	0,47	0,88	0,47	0,61	0,53	0,14	0,11	0,12	0,65	0,71	0,68
EDP	Lisbon	<a href="#">EDP</a>	0,45	0,45	1	0,62	0	0	0	0,43	0,31	0,45	0,37	0,57	0,42	0,48
REN	Lisbon	<a href="#">RENE</a>	0,7	0	0	0	0,7	1	0,82	0,7	0	0	0	0,7	1	0,82
EDP RENOVAVEIS	Lisbon	<a href="#">EDPR</a>	0,5	0	0	0	0,56	0,83	0,67	0,57	0,29	0,2	0,24	0,65	0,75	0,7
AKER CARBON CAPTUR	Oslo	<a href="#">ACCA</a>	0,4	0,39	0,88	0,54	0,5	0,08	0,14	0,43	0,43	1	0,6	0	0	0
AGILYX	Oslo	<a href="#">AGLX</a>	0,55	0,55	1	0,71	0	0	0	0,47	0,5	0,88	0,64	0	0	0
AKASTOR	Oslo	<a href="#">AKAST</a>	0,65	0,5	0,14	0,22	0,67	0,92	0,77	0,63	0	0	0	0,66	0,95	0,78
AKER HORIZONS	Oslo	<a href="#">AKH</a>	0,45	0,45	1	0,62	0	0	0	0,57	0,54	0,93	0,68	0,75	0,2	0,32
AKER BP	Oslo	<a href="#">AKRBP</a>	0,75	1	0,17	0,29	0,74	1	0,85	0,67	0,5	0,2	0,29	0,69	0,9	0,78
AKER SOLUTIONS	Oslo	<a href="#">AKSOA</a>	0,7	0,62	0,62	0,62	0,75	0,75	0,75	0,6	1	0,08	0,14	0,59	1	0,74

ARCHER	Oslo	<a href="#">ARCHA</a>	0,55	0,56	0,82	0,67	0,5	0,22	0,31	0,53	0,58	0,83	0,68	0,25	0,08	0,12
AWILCO DRILLING	Oslo	<a href="#">AWDR</a>	0,3	0,32	0,86	0,46	0	0	0	0,43	0,43	1	0,6	0	0	0
BORR DRILLING	Oslo	<a href="#">BORR</a>	0,45	0,45	1	0,62	0	0	0	0,57	0,56	0,67	0,61	0,58	0,47	0,52
BW ENERGY LIMITED	Oslo	<a href="#">BWE</a>	0,5	0,38	0,38	0,38	0,58	0,58	0,58	0,43	0,42	0,85	0,56	0,5	0,12	0,19
BW OFFSHORE LTD	Oslo	<a href="#">BWO</a>	0,65	0,67	0,44	0,53	0,64	0,82	0,72	0,57	0,56	0,6	0,58	0,57	0,53	0,55
CARBON TRANSITION	Oslo	<a href="#">CARBN</a>	0,65	0,38	0,6	0,46	0,83	0,67	0,74	0,5	0,4	0,14	0,21	0,52	0,81	0,63
CLOUDBERRY CLEAN	Oslo	<a href="#">CLOUD</a>	0,5	0,4	0,22	0,29	0,53	0,73	0,62	0,53	0	0	0	0,53	1	0,7
DNO	Oslo	<a href="#">DNO</a>	0,6	0,33	0,14	0,2	0,65	0,85	0,73	0,6	0,55	0,46	0,5	0,63	0,71	0,67
DOF	Oslo	<a href="#">DOF</a>	0,5	0,33	0,11	0,17	0,53	0,82	0,64	0,47	0,48	0,73	0,58	0,43	0,2	0,27
EVERFUEL	Oslo	<a href="#">EFUEL</a>	0,5	0,5	1	0,67	0	0	0	0,53	0,43	0,5	0,46	0,62	0,56	0,59
EIDESVIK OFFSHORE	Oslo	<a href="#">EIOF</a>	0,45	0,4	0,2	0,27	0,47	0,7	0,56	0,5	0,6	0,19	0,29	0,48	0,86	0,62
ELMERA GROUP	Oslo	<a href="#">ELMRA</a>	0,65	0,65	0,92	0,76	0,67	0,25	0,36	0,53	0,54	0,94	0,68	0,5	0,07	0,12
ELECTROMAGNET GEO	Oslo	<a href="#">EMGS</a>	0,6	0,57	0,44	0,5	0,62	0,73	0,67	0,67	0,69	0,69	0,69	0,64	0,64	0,64
EQUINOR	Oslo	<a href="#">EQNR</a>	0,65	0	0	0	0,65	1	0,79	0,43	0,41	0,92	0,56	0,67	0,11	0,19
GOLDEN ENERGY OFF	Oslo	<a href="#">GEOS</a>	0,6	1	0,2	0,33	0,56	1	0,71	0,47	0,67	0,12	0,2	0,44	0,92	0,6
HAVILA SHIPPING	Oslo	<a href="#">HAVI</a>	0,6	0,65	0,85	0,73	0,33	0,14	0,2	0,63	0,64	0,6	0,62	0,62	0,67	0,65
HORISONT ENERGI	Oslo	<a href="#">HRGI</a>	0,7	0	0	0	0,74	0,93	0,82	0,47	0,1	0,12	0,11	0,65	0,59	0,62
HUNTER GROUP	Oslo	<a href="#">HUNT</a>	0,45	0,45	1	0,62	0	0	0	0,43	0,41	1	0,59	1	0,06	0,11
HYDROGENPRO	Oslo	<a href="#">HYPRO</a>	0,45	0,45	1	0,62	0	0	0	0,57	0,55	0,8	0,65	0,62	0,33	0,43
INTEROIL EXPL PROD	Oslo	<a href="#">IOX</a>	0,4	0,4	1	0,57	0	0	0	0,5	0,42	0,14	0,21	0,52	0,81	0,63
MAGNORA	Oslo	<a href="#">MGN</a>	0,35	0,35	1	0,52	0	0	0	0,4	0,41	0,92	0,57	0	0	0
MPC ENERGY SOLUTIO	Oslo	<a href="#">MPCES</a>	0,5	0,5	1	0,67	0	0	0	0,5	0,5	0,93	0,65	0,5	0,07	0,12
NEL	Oslo	<a href="#">NEL</a>	0,45	0,41	0,88	0,56	0,67	0,17	0,27	0,6	0,56	0,64	0,6	0,64	0,56	0,6
NORTHERN DRILLING	Oslo	<a href="#">NODL</a>	0,75	0	0	0	0,75	1	0,86	0,6	0,38	0,56	0,45	0,76	0,62	0,68
NORTHERN OCEAN LTD	Oslo	<a href="#">NOL</a>	0,65	0	0	0	0,68	0,93	0,79	0,67	0	0	0	0,67	1	0,8
NORWEGIAN ENERGY	Oslo	<a href="#">NOR</a>	0,75	0	0	0	0,75	1	0,86	0,43	0	0	0	0,6	0,62	0,6
NORTH ENERGY	Oslo	<a href="#">NORTH</a>	0,35	0,35	1	0,52	0	0	0	0,47	0,32	0,67	0,43	0,73	0,38	0,5
ODFJELL DRILLING	Oslo	<a href="#">ODLO</a>	0,6	0,2	0,2	0,2	0,73	0,73	0,73	0,37	0,34	1	0,51	1	0,05	0,1

OKEA	Oslo	<a href="#">OKEA</a>	0,75	0,5	0,8	0,62	0,92	0,73	0,81	0,73	0,57	0,44	0,5	0,78	0,86	0,82
OCEAN SUN	Oslo	<a href="#">OSUN</a>	0,55	0,55	1	0,71	0	0	0	0,6	0,52	0,92	0,67	0,86	0,35	0,5
OCEANTEAM	Oslo	<a href="#">OTS</a>	0,4	0,39	0,88	0,54	0,5	0,08	0,14	0,4	0,4	1	0,57	0	0	0
PANORO ENERGY	Oslo	<a href="#">PENR</a>	0,35	0,25	0,22	0,24	0,42	0,45	0,43	0,5	0,2	0,08	0,12	0,56	0,78	0,65
PGS	Oslo	<a href="#">PGS</a>	0,6	0,67	0,22	0,33	0,59	0,91	0,71	0,5	0,5	0,93	0,65	0,5	0,07	0,12
PROSAFE	Oslo	<a href="#">PRSO</a>	0,6	0,5	0,25	0,33	0,62	0,83	0,71	0,57	0,44	0,64	0,52	0,71	0,53	0,61
PETROLIA	Oslo	<a href="#">PSE</a>	0,45	0,43	0,67	0,52	0,5	0,27	0,35	0,53	0,54	0,94	0,68	0,5	0,07	0,12
QUESTERRE ENERGY	Oslo	<a href="#">QEC</a>	0,55	0	0	0	0,58	0,92	0,71	0,43	0,45	0,6	0,51	0,4	0,27	0,32
QUANTAFUEL	Oslo	<a href="#">QFUEL</a>	0,4	0,4	1	0,57	0	0	0	0,6	0,52	1	0,68	1	0,29	0,45
REACH SUBSEA	Oslo	<a href="#">REACH</a>	0,6	0	0	0	0,6	1	0,75	0,5	0,42	0,38	0,4	0,56	0,59	0,57
SEABIRD EXPLORAT	Oslo	<a href="#">SBX</a>	0,35	0,37	0,88	0,52	0	0	0	0,5	0	0	0	0,5	1	0,67
SCANA	Oslo	<a href="#">SCANA</a>	0,4	0,33	0,09	0,14	0,41	0,78	0,54	0,53	0,5	0,07	0,12	0,54	0,94	0,68
SCATEC	Oslo	<a href="#">SCATC</a>	0,65	0,64	0,82	0,72	0,67	0,44	0,53	0,53	0,54	0,88	0,67	0,5	0,14	0,22
S.D. STANDARD ETC	Oslo	<a href="#">SDSD</a>	0,7	0	0	0	0,7	1	0,82	0,63	0,4	0,2	0,27	0,68	0,85	0,76
SEAWAY 7	Oslo	<a href="#">SEAW7</a>	0,4	0,37	1	0,54	1	0,08	0,14	0,43	0,43	1	0,6	0	0	0
SHELF DRILLING	Oslo	<a href="#">SHLF</a>	0,45	0,33	0,83	0,48	0,8	0,29	0,42	0,7	0	0	0	0,7	1	0,82
SIEM OFFSHORE	Oslo	<a href="#">SIOFF</a>	0,4	0,42	0,89	0,57	0	0	0	0,53	0,33	0,17	0,22	0,58	0,78	0,67
SOLSTAD OFFSHORE	Oslo	<a href="#">SOFF</a>	0,5	1	0,17	0,29	0,44	1	0,62	0,3	0	0	0	0,36	0,64	0,46
SUBSEA 7	Oslo	<a href="#">SUBC</a>	0,65	0,5	0,43	0,46	0,71	0,77	0,74	0,47	0,41	0,75	0,53	0,62	0,28	0,38
TECO 2030	Oslo	<a href="#">TECO</a>	0,45	0	0	0	0,45	1	0,62	0,47	0,67	0,12	0,2	0,44	0,92	0,6
TGS	Oslo	<a href="#">TGS</a>	0,55	0	0	0	0,61	0,85	0,71	0,67	1	0,09	0,17	0,66	1	0,79
ZENITH ENERGY	Oslo	<a href="#">ZENA</a>	0,35	0,38	0,67	0,48	0,25	0,09	0,13	0,57	0,5	0,15	0,24	0,58	0,88	0,7
AGRIPOWER	Paris	<a href="#">ALAGP</a>	0,4	0,42	0,89	0,57	0	0	0	0,6	0,57	0,15	0,25	0,59	0,94	0,73
MINT	Paris	<a href="#">ALBUD</a>	0,5	0,47	0,89	0,62	0,67	0,18	0,29	0,5	0,5	1	0,67	0	0	0
DOLFINES	Paris	<a href="#">ALDOL</a>	0,45	0,42	1	0,59	1	0,08	0,15	0,47	0,33	0,45	0,38	0,6	0,47	0,53
ENERTIME	Paris	<a href="#">ALENE</a>	0,5	0,4	0,5	0,44	0,6	0,5	0,55	0,43	0,43	1	0,6	0	0	0
EO2	Paris	<a href="#">ALEO2</a>	0,3	0,3	1	0,46	0	0	0	0,43	0,41	1	0,59	1	0,06	0,11
ECOSLOPS	Paris	<a href="#">ALESA</a>	0,5	0,47	0,89	0,62	0,67	0,18	0,29	0,53	0,45	0,38	0,42	0,58	0,65	0,61

GLOBAL BIOENERGIES	Paris	<a href="#">ALGBE</a>	0,45	0,42	1	0,59	1	0,08	0,15	0,37	0,33	0,46	0,39	0,42	0,29	0,34
METHANOR	Paris	<a href="#">ALMET</a>	0,4	0,4	1	0,57	0	0	0	0,53	0,43	0,5	0,46	0,62	0,56	0,59
VERGNET	Paris	<a href="#">ALVER.PA</a>	0,55	0,56	0,5	0,53	0,55	0,6	0,57	0,53	0,52	1	0,68	1	0,07	0,12
AUREA	Paris	<a href="#">AUER</a>	0,35	0,1	0,2	0,13	0,6	0,4	0,48	0,63	0,5	0,09	0,15	0,64	0,95	0,77
SECHE ENVIRONNEM.	Paris	<a href="#">CCHE</a>	0,65	0	0	0	0,68	0,93	0,79	0,43	0,39	0,75	0,51	0,57	0,22	0,32
DERICHEBOURG	Paris	<a href="#">DBG</a>	0,45	0,47	0,9	0,62	0	0	0	0,47	0,48	0,93	0,64	0	0	0
EDF	Paris	<a href="#">EDF</a>	0,4	0,39	0,88	0,54	0,5	0,08	0,14	0,53	0,57	0,27	0,36	0,52	0,8	0,63
ELEC.STRASBOURG	Paris	<a href="#">EDSP</a>	0,35	0,37	0,88	0,52	0	0	0	0,53	0,47	0,69	0,56	0,64	0,41	0,5
TotalEnergiesGabon	Paris	<a href="#">EGAB</a>	0,75	0	0	0	0,75	1	0,86	0,7	0	0	0	0,72	0,95	0,82
ENGIE	Paris	<a href="#">ENGIE</a>	0,55	0,55	1	0,71	0	0	0	0,6	0,59	1	0,74	1	0,08	0,14
ESSO	Paris	<a href="#">ESSE</a>	0,65	0	0	0	0,65	1	0,79	0,3	0,18	0,3	0,22	0,46	0,3	0,36
FRANCAISE ENERGIE	Paris	<a href="#">FDEL</a>	0,65	0	0	0	0,65	1	0,79	0,4	0,37	0,91	0,53	0,67	0,11	0,18
CGG	Paris	<a href="#">GEPH</a>	0,54	0,25	0,1	0,14	0,44	0,7	0,54	0,43	0,43	1	0,6	0	0	0
GPE GROUP PIZZORNO	Paris	<a href="#">GPEP</a>	0,35	0,37	0,88	0,52	0	0	0	0,27	0,28	0,89	0,42	0	0	0
GTT	Paris	<a href="#">GTT</a>	0,55	0	0	0	0,65	0,79	0,71	0,37	0,32	1	0,49	1	0,1	0,17
MAUREL ET PROM	Paris	<a href="#">MAUP</a>	0,45	0,4	0,75	0,52	0,6	0,25	0,35	0,3	0,32	0,82	0,46	0	0	0
MCPHY ENERGY	Paris	<a href="#">MCPHY</a>	0,35	0,33	0,3	0,32	0,36	0,4	0,38	0,57	0	0	0	0,57	1	0,72
SEQUA PETROLEUM NV	Paris	<a href="#">MLSEQ</a>	0,5	0,22	0,4	0,29	0,73	0,53	0,62	0,73	0	0	0	0,73	1	0,85
NEOEN	Paris	<a href="#">NEOEN</a>	0,45	0,29	0,25	0,27	0,54	0,58	0,56	0,4	0,4	1	0,57	0	0	0
NHOA	Paris	<a href="#">NHOA</a>	0,5	0,27	0,6	0,37	0,78	0,47	0,58	0,57	0,43	0,55	0,48	0,69	0,58	0,63
OREGE	Paris	<a href="#">OREGE</a>	0,45	0,45	1	0,62	0	0	0	0,5	0,46	1	0,63	1	0,12	0,21
SCHLUMBERGER	Paris	<a href="#">SLBP</a>	0,55	0	0	0	0,55	1	0,71	0,4	0,4	0,4	0,4	0,4	0,4	0,4
TOTALENERGIES	Paris	<a href="#">TTEF</a>	0,55	0,5	0,78	0,61	0,67	0,36	0,47	0,5	0,5	1	0,67	0	0	0
VEOLIA ENVIRON.	Paris	<a href="#">VIE</a>	0,4	0	0	0	0,4	1	0,57	0,43	1	0,06	0,11	0,41	1	0,59
VOLTALIA	Paris	<a href="#">VLTSA</a>	0,35	0,35	1	0,52	0	0	0	0,57	0,38	0,27	0,32	0,64	0,74	0,68

Fonte: elaboração própria

## Anexo C Médias Medidas de Performance

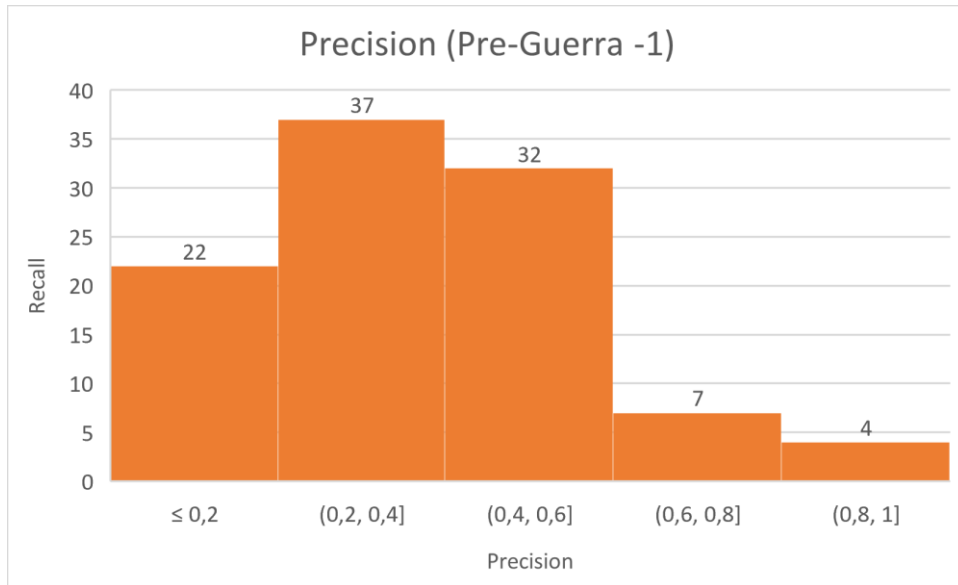


Figura C. 1- Média Precision (Pré-Guerra -1)

Fonte: elaboração própria




Figura C. 2- Média Precision (Pós-Guerra 1)

Fonte: elaboração própria




Figura C. 3-Média Recall (Pré-Guerra -1)

Fonte: elaboração própria





Figura C. 4-Média Recall (Pré-Guerra 1)


Fonte: elaboração própria





*Figura C. 5-Média F1-score (Pré-Guerra -1)*

Fonte: elaboração própria



*Figura C. 6-Média F1-score (Pós-Guerra -1)*

Fonte: elaboração própria

## Anexo D Informação das empresas

Tabela D. 1-Informação das 102 Empresas

Company	City	ISIN	Market	Industry	Sector	Csv
AKER CARBON CAPTUR	Oslo	NO0010890304	Oslo Børs	Pollution & Treatment Controls	Industrials	<a href="#">ACCA</a>
AGILYX	Oslo	NO0010872468	Oslo Børs	Waste Management	Industrials	<a href="#">AGLX</a>
AKASTOR	Oslo	NO0010215684	Oslo Børs	Oil & Gas Equipment & Services	Energy	<a href="#">AKAST</a>
AGRIPOWER	Paris	FR0013452281	Euronext Growth Paris	Utilities - Renewable	Utilities	<a href="#">ALAGP</a>
AKER HORIZONS	Oslo	NO0010921232	Oslo Børs	Asset Management	Financial Services	<a href="#">AKH</a>
AKER BP	Oslo	NO0010345853	Oslo Børs	Oil & Gas E&P	Energy	<a href="#">AKRBP</a>
AKER SOLUTIONS	Oslo	NO0010716582	Oslo Børs	Oil & Gas Equipment & Services	Energy	<a href="#">AKSOA</a>
ARCHER	Oslo	BMG0451H1170	Oslo Børs	Oil & Gas Drilling	Energy	<a href="#">ARCHA</a>
AWILCO DRILLING	Oslo	NO0012740218	Euronext Growth Oslo	Oil & Gas Equipment & Services	Energy	<a href="#">AWDR</a>
SIF HOLDING	Amsterdam	NL0011660485	Euronext Amsterdam	Metal Fabrication	Industrials	<a href="#">SIFG</a>
BORR DRILLING	Oslo	BMG1466R1732	Oslo Børs	Oil & Gas Drilling	Energy	<a href="#">BORR</a>
BW ENERGY LIMITED	Oslo	BMG0702P1086	Oslo Børs	Oil & Gas E&P	Energy	<a href="#">BWE</a>
BW OFFSHORE LTD	Oslo	BMG1738J1247	Oslo Børs	Oil & Gas Equipment & Services	Energy	<a href="#">BWO</a>
CARBON TRANSITION	Oslo	NO0010778095	Euronext Expand Oslo	Marine Shipping	Industrials	<a href="#">CARBN</a>

CLOUDBERRY CLEAN	Oslo	NO0010876642	Oslo Børs	Utilities - Renewable	Utilities	<a href="#">CLOUD</a>
DNO	Oslo	NO0003921009	Oslo Børs	Oil & Gas E&P	Energy	<a href="#">DNO</a>
DOF	Oslo	NO0010070063	Oslo Børs	Oil & Gas Equipment & Services	Energy	<a href="#">DOF</a>
EVERFUEL	Oslo	DK0061414711	Euronext Growth Oslo	Specialty Chemicals	Basic Materials	<a href="#">EFUEL</a>
EIDESVIK OFFSHORE	Oslo	NO0010263023	Oslo Børs	Oil & Gas Equipment & Services	Energy	<a href="#">EIOF</a>
ELMERA GROUP	Oslo	NO0010815673	Oslo Børs	Utilities - Regulated Electric	Utilities	<a href="#">ELMRA</a>
MARATHON OIL CORP	Brussels	US5658491064	Traded not listed Brussels	Oil & Gas E&P	Energy	<a href="#">MRO</a>
ELECTROMAGNET GEO	Oslo	NO0010358484	Oslo Børs	Oil & Gas Equipment & Services	Energy	<a href="#">EMGS</a>
OCCIDENTAL PETROL.	Brussels	US6745991058	Traded not listed Brussels	Oil & Gas E&P	Energy	<a href="#">OXY</a>
EQUINOR	Oslo	NO0010096985	Oslo Børs	Oil & Gas Integrated	Energy	<a href="#">EQNR</a>
GOLDEN ENERGY OFF	Oslo	NO0010813843	Euronext Growth Oslo	Marine Shipping	Industrials	<a href="#">GEOS</a>
HAVILA SHIPPING	Oslo	NO0010257728	Oslo Børs	Marine Shipping	Industrials	<a href="#">HAVI</a>
HORISONT ENERGI	Oslo	NO0010917339	Euronext Growth Oslo	Specialty Chemicals	Basic Materials	<a href="#">HRGI</a>
MINT	Paris	FR0004172450	Euronext Growth Paris	Telecom Services	Communication Services	<a href="#">ALBUD</a>
DOLFINES	Paris	FR0014004QZ9	Euronext Growth Paris	Oil & Gas Equipment & Services	Energy	<a href="#">ALDOL</a>
HUNTER GROUP	Oslo	NO0010283211	Euronext Expand Oslo	Oil & Gas Midstream	Energy	<a href="#">HUNT</a>
HYDROGENPRO	Oslo	NO0010892359	Oslo Børs	Specialty Industrial Machinery	Industrials	<a href="#">HYPRO</a>

INTEROIL EXPL PROD	Oslo	NO0010284 318	Oslo Børs	Oil & Gas E&P	Energy	<a href="#">IOX</a>
MAGNORA	Oslo	NO0010187 032	Oslo Børs	Utilities - Renewable	Utilities	<a href="#">MGN</a>
ENERTIME	Paris	FR0011915 339	Euronext Growth Paris	Specialty Industrial Machinery	Industrials	<a href="#">ALENE</a>
MPC ENERGY SOLUTIO	Oslo	NL0015268 814	Euronext Growth Oslo	Utilities - Renewable	Utilities	<a href="#">MPCES</a>
EO2	Paris	FR0010465 534	Euronext Growth Paris	Lumber & Wood Production	Basic Materials	<a href="#">ALEO2</a>
NEL	Oslo	NO0010081 235	Oslo Børs	Specialty Industrial Machinery	Industrials	<a href="#">NEL</a>
NORTHERN DRILLING	Oslo	BMG6624L 1090	Oslo Børs	Oil & Gas Drilling	Energy	<a href="#">NODL</a>
NORTHERN OCEAN LTD	Oslo	BMG6682J1 036	Oslo Børs	Oil & Gas Drilling	Energy	<a href="#">NOL</a>
NORWEGIAN ENERGY	Oslo	NO0010379 266	Oslo Børs	Oil & Gas E&P	Energy	<a href="#">NOR</a>
NORTH ENERGY	Oslo	NO0010550 056	Euronext Expand Oslo	Asset Management	Financial Services	<a href="#">NORTH</a>
ODFJELL DRILLING	Oslo	BMG67180 1022	Oslo Børs	Oil & Gas Drilling	Energy	<a href="#">ODLO</a>
OKEA	Oslo	NO0010816 895	Oslo Børs	Oil & Gas E&P	Energy	<a href="#">OKEA</a>
SBM OFFSHORE	Amsterdam	NL0000360 618	Euronext Amsterdam	Oil & Gas Equipment & Services	Energy	<a href="#">SBMO</a>
OCEAN SUN	Oslo	NO0010887 565	Euronext Growth Oslo	Utilities - Renewable	Utilities	<a href="#">OSUN</a>
OCEANTEAM	Oslo	NO0010317 316	Oslo Børs	Marine Shipping	Industrials	<a href="#">OTS</a>
PANORO ENERGY	Oslo	NO0010564 701	Oslo Børs	Oil & Gas E&P	Energy	<a href="#">PENR</a>
PGS	Oslo	NO0010199 151	Oslo Børs	Oil & Gas Equipment & Services	Energy	<a href="#">PGS</a>

ENI	Brussels	IT00031324 76	Traded not listed Brussels	Oil & Gas Integrated	Energy	<a href="#">ENIMI</a>
PETRONOR E&P	Oslo	NO0011157 232	Oslo Børs	Oil & Gas E&P	Energy	<a href="#">PNOR</a>
GALP ENERGIA- NOM	Lisbon	PTGAL0A M0009	Euronext Lisbon	Oil & Gas Integrated	Energy	<a href="#">GALP</a>
SHELL PLC	Amsterdam	GB00BP6M XD84	Euronext Amsterdam	Oil & Gas Integrated	Energy	<a href="#">SHEL</a>
ECOSLOPS	Paris	FR0011490 648	Euronext Growth Paris	Waste Management	Industrials	<a href="#">ALESA</a>
FLUXYS BELGIUM D	Brussels	BE0974265 945	Euronext Brussels	Oil & Gas Midstream	Energy	<a href="#">FLUX</a>
PROSAFE	Oslo	NO0010861 990	Oslo Børs	Oil & Gas Equipment & Services	Energy	<a href="#">PRSO</a>
PETROLIA	Oslo	CY0102630 916	Oslo Børs	Oil & Gas Equipment & Services	Energy	<a href="#">PSE</a>
GLOBAL BIOENERGIES	Paris	FR0011052 257	Euronext Growth Paris	Utilities - Diversified	Utilities	<a href="#">ALGBE</a>
QUESTERRE ENERGY	Oslo	CA74836K1 003	Oslo Børs	Oil & Gas E&P	Energy	<a href="#">QEC</a>
QUANTAFUEL	Oslo	NO0010785 967	Euronext Growth Oslo	Waste Management	Industrials	<a href="#">QFUEL</a>
REACH SUBSEA	Oslo	NO0003117 202	Oslo Børs	Oil & Gas Equipment & Services	Energy	<a href="#">REACH</a>
METHANOR	Paris	FR0011217 710	Euronext Growth Paris	Utilities - Diversified	Utilities	<a href="#">ALMET</a>
SEABIRD EXPLORAT	Oslo	CY0101162 119	Oslo Børs	Oil & Gas Equipment & Services	Energy	<a href="#">SBX</a>
VERGNET	Paris	FR0004155 240	Euronext Growth Paris	Renewable Energy	Energy	<a href="#">ALVER. PA</a>
SCANA	Oslo	NO0003053 308	Oslo Børs	Industrial Distribution	Industrials	<a href="#">SCANA</a>
AUREA	Paris	FR0000039 232	Euronext Paris	Waste Management	Industrials	<a href="#">AUER</a>

SCATEC	Oslo	NO0010715 139	Oslo Børs	Utilities - Renewable	Utilities	<a href="#">SCATC</a>
SECHE ENVIRONNEM.	Paris	FR0000039 109	Euronext Paris	Waste Management	Industrials	<a href="#">CCHE</a>
EDP	Lisbon	PTEDP0AM 0009	Euronext Lisbon	Utilities - Diversified	Utilities	<a href="#">EDP</a>
DERICHEBOURG	Paris	FR0000053 381	Euronext Paris	Waste Management	Industrials	<a href="#">DBG</a>
EDF	Paris	FR0010242 511	Euronext Paris	Multiline Utilities	Utilities	<a href="#">EDF</a>
ELEC.STRASBOURG	Paris	FR0000031 023	Euronext Paris	Utilities - Renewable	Utilities	<a href="#">EDSP</a>
REN	Lisbon	PTREL0AM 0008	Euronext Lisbon	Utilities - Diversified	Utilities	<a href="#">RENE</a>
ELIA GROUP	Brussels	BE0003822 393	Euronext Brussels	Utilities - Regulated Electric	Utilities	<a href="#">ELI</a>
S.D. STANDARD ETC	Oslo	CY0101550 917	Oslo Børs	Oil & Gas Equipment & Services	Energy	<a href="#">SDSD</a>
TotalEnergiesGabon	Paris	GA0000121 459	Euronext Paris	Oil & Gas E&P	Energy	<a href="#">EGAB</a>
SEAWAY 7	Oslo	NO0010893 803	Euronext Growth Oslo	Oil & Gas Equipment & Services	Energy	<a href="#">SEAW7</a>
EDP RENOVAVEIS	Lisbon	ES01277970 19	Euronext Lisbon	Utilities - Renewable	Utilities	<a href="#">EDPR</a>
ENGIE	Paris	FR0010208 488	Euronext Paris, Brussels	Utilities - Diversified	Utilities	<a href="#">ENGIE</a>
SHELF DRILLING	Oslo	KYG236271 055	Oslo Børs	Oil & Gas Drilling	Energy	<a href="#">SHLF</a>
SIEM OFFSHORE	Oslo	KYG812291 253	Oslo Børs	Oil & Gas Midstream	Energy	<a href="#">SIOFF</a>
ESSO	Paris	FR0000120 669	Euronext Paris	Oil & Gas Refining & Marketing	Energy	<a href="#">ESSF</a>
NEW SOURCES ENERGY	Amsterdam	NL0009822 014	Euronext Amsterdam	Utilities - Renewable	Utilities	<a href="#">NSEN</a>

SOLSTAD OFFSHORE	Oslo	NO0003080608	Oslo Børs	Marine Shipping	Industrials	<a href="#">SOFF</a>
SUBSEA 7	Oslo	LU0075646355	Oslo Børs	Oil & Gas Equipment & Services	Energy	<a href="#">SUBC</a>
FRANCAISE ENERGIE	Paris	FR0013030152	Euronext Paris	Oil & Gas E&P	Energy	<a href="#">FDEL</a>
TECO 2030	Oslo	NO0010887516	Euronext Growth Oslo	Specialty Industrial Machinery	Industrials	<a href="#">TECO</a>
CGG	Paris	FR0013181864	Euronext Paris	Oil & Gas Equipment & Services	Energy	<a href="#">GEPH</a>
GPE GROUP PIZZORNO	Paris	FR0010214064	Euronext Paris	Professional & Commercial Services	Industrials	<a href="#">GPEP</a>
GTT	Paris	FR0011726835	Euronext Paris	Oil & Gas Equipment & Services	Energy	<a href="#">GTT</a>
MAUREL ET PROM	Paris	FR0000051070	Euronext Paris	Oil & Gas E&P	Energy	<a href="#">MAUP</a>
TGS	Oslo	NO0003078800	Oslo Børs	Oil & Gas Equipment & Services	Energy	<a href="#">TGS</a>
RENEWI	Amsterdam	GB00BNR4T868	Euronext Amsterdam	Waste Management	Industrials	<a href="#">RWI</a>
MCPHY ENERGY	Paris	FR0011742329	Euronext Paris	Specialty Industrial Machinery	Industrials	<a href="#">MCPHY</a>
SEQUA PETROLEUM NV	Paris	NL0010623518	Euronext Access Paris	Oil & Gas E&P	Energy	<a href="#">MLSEQ</a>
ZENITH ENERGY	Oslo	CA98936C1068	Euronext Growth Oslo	Oil & Gas E&P	Energy	<a href="#">ZENA</a>
NEOEN	Paris	FR0011675362	Euronext Paris	Utilities - Renewable	Utilities	<a href="#">NEOEN</a>
NHOA	Paris	FR0012650166	Euronext Paris	Specialty Industrial Machinery	Industrials	<a href="#">NHOA</a>
OREGE	Paris	FR0010609206	Euronext Paris	Waste Management	Industrials	<a href="#">OREGE</a>
GREENCOAT REN.	Dublin	IE00BF2NR112	Euronext Growth Dublin	Electrical Utilities & IPPs	Utilities	<a href="#">GRPG</a>

SCHLUMBERGER	Paris	AN8068571 086	Euronext Paris	Oil & Gas Equipment & Services	Energy	<a href="#">SLBP</a>
TOTALENERGIES	Paris	FR0000120 271	Euronext Paris, Brussels	Oil & Gas Integrated	Energy	<a href="#">TTEF</a>
VEOLIA ENVIRON.	Paris	FR0000124 141	Euronext Paris	Waste Management	Industrials	<a href="#">VIE</a>
VOLTALIA	Paris	FR0011995 588	Euronext Paris	Utilities - Renewable	Utilities	<a href="#">VLTA</a>

Fonte: elaboração própria