

PONTIFÍCIA UNIVERSIDADE CATÓLICA  
DO RIO DE JANEIRO



Arthur Salvador Coelho

2011224

# **O impacto macroeconômico da guerra entre Rússia e Ucrânia**

**Monografia de final de curso**

Orientador: Francisco Luna

Rio de Janeiro, dezembro de 2023

Declaro que o presente trabalho é de minha autoria e que não recorri para realiza-lo, a nenhuma forma de ajuda externa, exceto quando autorizado pelo professor tutor.

As opiniões expressas neste trabalho são de responsabilidade única e exclusiva do autor.

**Arthur Salvador Coelho**

Graduando em Ciências Econômicas – PUC-Rio

## Resumo

Estudos anteriores evidenciaram que conflitos armados, tensões geopolíticas e o terrorismo são capazes de afetar significativamente os mercados financeiros globais. No entanto, são poucos os estudos que focam em mudanças na intensidade dos eventos e ainda mais raros os que utilizam uma metodologia capaz de compensar pelas grandes variações diárias de intensidade entre cada evento, como em números de mortes, por exemplo. Nesse sentido ao usar dados da base Armed Conflict Location & Event Data Project (ACLED) que contabiliza as mortes de cada evento e agregando-as em uma estatística semanal, podemos ter uma medida mais estável da intensidade do conflito e possivelmente mais condizente com a acessibilidade à informação nos mercados globais. Para associar essa medida semanal, utilizamos um modelo GARCH-MIDAS, capaz de assumir dados com frequências distintas. No geral, o estudo mostra que variações no número de mortes influenciam significativamente a volatilidade dos mercados, um resultado consistente com a literatura sobre o assunto. Os resultados são relevantes para políticos e gestores de portfólio, na medida que fornecem informações sobre os efeitos que conflitos modernos possuem nos mercados financeiros modernos.

## **Sumário de figuras**

1. Gráfico 1: Número de fatalidades diárias .....	12
2. Gráfico 2: Fatalidades semanais .....	13
3. Gráfico 3: Retornos diários S&P500 .....	14

## **Sumário de tabelas**

1. Tabela 1: Estatísticas descritivas .....	14
2. Tabela 2: Resultados (modelos 1 a 5) .....	19
3. Tabela 3: Resultados (modelos 6 a 9) .....	20

## **Sumário de capítulos**

1. Introdução.....	7
2. Revisão bibliográfica.....	9
3. Dados.....	11
4. Metodologia.....	16
5. Resultados.....	18
6. Conclusão.....	25
8. Referências bibliográficas.....	27

## **Agradecimentos**

Deixo nesta breve seção um agradecimento especial a meu orientador Francisco Luna, por seu apoio e disponibilidade ao longo de todo o desenvolvimento do presente trabalho. Sem suas orientações, a confecção da pesquisa teria sido difícil e com resultados possivelmente menos satisfatórios. Gostaria também de agradecer aos amigos e colegas que tive ao longo dos 4 anos que cursei Economia na PUC-Rio. Seja diretamente, pelas dúvidas que sanei com eles, ou indiretamente, pelos momentos felizes que tive junto aos mesmos, é fato que o resultado deste trabalho não seria o mesmo. E por último, mas não menos importante, gostaria de agradecer todo o Departamento de Economia da PUC-Rio, pois nada disto teria sido possível sem a competência na transmissão de conhecimento dos professores e apoio dado pelo departamento aos alunos.

# 1. Introdução

O conflito entre Rússia e Ucrânia pode ser considerado um dos eventos com maior relevância desde a Segunda Guerra, tanto pelo tamanho de um dos participantes quanto pelo impacto econômico que gerou, especialmente considerando que o conflito teve início em meio a um cenário de recuperação da crise sanitária global da COVID-19. Do ponto de vista econômico, a Rússia é um dos principais mercados emergentes, altamente engajado no comércio internacional, com vínculos energéticos especiais com economias europeias e asiáticas, como China e Japão.

Como uma economia impulsionada pela energia, a Rússia é o terceiro maior produtor de petróleo do mundo<sup>1</sup> e depende fortemente das exportações de gás, metais e minérios. No entanto, as severas sanções financeiras, econômicas e comerciais impostas pelo Ocidente, em decorrência do conflito, afetaram o funcionamento dessa economia, gerando um grande choque nos mercados globais.

Regiões em todo o mundo experimentaram elevação de preços, que atingiram arduamente os consumidores. Nesse sentido, **Yazbeck et. Al (2022)** estudou a resposta de diversos hábitos alimentares de famílias libanesas frente ao desenvolvimento do conflito entre Rússia e Ucrânia e demonstrou que a insegurança alimentar era duas vezes mais prevalente em domicílios com baixa renda, 35% mais prevalente em mulheres e três vezes mais prevalente em participantes que eram casados. Ademais, 44% dos respondentes reportaram ingestão menor de alimentos saudáveis, comparado ao período pré-guerra.

As mudanças econômicas provocadas pelo conflito também causaram turbulência nos mercados financeiros globais. **Boungou & Yatié (2022)** demonstraram, usando dados do Wikipedia Trends, que um aumento de 1% na intensidade de pesquisas na internet sobre a guerra gera uma queda de 0,8% em índices do mercado acionário, evidenciando o efeito da tensão entre os dois países em conflito sobre os retornos.

Adicionalmente, **Zhou & Lu (2022)** demonstram, criando uma medida de atenção ao conflito entre Rússia e Ucrânia, que esta afeta positivamente a volatilidade de mercado,

---

<sup>1</sup> <https://www.iea.org/reports/russian-supplies-to-global-energy-markets/oil-market-and-russian-supply-2>

demonstrando que esta atenção possui informação relevante sobre o conflito, tornando-a uma boa preditora para volatilidade futura.

Nesse sentido, há de se destacar também que o conflito deu impulso às iniciativas de transição energética ao redor do mundo<sup>2</sup>. De acordo com a International Energy Agency – IEA, a disrupção econômica causada pela guerra na Ucrânia ampliou os apelos para uma transição energética acelerada, principalmente na Europa, onde os efeitos da guerra foram sentidos de forma aguda e o gás russo dominou historicamente as importações. A aceleração dos planos transição energética configura uma força contrária à elevação dos preços do petróleo e gás, gerando disrupções também em outros setores poluentes e não poluentes.

Sendo assim, diante do cenário de incerteza geopolítica e regulatória, há de se analisar o impacto deste evento sobre a volatilidade dos retornos no mercado financeiro. Existem trabalhos brasileiros neste sentido como **Abreu & Camargos (2022)**, que analisou a eficiência de diversos mercados globais antes e após a invasão da Ucrânia, constatando um incremento no grau de aleatoriedade das séries analisadas e comportamento mais homogêneo dos mercados, e **Mello (2023)**, que constatou que a guerra entre Rússia e Ucrânia não afetou fortemente, pelo menos inicialmente, os mercados acionários latino-americanos. O presente trabalho se diferencia dos anteriores ao buscar identificar o efeito de mudanças na intensidade do conflito, utilizando dados da base Armed Conflict Location & Event Data Project (ACLED)<sup>3</sup>, no mercado financeiro dos EUA, através de um modelo GARCH-MIDAS, que permitirá capturar não somente os efeitos de aumento ou redução da volatilidade deste mercado.

Na próxima seção é feita uma revisão da literatura internacional sobre o tema identificando os principais pontos de pesquisas anteriores. Em seguida, são descritos os dados utilizados neste trabalho para identificar os efeitos. Na seção seguinte é dada a explicação sobre a metodologia do modelo GARCH-MIDAS a ser utilizado e quais os coeficientes de interesse das equações. Na quinta seção serão expostos os principais resultados do trabalho, resultados de testes para validar o modelo e comportamento das funções de peso. Finalmente, na seção de conclusão, é feita uma retomada de todo o estudo e como ele contribui para a literatura e possíveis pontos de melhoria.

---

<sup>2</sup> <https://www.iea.org/topics/russias-war-on-ukraine>

<sup>3</sup> <https://acleddata.com/>



## 2. Revisão bibliográfica

Nos últimos anos, a literatura que trata da resposta de mercados financeiros a eventos anormais teve uma grande expansão, graças à eclosão da pandemia da COVID-19 e, mais recentemente, a guerra entre Rússia e Ucrânia.

**Suwannapak & Chancharat (2022)** estudaram o efeito da progressão da pandemia na Tailândia na volatilidade do mercado acionário, utilizando um modelo BEKK-GARCH, e verificaram que há um aumento da volatilidade em resposta a incrementos no número de infecções, um resultado consistente com a literatura.

No contexto deste trabalho, como dito na introdução, **Boungou & Yatié** identificaram uma resposta negativa dos mercados financeiros à progressão da guerra, no entanto, seu trabalho não possui foco na volatilidade enfrentada por esses mercados, mas sim nos retornos. Nesse sentido, três publicações foram de suma motivação para este trabalho.

**Yang et. al (2021)** associou a resposta da volatilidade do índice CSI 300, da bolsa de Shanghai, a diversos índices de risco geopolítico em países emergentes, nomeadamente GPRs, através de um modelo GARCH-MIDAS, revelando um impacto positivo na volatilidade, particularmente para níveis de GPR acima da média, sugerindo que investidores estão mais atentos a níveis mais altos de risco geopolítico.

Ademais, **Arfaoui & Naoui (2022)**, examinaram a influência de ataques terroristas no mercado acionário britânico e francês. Construindo um índice diário de terror e utilizando uma regressão quantílica, os autores descobrem que os retornos dos mercados acionários de ambos os países respondem negativamente à aumentos no índice, porém, surpreendentemente, a volatilidade reduz quando índice de terror está ao redor da média ou em quantis extremos.

**Ngwakwe (2022)** fez grande contribuição à literatura ao investigar se houve diferença na resposta dos mercados entre o período de acúmulo de tropas russas ao redor da fronteira com a Ucrânia, ou seja, rumores de que haveria uma guerra, e o efetivo início do conflito. Sua pesquisa revelou que para o mercado britânico e americano, o acúmulo de tropas não teve efeito significativo na volatilidade, diferentemente do mercado acionário europeu, que foi afetado significativamente pelo evento. No que tange o período de guerra efetiva, todos os mercados sofrem efeito significativo em sua volatilidade. O trabalho também


conclui que o mercado acionário americano é mais resiliente ao impacto da guerra do que o europeu e do Reino Unido, oferecendo, portanto, um refúgio mais seguro para investidores.

Existem outros trabalhos que tratam da volatilidade durante a guerra na Ucrânia, como **Beraich et. al (2022)** e **Li et. al (2022)**, que possuem resultados consistente entre si, porém estes focam nos spillovers de volatilidade entre mercados, um efeito que com certeza é importante para o entendimento das dinâmicas de mercado, mas não é o foco do presente trabalho.

### 3. Dados

O estudo promovido neste trabalho visa associar, por meio de uma relação causal, a intensidade da guerra com a volatilidade do mercado financeiro dos EUA. Para tal, utilizam-se dados da base Armed Conflict Location & Event Data Project (ACLED), que possui informações acerca de eventos violentos que ocorrem ao redor de todo mundo. Os dados contidos na base detalham bem as informações relacionadas a cada evento, com colunas que caracterizam o tipo de evento, atores envolvidos, tipo de interação entre esses atores (forças armadas contra forças armadas, forças armadas contra civis, forças armadas contra rebeldes, forças armadas contra protestantes, etc.), local e data em que o evento ocorreu, fonte da informação, número de fatalidades, caso aplicável, e também notas acerca do evento, que incluem estas informações em uma frase descritiva do evento. Mais especificamente sobre a coluna de notas, como ela contém muitas informações sobre o eventos, incluindo os atores e tipo de interação, podemos usá-la para filtrar os eventos que envolvem “Rússia”, “Ucrânia” (e suas derivações) para assim saber exatamente quais eventos estão associados ao conflito entre estes dois países. O gráfico a seguir foi gerado desta maneira e evidencia o início do conflito com uma linha pontilhada vermelha, bem como a escalada no número de mortes. Para fins deste estudo, o período compreendido pelos dados é do dia 29/03/2021 até 08/09/2023.

## 1. Número de fatalidades diárias



Nota: O início do conflito é muito bem marcado pela rápida escalada no número de mortes

Fonte: Gráfico gerado através de manipulação de dados no R

Cabe ressaltar que é possível que nem todos os eventos utilizados na construção do gráfico acima estejam atrelados, direta ou indiretamente, ao conflito, no entanto, é clara a mudança da relação entre os países após o início da guerra. Ademais, a base de dados ACLED, define, em seu Codebook<sup>4</sup>, que rastreia a violência política relatada a partir de quatro tipos principais de fontes:

1. mídia local, regional, nacional e continental revisada diariamente;
2. relatórios de ONGs ou organizações internacionais usados para complementar comunicados de mídia;
3. contas de redes sociais selecionadas, incluindo Twitter e Telegram; e
4. informações e dados fornecidos por meio de parcerias com observatórios de conflitos locais em caso de difícil acesso à informação.

Os dados são coletados por especialistas treinados e atualizados semanalmente. Também é importante notar que não é desejável fazer este filtro diretamente na coluna de atores,


---

<sup>4</sup> [https://acleddata.com/acleddatanew/wp-content/uploads/dlm\\_uploads/2023/06/ACLED\\_Codebook\\_2023.pdf](https://acleddata.com/acleddatanew/wp-content/uploads/dlm_uploads/2023/06/ACLED_Codebook_2023.pdf)

pois podem haver protestos relacionados ao conflito, por exemplo, em outros países que por sua vez contribuem para o sentimento de intensidade da guerra. Desse modo, se o filtro fosse feito pelos atores, estaríamos perdendo esse potencial efeito.

Neste estudo, utiliza-se o número de fatalidades como uma variável proxy para a intensidade do conflito. Ademais, agregamos as fatalidades em um número semanal para a avaliar os efeitos sobre os retornos do S&P500, pois é improvável que agentes econômicos estejam atentos ao número diário de mortes no conflito.

## 2. Fatalidades semanais



A agregação semanal de mortes transmite a mesma mensagem, mas com maior estabilidade


Fonte: Gráfico gerado através de manipulação de dados no R

Esta estatística semanal será associada a uma série temporal de retornos diários do índice S&P500, extraído do FRED<sup>5</sup>.

---

<sup>5</sup> <https://fred.stlouisfed.org/series/SP500>

### 3. Retornos diários S&P500



Nota: É possível notar um aumento na volatilidade dos retornos após o início do conflito

Fonte: Gráfico gerado através de manipulação de dados no R

Na tabela a seguir, estão exibidos alguns fatos estilizados dos dados utilizados neste trabalho.

#### 1. Estatísticas descritivas

	Média	Max	Min	SD	Skew	Kurt	JB	<i>n</i>
Retornos	0.02	5.39	-4.42	1.13	-0.17	4.76	85.74	640
Fatalidades diárias	50.06	640.00	0.00	81.20	3.12	15.79	7,560.22	896
Fatalidades semanais	347.69	1,378.00	0.00	335.53	0.62	2.58	9.11	129

Nota: Retornos possuem média muito próxima de 0 e séries temporais não apresentam distribuição normal. Os números de observações de fatalidades e retornos diários diverge, pois há contagem em finais de semana.

A série temporal de retornos diários possui uma medida de assimetria (Skew) negativa, indicando que sua distribuição possui mais valores negativos (uma cauda maior à

esquerda). Como não há valores negativos de fatalidades, os valores de Skew para as outras duas séries será positivo. Já no que se refere à normalidade das séries, todas possuem Kurtosis maior que +2, evidenciando que as distribuições são mais “estritas” que a normal, ou seja, com mais respostas ao centro. Um teste mais efetivo para a aferição da normalidade de distribuições é o teste Jarque-Bera, onde valores próximos a 0 indicam que a distribuição é parecida com uma normal. No caso das séries aqui apresentadas, os valores do teste não estão próximos de 0, evidenciando que as distribuições não são normais.

## 4. Metodologia

Para esta associação, será usado um modelo GARCH-MIDAS, proposto em **Engle et al. (2013)**, que permitirá capturar informações relacionadas aos retornos, volatilidade e dinâmica de retorno ao equilíbrio do mercado financeiro. A grande vantagem deste modelo é que ele permite utilizar dados de frequências distintas, tornando-o ideal para a proposta de associação semanal com dados diários. Esta metodologia funciona dividindo a variância condicional em dois componentes: um de longo prazo e outro de curto prazo.

Primeiramente, suponha que os retornos diários do índice S&P500 seja dado pela seguinte equação:

$$r_{i,t} = \mu + \sqrt{\tau_t} g_{i,t} \varepsilon_{i,t}, \quad \forall i = i, \dots, N_t$$
$$\varepsilon_{i,t} | \Phi_{i-1,t} \sim N(0,1)$$

Onde  $r_{i,t}$  se refere ao retorno do S&P500 in dia  $i$  da semana  $t$ . Os componentes de longo e curto prazo são  $\tau_t$  e  $g_{i,t}$ , respectivamente. No modelo proposto por **Engle et al. (2013)**, o componente de curto prazo é descrito por um processo GARCH (1, 1) diário da seguinte forma:

$$g_{i,t} = (1 - \alpha - \beta) + \alpha \frac{(r_{i-1,t} - \mu)^2}{\tau_t} + \beta g_{i-1,t}$$

No entanto, os resultados de **Awartani & Corradi (2005)** mostram que existe assimetria entre choques e volatilidade no índice S&P500. Sendo assim, seguindo o que é feito por **Yang et. al (2021)**, é possível que o componente de curto prazo seja melhor representado por um processo GJR-GARCH (1, 1) estacionário, definido da seguinte forma:

$$g_{i,t} = \left( \frac{1 - \alpha - \gamma}{2 - \beta} \right) + \left( \alpha + \gamma_{\{\varepsilon_{i-1,t} < 0\}} \right) \frac{\varepsilon_{i-1,t}^2}{\tau_t} + \beta g_{i-1,t}$$

O componente de longo prazo do modelo,  $\tau_t$ , é geralmente interpretado como uma suavização da variável de interesse, baseada em uma função de peso variável:

$$\log(\tau_t) = m + \theta \sum_{k=1}^K \varphi_k(\omega_1, \omega_2) F_{t-k}$$



Onde  $F_t$  é o número de fatalidades na semana  $t$ ,  $\theta$  é o coeficiente de interesse,  $k$  são os lags das fatalidades e  $\varphi_k$  é a função de pesos a ser utilizada. Caso se deseje usar duas variáveis no modelo, como número de fatalidades e volatilidade realizada, por exemplo, podemos escrever o componente de longo prazo da seguinte forma:

$$\log(\tau_t) = m_2 + \theta_1 \sum_{k=1}^K \varphi_{1,k}(\omega_{1,1}, \omega_{2,1}) F_{t-k} + \theta_2 \sum_{k=1}^K \varphi_{2,k}(\omega_{1,2}, \omega_{2,2}) RV_{t-k}$$

Agora, para concluir o modelo, devemos especificar a função de peso, que pode ser descrita por uma função beta irrestrita:

$$\varphi_k(\omega_1, \omega_2) = \frac{\left(\frac{k}{K}\right)^{\omega_1-1} \left(1 - \frac{k}{K}\right)^{\omega_2-1}}{\sum_{j=1}^K \left(\frac{j}{K}\right)^{\omega_1-1} \left(1 - \frac{j}{K}\right)^{\omega_2-1}}$$

**Yang et. al (2021)** também considera em sua especificação um modelo onde a função de pesos é restrita a  $\omega_1 = 1$ :

$$\varphi_k(1, \omega_2) = \frac{\left(1 - \frac{k}{K}\right)^{\omega_2-1}}{\sum_{j=1}^K \left(1 - \frac{j}{K}\right)^{\omega_2-1}}$$

Durante a demonstração dos resultados, várias especificações serão testadas através de um teste Ljung-Box nos resíduos de cada modelo, com seus respectivos valores de coeficientes.

## 5. Resultados

Foram realizadas nove especificações diferentes que diferem quanto à inclusão de um parâmetro  $\gamma$ , que denota o GARCH assimétrico no componente de curto prazo, restrição  $\omega_{1,1} = 1$  e o tipo de variável dependente utilizada (valor absoluto do número de mortes, diferença no número de mortes ou volatilidade realizada). Em todos os casos, o coeficiente de interesse é  $\theta_1$  que corresponde ao efeito do número de mortes na volatilidade do índice S&P500. No caso da diferença semanal dos números de mortes, o coeficiente corresponde ao efeito que aumentos no número de mortes têm sobre a volatilidade. Já no que se refere ao último modelo, o coeficiente se refere ao efeito que valores maiores de volatilidade realizada de valores passados possuem sobre a volatilidade atual.

Primeiramente, vê-se que o modelo 4, que utiliza o número absoluto de mortes semanais como variável dependente, componente de curto prazo definido por um GARCH assimétrico e uma restrição de  $\omega_{1,1} = 1$  no esquema de pesos, não apresenta efeito significativo. No entanto, removendo a restrição, caso do modelo 3, concluímos que há um efeito significativo ao nível de 1%, porém em direção contrária ao esperado. O valor de  $\theta_1 = -0,002$  indica que contagens maiores de mortes semanais reduzem significativamente a volatilidade do índice S&P500. Este é o mesmo caso dos modelos 1 e 2 que apresentam ambos  $\theta_1 = -0,003$ . Vale ressaltar que estes resultados não são inconsistentes com a literatura, visto que existem trabalhos que atribuem um efeito redutor de volatilidade aos conflitos, como **Wu et al. (2023)**. Vale ressaltar que ao realizar um teste ADF no número de mortes semanal, o P-valor do teste é 0,01, o que permite rejeitar a hipótese nula de que a série temporal não é estacionária.

## 2. Resultados (modelos 1 a 5)

	(1)	(2)	(3)	(4)	(5)
$\mu$	0,047 (0,056)	0,059 (0,054)	0,042 (0,047)	-0,006 (0,359)	0,036 (0,052)
$\alpha$	0,000 (0,071)	0,082 (0,102)	0,000 (0,076)	0,000 (0,352)	0,045 (0,038)
$\beta$	0,813*** (0,221)	0,867*** (0,172)	0,848*** (0,101)	0,951*** (0,252)	0,924*** (0,087)
$\gamma$			0,099 (0,075)	0,094 (0,178)	
$m$	0,944*** (0,119)	1,329*** (0,462)	0,885*** (0,183)	0,129 (0,683)	-0,427 (0,293)
$\theta_1$	-0,003*** (0,000)	-0,003*** (0,000)	-0,002*** (0,000)	0,001 (0,004)	0,100*** (0,025)
$\omega_{1,1}$	10,957 (6,722)		13,928 (11,574)		1,55*** (0,242)
$\omega_{2,1}$	1,794 (1,449)	1,000 (0,651)	1,938 (1,583)	11,733 (11,708)	1,657*** (0,414)
$\theta_2$					
$\omega_{2,2}$					
LLH	-620,068	-628,623	-617,328	-620,727	-622,337
BIC	1282,076	1293,194	1282,589	1283,394	1286,613
LB Test	0,157	0,243	0,12	0,107	0,142
Variação nas mortes semanais	Não	Não	Não	Não	Sim

Nota: Erros são robustos à heteroscedasticidade. Teste LB nos resíduos não permitem rejeitar a hipótese nula. Modelos 1 a 3 indicam que números maiores de mortes reduzem a volatilidade do índice S&P500.

### 3. Resultados (modelos 6 a 9)

	(6)	(7)	(8)	(9) (RV)
$\mu$	0,024 (0,052)	0,013 (0,054)	0,003 (0,057)	0,043 (0,052)
$\alpha$	0,046* (0,025)	0,000 (0,147)	0,000 (0,169)	0,041 (0,030)
$\beta$	0,953*** (0,032)	0,863*** (0,127)	0,862*** (0,122)	0,959*** (0,034)
$\gamma$		0,147 (0,106)	0,15 (0,124)	
$m$	0,22 (0,538)	-0,438* (0,232)	-0,905** (0,372)	0,423 (0,529)
$\theta_1$	0,031** (0,013)	0,103*** (0,024)	0,037*** (0,014)	0,037 (0,080)
$\omega_{1,1}$		1,544*** (0,183)		
$\omega_{2,1}$	1,077*** (0,229)	1,673*** (0,353)	1,181*** (0,329)	1,876* (1,003)
$\theta_2$			0,112*** (0,039)	
$\omega_{2,2}$			3,219** (1,460)	
LLH	-623,455	-615,82	-617,611	-627,271
BIC	1282,859	1279,571	1289,146	1290,492
LB Test	0,168	0,106	0,127	0,173
Variação nas mortes semanais	Sim	Sim	Sim	

Nota: Erros são robustos à heteroscedasticidade. Teste LB nos resíduos não permitem rejeitar a hipótese nula. Modelos 6 a 8 indicam que aumentos no número de mortes aumentam a volatilidade do índice S&P500.

Já no que tange os modelos que usam a diferença do número de mortes semanal como variável dependente, os resultados são positivamente significativos. Para o modelo 5, onde o componente de curto prazo é um GARCH (1, 1) e não há restrição no esquema de pesos, o coeficiente de interesse  $\theta_1 = 0,100$  é significativo ao nível de 1%. Já para o modelo 6, que adiciona a restrição  $\omega_{1,1} = 1$  no modelo 5,  $\theta_1 = 0,031$  é significativo ao nível de 5%. O modelo 7 utiliza um GJR-GARCH como componente de curto prazo e não possui restrições no esquema de pesos, sendo a estimativa do coeficiente de interesse  $\theta_1 = 0,103$ , significativo ao nível de 1%. Finalmente, o modelo 8 utiliza um GJR-GARCH como componente de curto prazo e possui duas variáveis dependentes, a diferença semanal no número de mortes e a volatilidade realizada na semana, definida como  $RV = \sum_{i=1}^N r_{i,t}^2$ , onde  $N = 5$ , bem como restrições de  $\omega_{1,1} = 1$  e  $\omega_{1,2} = 1$ , sendo a estimativa do coeficiente de interesse  $\theta_1 = 0,037$  significativo ao nível de 1% e o coeficiente  $\theta_2 = 0,112$ , referente ao efeito da volatilidade realizada, também significativo ao nível de 1%. Ao realizar um teste ADF na diferença entre o número de mortes semanais, o P-valor também é 0,01. Estes resultados também são consistentes com a literatura sobre o efeito de guerras no mercado acionário, concordando com trabalhos como **Schneider & Troeger (2006)** e **Hudson & Urquhart (2015)**.


O modelo 9 foi estimado com o intuito de fornecer uma base de comparação, já que não usa as mortes como variável dependente principal, mas sim a volatilidade realizada, porém o resultado da estimação não se mostrou significativo.'

Ao olhar para os valores das funções de log-probabilidade, vê-se que o modelo que possui o menor valor é o 7, ou seja, ele é o que mais bem se adequa aos dados. No entanto, vale ressaltar que a comparação entre valores de LLH deve ser feita somente entre modelos que possuem o mesmo número de parâmetros, como por exemplo os modelos 6 e 2 que possuem 6 parâmetros cada. Neste caso, o modelo é mais eficiente.


Já o critério de informação BIC é uma abordagem geral bem conhecida para seleção de modelos que favorece modelos mais parcimoniosos em detrimento de modelos mais complexos. Nesse sentido, podemos comparar os diferentes modelos, mas chegamos a mesma conclusão de que o modelo 7 é o que mais bem se adequa aos dados, já que possui o menor valor de BIC. No entanto, o modelo 8, mais complexo, possui um valor bem mais alto, sendo apenas melhor que os modelos 2 e 9.

Para testar os modelos foi feito um teste Ljung-Box nos resíduos com 10 lags para auferir se há autocorrelação residual e em todos os modelos não é possível rejeitar a hipótese nula de que não há autocorrelação residual ao nível de 10%.


(1)




(2)




(3)




(4)




(5)




(6)




(7)



(8)



(9)



Quando tratamos de um modelo com sistema de pesos é interessante analisar as ponderações feitas neste sentido para saber se são necessárias hipóteses adicionais. Ao analisar graficamente o sistema de pesos, é possível verificar que, em uma primeira análise, os modelos 1, 3, 5 e 7 possuem um comportamento inesperado, visto que sugerem que mortes de semanas anteriores possuem mais relevância que as mais recentes, enquanto que os modelos 2, 4 e 6 possuem comportamento mais dentro do esperado. É improvável que as situações apresentadas nos modelos 1 e 3 sejam factíveis, pois dão relevância extrema às últimas semanas dos lags, porém a informação presente nos modelos 5 e 7 pode vir ser explicada pela atenção que o mercado dá à guerra. Sob a hipótese de mercados eficientes, tal resultado não faria sentido, dado que supõe-se que o mercado considera toda a informação disponível no presente. Porém, se flexibilizarmos tal hipótese, é possível que os agentes tomem decisões baseadas em informações um pouco defasadas, viabilizando o que é apresentado graficamente.



## 6. Conclusão

Sendo assim, vê-se que o número de mortes, aqui usada como proxy para a intensidade do conflito, constitui uma informação relevante para explicar a volatilidade do índice do mercado acionários S&P500. Há divergência na direção de tal efeito dependendo se o número de mortes é absoluto ou uma diferença com relação à semana anterior. Em nenhum dos modelos podemos rejeitar a hipótese de que não há autocorrelação dos resíduos, indicando que os modelos fizeram bem seu trabalho.

Esta monografia contribui para a literatura referente ao efeito de conflitos violentos no mercado financeiro ao focar na exposição de resultados que levam em conta variáveis com diferentes periodicidades e utilizando uma base de dados rica. Espera-se que esta pesquisa possa servir como base para políticos e gestores de portfólio na tomada de decisões diante de cenários similares que venham a possivelmente se arquitetar no futuro, extraíndo informações sobre a volatilidade de ativos e possíveis mudanças nas alocações para maximizar os retornos, dado um nível de risco aceitável.

No presente trabalho, existem diversos pontos que podem ser alvos de futuras pesquisas para mensuração mais precisa dos resultados. Um destes pontos é referente à mensuração da intensidade do conflito, que aqui foi resumida no número de mortes semanais. Uma das críticas ao uso de tal medida é que não estamos medindo a intensidade em si, mas sim algo que é reflexo dela. Neste sentido, os próximos trabalhos que tratem deste tema podem se propor a medir diretamente a intensidade com modelos de variável latente, por exemplo. **Stoehr et. al (2023)** obteve grande avanço neste sentido ao construir um modelo generativo probabilístico que assume que cada evento observado está associado a uma classe latente de intensidade utilizando 4 variáveis, a escala de Goldstein, uma medida muito utilizada quando se deseja obter a intensidade de um evento específico, mas que não leva em consideração outros fatores como o número de casualidades, categoria do “agressor”, categoria da “vítima” e o número de casualidades (pessoas feridas e mortas). Os autores avaliam o modelo proposto tanto intrínseca quanto extrinsecamente, mostrando que ele obtém desempenho preditivo comparativamente bom. A base de dados ACLED se mostra extremamente rica e há um grande potencial inexplorado neste trabalho para pesquisas futuras.

Outra forma de medir a intensidade seria com pesquisas dirigidas a agentes do mercado com a pergunta “De 1 a 10, o quão intenso foi o conflito entre X e Y esta semana?”, embora esta talvez não seja uma boa opção para a guerra entre Rússia e Ucrânia especificamente, dado o extenso período de tempo desde o início do conflito. Assumindo que não há vieses relativos às respostas (hipótese forte) esta pode ser a melhor medida se estas forem administradas rapidamente a partir do início de um conflito. As respostas a esta pesquisa podem também alimentar um modelo de variável latente com perguntas menos diretas.

Já no que se refere à variável dependente utilizada, outros índices, além do S&P500 podem ser uma melhor opção se o objetivo é analisar as condições econômicas do país. Como exposto pela revista *The Economist*<sup>6</sup> no dia 8 de novembro de 2023, “se você quiser saber o real estado do mercado acionário dos Estados Unidos, evite o índice principal. Veja o S&P 493”, argumentando que uma porção significativa da performance do índice é dada por apenas 1,4% das firmas nele contidas, enquanto os restantes 98,6% das empresas não são bem caracterizados por estes sete prodígios tecnológicos, e que o S&P493 é menos vulnerável à mudanças de humor no mercado.

E finalmente, outras derivações de modelos podem ser estimadas. No caso deste trabalho, o pacote mfGARCH<sup>7</sup>, desenvolvido por Onno Kleen<sup>8</sup> foi utilizado para computar as estimações. No entanto o pacote carrega consigo algumas restrições, como por exemplo a impossibilidade de  $\omega_{1,2} \neq 1$  ou de usar um GARCH(1, 1) quando são utilizadas duas variáveis independentes. Trabalhos futuros podem superar estas dificuldades técnicas com a atualização e/ou desenvolvimento de pacotes mais complexos, bem como utilização de outras linguagens de programação, que não o R.

---

<sup>6</sup> [Forget the S&P 500. Pay attention to the S&P 493](#)

<sup>7</sup> <https://cran.r-project.org/web/packages/mfGARCH/index.html>

<sup>8</sup> <https://onnokleen.de/>

## 8. Referências bibliográficas

Yazbeck, Nour, Mansour, Rania, Salame, Hassan, Chahine, Nazih Bou & Hoteit, Maha. 2022. The Ukraine–Russia War Is Deepening Food Insecurity, Unhealthy Dietary Patterns and the Lack of Dietary Diversity in Lebanon: Prevalence, Correlates and Findings from a National Cross-Sectional Study. <https://doi.org/10.3390/nu14173504>

Boungou, Whelsy & Yatié, Alhonita. 2022. The impact of the Ukraine–Russia war on world stock market returns. <https://doi.org/10.1016/j.econlet.2022.110516>

Zhou, Haonan & Lu, Xinjie. 2023. Investor attention on the Russia-Ukraine conflict and stock market volatility: Evidence from China. <https://doi.org/10.1016/j.frl.2022.1035263>

Abreu, Daniel Perreira Alves de & Camargos, Marco Antônio de. 2022. Guerra Rússia x Ucrânia: Análise dos Impactos na Eficiência de Mercado das Criptomoedas e dos Países do G-20 via Teoria de Fractais. <https://anpad.com.br/uploads/articles/120/approved/3d3d286a8d153a4a58156d0e02d8570c.pdf>

Mello, Eduardo Cezar Carvalho de. 2023. Análise dos impactos causados pelo conflito na Ucrânia nas bolsas latino-americanas. <https://repositorio.unifesp.br/handle/11600/67041>

Suwannapak, Suthasinee, & Chancharat, Surachai. 2022. Stock Market Volatility Response to COVID-19: Evidence from Thailand. *Journal of Risk and Financial Management*. <https://doi.org/10.3390/jrfm15120592>

Yang, Menglong, Zhang, Qiang, Yi, Adan & Peng, Peng. 2021. Geopolitical Risk and Stock Market Volatility in Emerging Economies: Evidence from GARCH-MIDAS Model. <https://www.hindawi.com/journals/ddns/2021/1159358/#abstract>

Arfaoui, Nadia & Naoui, Kamel. 2022. Terrorism, investor sentiment, and stock market reaction: Evidence from the British and the French markets <https://doi.org/10.1016/j.frl.2021.102462>

Ngwakwe, Collins. 2022. Stock Market Volatility during Rumours of War and Actual War: Case of Russia-Ukraine Conflict. <https://www.cceol.com/search/article-detail?id=1058787>

Beraich, Mohamed, Amzile, Karim, Laamire, Jaouad, Zirari, Omar & Fadali, Mohamed Amine. 2022. Volatility Spillover Effects of the US, European and Chinese Financial Markets in the Context of the Russia–Ukraine Conflict. *International Journal of Financial Studies*. <https://doi.org/10.3390/ijfs10040095>

Li, Yanshuang, Alshater, Muneer & Yoon, Seong-Min. 2022. The Impact of Russia-Ukraine Conflict on Global Financial Markets. <https://ssrn.com/abstract=4108325> or <http://dx.doi.org/10.2139/ssrn.4108325>

Engle, Robert F., Ghysels, Eric & Sohn, Bumjean. 2013. Stock Market Volatility And Macroeconomic Fundamentals. *The Review of Economics and Statistics*. <https://www.jstor.org/stable/43554794>

Awartani, Basel M. A. & Corradi, Valentina. 2005. Predicting the volatility of the S&P-500 stock index via GARCH models: the role of asymmetries. *International Journal of Forecasting*.

<https://warwick.ac.uk/fac/soc/economics/staff/academic/corradi/papers/ijfbasel.pdf>

Wu, Feng-lin, Zhan, Xu-dong, Zhou, Jia-qi & Wang, Ming-hui. 2023. Stock market volatility and Russia–Ukraine conflict. *Finance Research Letters*. <https://doi.org/10.1016/j.frl.2023.103919>

Schneider, Gerald & Troeger, Vera E. 2006. War and the World Economy: Stock Market Reactions to International Conflicts. *The Journal of Conflict Resolution*. <https://www.jstor.org/stable/27638514>

Hudson, Robert & Urquhart, Andrew. 2015. War and stock markets: The effect of World War Two on the British stock market. *International Review of Financial Analysis*. <https://doi.org/10.1016/j.irfa.2015.05.015>

Stoehr, Niklas, Hennigen, Lucas Torroba, Valvoda, Josef, West, Robert, Cotterell, Ryan & Schein, Aaron. 2023. An Ordinal Latent Variable Model of Conflict Intensity. <https://doi.org/10.48550/arXiv.2210.03971>