

ANÁLISE ECONOMÉTRICA DOS PREÇOS DO BARRIL DE PETRÓLEO PELO MODELO ARCH/GARCH, BRASIL, 2012-2022

PROF. DR. MOISÉS PAIS DOS SANTOS¹
DOUGLAS LOPES DOS REIS²

RESUMO

O presente trabalho tem como objetivo contribuir para a literatura disponível sobre projeções dos preços do barril de petróleo e sua aplicação em modelos de previsão de séries temporais. Dessa maneira, ajuda na formação de expectativas futuras por parte dos agentes econômicos, além fornecer subsídios para o delineamento de estratégias adequadas para o gerenciamento do risco de variações nos preços (retornos) destas commodities. A metodologia adotada baseia-se nos modelos de heterocedasticidade condicional auto-regressiva (ARCH) e GARCH. Concluiu-se que o retorno do ativo para o período considerado é extremamente baixo e que choques sobre a série temporal no período analisado tendem a repercutir por longos períodos.

Palavras-chave: petróleo; modelos ARCH/GARCH; volatilidade; retorno do ativo.

ABSTRACT

This paper aims to contribute to the available literature on oil barrel price projections and their application in time series forecasting models. In this way, it helps in the formation of future expectations on the part of economic agents, in addition to providing subsidies for the outlining of adequate strategies for managing the risk of variations in the prices (returns) of these commodities. The adopted methodology is based on the conditional autoregressive heteroscedasticity models (ARCH) and GARCH. It was concluded that the asset return for the considered period is extremely low and that shocks on the time series in the analyzed period tend to reverberate for long periods.

Keywords: oil; ARCH/GARCH models; volatility; asset return.

1 Prof. Dr. em Economia, na Faculdade Strong Business School, no Curso de Ciências Econômicas.

2 Aluno da Faculdade Strong Business School, Curso de Ciências Econômicas

1. INTRODUÇÃO

Este estudo apresenta uma análise empírica do processo de volatilidade do retorno de uma *commodity* importante no mercado brasileiro, o petróleo. Nesta análise duas características determinantes de tal processo serão analisadas, a persistência de choques e assimetrias na volatilidade. Este tópico é considerado particularmente importante para a economia brasileira, dada a expressiva importância econômica dessa *commodity*. Assim, a análise do padrão da volatilidade e dos retornos gerados por esta *commodity* possui implicações importantes concernentes à formulação de políticas para o setor e performance econômica do país.

Entende-se que a origem da volatilidade é diferente para os tipos de *commodities*. No caso de *commodities* primárias, por exemplo, a volatilidade do preço surgiria, sobretudo, devido a distúrbios na oferta, enquanto para matérias-primas industriais ela seria resultado de distúrbios na demanda. A interação destas variações com a demanda de curto prazo e as elasticidades da oferta resultaria em acentuadas flutuações de preços. Além disso, entende-se que o aumento da volatilidade nos mercados de *commodities* primárias pode justificar o uso de processos baseados em informação para a modelagem do padrão de volatilidade do retorno de tais *commodities*.

No contexto histórico, o petróleo foi e continua sendo a principal fonte de energia respondendo por 35,6% do consumo de energia primária do mundo (2007) e exerce um importante papel estratégico tanto para países exportadores como para países importadores. Até a década de 1970 os preços eram majoritariamente determinados pelas grandes empresas petrolíferas e, após o primeiro choque do petróleo, a Organização dos Países Exportadores de Petróleo (OPEP) emerge como grande balizador dos preços, que ocorre até os anos 1980. A partir deste momento, a influência da OPEP tem se reduzido e o mercado tem exercido crescente influência na determinação dos preços do petróleo, de forma que hoje a OPEP não é mais capaz de estabelecer o preço de referência para o petróleo.

As principais referências para a formação de preços no mercado internacional hoje são os preços *spot* e futuros dos petróleos WTI e Brent

transacionados respectivamente na *New York Mercantile Exchange* (NYMEX) e na *International Petroleum Exchange* (IPE) e os preços são determinados com base em prêmios ou descontos em relação a estes referenciais. Os prêmios ou descontos refletem as características dos diferentes tipos de petróleo, locais de entrega e, assim, as condições entre oferta e demanda. Existe a suposição de que um aumento na participação de especuladores pode ser responsável por um aumento na volatilidade condicional dos retornos dos preços do petróleo que vem ocorrendo nos últimos anos.

Isto posto, neste artigo utiliza-se o modelo de heterocedasticidade condicional autorregressiva, ARCH (Autoregressive Conditional Heteroskedasticity) para caracterizar e analisar a volatilidade das séries de retornos mensais do barril de petróleo e, adicionalmente, apresentar uma opção de modelagem dos parâmetros GARCH (p, q) que melhor se adapte à série temporal pela metodologia Box-Jenkins.

A finalidade deste trabalho é contribuir para a literatura disponível sobre projeções dos preços do barril de petróleo e sua aplicação em modelos de previsão de séries temporais. E, dessa maneira, ajudar na formação de expectativas futuras por parte dos agentes econômicos, além fornecer subsídios para o delineamento de estratégias adequadas para o gerenciamento do risco de variações nos preços (retornos) destas *commodities*.

O trabalho contém quatro seções sendo a primeira, esta introdução. A segunda seção aborda o referencial teórico e a metodologia empregada; a terceira seção apresenta os resultados obtidos com os modelos utilizados e, finalmente, a última seção apresenta as principais considerações finais deste trabalho.

2. REFERENCIAL TEÓRICO

Conforme Bueno (2015), as séries temporais do mercado financeiro possuem dependências temporais de ordem superior conhecidas como perturbações aleatórias consideradas em seus momentos incondicionais. Essas dependências expressam a existência de aglomerações de aglomerações na série e a alternância de período de baixa volatilidade com períodos de alta volatilidade.

Desta forma, os modelos de heterocedasticidade condicional surgiram principalmente porque a importância do risco da incerteza na teoria econômica moderna tornou-se proeminente e pelo fato de modelos como o modelo *Capital Asset Pricing* (CAPM) de Sharpe (1977) não funcionarem tão bem empiricamente. Talvez fosse necessário incluir momentos de ordem maior no modelo CAPM para aproximá-lo dos dados empíricos.

Assim, desenvolveram-se técnicas que permitem a modelagem temporada das variâncias e covariâncias. Os modelos de heterocedasticidade condicional (GARCH) fundamentam-se na estimação de variância condicional, em vez de considerá-la constante ao longo do tempo. A contribuição principal destes modelos é a distinção do uso entre momentos de segunda ordem condicionais e não condicionais. Enquanto a matriz de covariância não condicional para as variáveis de interesse pode ser invariante no tempo, a matriz de covariância condicional depende dos estados passados da natureza. Empiricamente, observa-se que as séries financeiras não tem distribuição normal padrão, em geral, dada a elevada probabilidade de eventos extremos. Então, os modelos ARCH/GARCH teriam a capacidade de modelar esse fato estilizado.

Segundo Gujarati (2011), as análises de séries temporais como preços de ações, taxas de inflação e taxas de câmbio possuem autocorrelação entre si que recebe nomes como heterocedasticidade condicional autorregressiva (ARCH - Autoregressive Conditional Heteroscedasticity) e, se a variância do erro estiver relacionada com o termo de erro elevado ao quadrado no período anterior, chamada de heterocedasticidade condicional autorregressiva generalizada (GARCH - Generalized Autoregressive Conditional Heteroscedasticity), se a variância do erro estiver relacionada com os termos de erro elevados ao quadrado em vários períodos anteriores.

Os modelos GARCH, inicialmente proposto por Engle (1982), como ARCH, e generalizado por Bollerslev (1986) fornecem uma maneira de modelar uma mudança na variância de uma série temporal dependente do tempo. A principal diferença entre eles seria o fato de que enquanto o modelo ARCH(q) demonstra que a variância condicional, ou volatilidade, em um determinado período, depende da magnitude de uma série de

retornos ao quadrado (ou erros quadráticos), em “q” períodos anteriores, o modelo GARCH(p,q) vai além com componente adicional, sendo este a variância condicional em “p” períodos anteriores. O modelo GARCH (p,q) possui um termo autorregressivo, como em ARCH(q), com a adição de um termo de média móvel. O termo autorregressivo (p) modela a variância condicional dos erros quadráticos ou simplesmente modela a variância condicional da série temporal ao quadrado, já a parte de média móvel (q) modela a variação do processo. Outro motivo relevante para se usar o modelo GARCH, é que ele pode capturar a aglomeração da volatilidade, ou *clusters* de volatilidade, sofrida por séries financeiras. Os preços dos ativos são caracterizados por esse fenômeno, que se trata de períodos nos quais os preços exibem grandes variações para um longo período seguido por um período de tranquilidade comparativa.

Existem hoje muitas variantes do modelo GARCH, a maioria das quais fornece apenas melhorias marginais no modelo original. Entre essas extensões do modelo GARCH, estão o Integrated GARCH, Exponential GARCH ou EGARCH, GJR-GARCH e outras. A família de modelos GARCH é amplamente utilizada na prática para prever a volatilidade e os retornos do mercado financeiro.

3. METODOLOGIA

Nesta seção formalizam-se os modelos de heteroscedasticidade condicional auto-regressiva (ARCH) que foram utilizados e os procedimentos de inferência adotados, serão estimadas as variantes utilizadas do modelo original, a saber, o modelo GARCH. A variância condicional fornecida por estes modelos é utilizada como *proxy* para a volatilidade do retorno da *commodity* considerada.

3.1 Modelo ARCH (q)

O primeiro modelo foi apresentado por Engle (1982) em que o ϵ_t (termo de erro, resíduo de retorno, em relação a um processo médio) é um processo estocástico real em tempo discreto, condicional a informação em $t - 1$. Suponha-se que se queira estimar o Modelo ARIMA (p, 0, q), o erro desse processo segue um processo ARCH com ϵ_t divididos em uma peça estocástica z_t e um

desvio padrão dependente de tempo σ_t caracteriza o tamanho típico do termo, de modo que:

$$\epsilon_t = \sigma_t z_t; \quad (I)$$

dado que a variável aleatória z_t é um processo forte de ruído branco³, a série σ_t^2 é modelada por:

$$\alpha_0 + \sum_{i=1}^q \alpha_i \epsilon_{t-i}^2, \quad (II)$$

em que $\alpha_0 > 0$ e $\alpha_i \geq 0; i > 0$.

Um modelo ARCH (q) pode ser estimado usando mínimos quadrados ordinários (MQO)⁴, uma metodologia para testar a extensão do atraso dos erros ARCH usando o teste do multiplicador de Lagrange foi proposta por Engle (1982). O procedimento segue os passos abaixo:

1. Estime o modelo auto regressivo AR(q) mais adequado

$$y_t = \alpha_0 + \alpha_1 y_{t-1} + \dots + \alpha_q y_{t-q} + \epsilon_t = \alpha_0 + \sum_{i=1}^q \alpha_i y_{t-i} + \epsilon_t \quad (III)$$

2. Obtenha os quadrados do erro ϵ_t^2 e regresse-os em uma constante e q valores atrasados;

$$\hat{\epsilon}_t^2 = \hat{\alpha}_0 + \sum_{i=1}^q \hat{\alpha}_i \hat{\epsilon}_{t-i}^2, \quad (IV)$$

sendo q, a extensão dos atrasos ARCH.

Neste caso a hipótese nula é que na ausência de componentes ARCH, temos $\alpha_i = 0$ para todo $i = 1, 2, 3, \dots, q$. Por outro lado, a hipótese alternativa é que na presença de componentes ARCH pelo menos um dos coeficientes estimados deve ser significativo a 1%, 5% ou 10%.

Na literatura atual os modelos puramente ARCH (q) são considerados difíceis de serem utilizados pois necessitam de muitos parâmetros para serem ajustados corretamente, por este motivo foi desenvolvido o Modelo GARCH que é detalhado no tópicos a seguir.

3.2 Modelo GARCH (p,q)

Uma das variações do modelo ARCH é o mais conhecido entre os desenvolvidos e é chamado de modelo de heterocedasticidade condicional autorregressiva generalizada (GARCH),

originalmente proposto por Bollerslev (1986). O modelo GARCH mais simples é o modelo GARCH (1, 1), que pode ser escrito da seguinte forma:

$$\sigma_t^2 = \alpha_0 + \alpha_1 u_{t-1}^2 + \alpha_2 u_{t-1}^2, \quad (V)$$

que informa que a variância condicional de u no período t depende não apenas do termo de erro quadrático no período de tempo anterior como em ARCH(1), mas também de sua variância condicional no período de tempo anterior. Esse modelo pode ser generalizado para um modelo GARCH (p, q) no qual há p termos defasados do termo de erro quadrático e q termos das variâncias condicionais defasadas.

O modelo GARCH (p, q) pode ser interpretado como um processo auto regressivo em ϵ_t^2 . Abaixo detalha-se o modelo na equação final abaixo:

$$\epsilon_t^2 = \omega + \sum_{i=1}^{\max\{p,q\}} (\alpha_i + \beta_j) \epsilon_{t-i}^2 - \sum_{j=1}^p \beta_j v_{t-j} + v_t \quad (VI)$$

A última equação se parece com um modelo ARMA [$\max\{p,q\}, p$], sugerindo que a identificação do modelo GARCH pode seguir a mesma metodologia proposta por Box-Jenkins. Essa metodologia vale para a identificação de modelos GARCH quando se trata de fato de um modelo GARCH, em vez de um modelo assimétrico e isso nem sempre é fácil ser verificado.

As restrições impostas sobre os coeficientes dos modelos GARCH de que eles devem ser todos maiores que zero podem ser relaxadas.

4. DADOS UTILIZADOS

Os dados utilizados para o trabalho de abordagem da metodologia referem-se aos resultados mensais do preço do barril de petróleo Brent em reais entre 03 de janeiro de 2012 e 14 de outubro de 2022. Os números foram extraídos do Portal Investing.com (uma plataforma de mercados financeiros que oferece dados em tempo real e cotações em tempo real).

³ O ruído branco ocorre quando amostras são vistas como uma sequência de variáveis aleatórias não auto correlacionadas com média zero e variância finita. Já quando há uma única ocorrência de ruído branco é um choque aleatório.

⁴ É uma técnica de otimização matemática que procura encontrar o melhor ajuste para um conjunto de dados tentando minimizar a soma dos quadrados das diferenças entre o valor estimado e os dados observados (tais diferenças são chamadas resíduos).

5. RESULTADOS OBTIDOS

Obteve-se a série temporal dos valores históricos do barril de petróleo tipo Brent para análise da taxa

de retorno e volatilidade do ativo a partir de um *site* externo e independente. No eixo X está identificado o tempo e no eixo Y, o valor em reais do barril de petróleo Brent, conforme apresentado no Gráfico 1:



Gráfico 1: Evolução do preço em reais do barril de Petróleo (Brent)

A variável em nível possui variações movimentações durante o período que dificultam a análise de volatilidade pelo modelo ARCH/GARCH, principalmente porque podem apresentar parâmetros não significativos à análise. O gráfico possui um padrão decrescente em todo seu período analisado com pequenas variações positivas e negativas em alguns observados.

Com o intuito de identificar a taxa de retorno do ativo foi realizada a primeira diferença logarítmica da série temporal denominada *Id_PETR_BRENT*. Agora, com a primeira diferença obtida, perde-se a

primeira observação da série (01.2012) e apresenta-se a taxa de retorno, conforme gráfico a seguir:

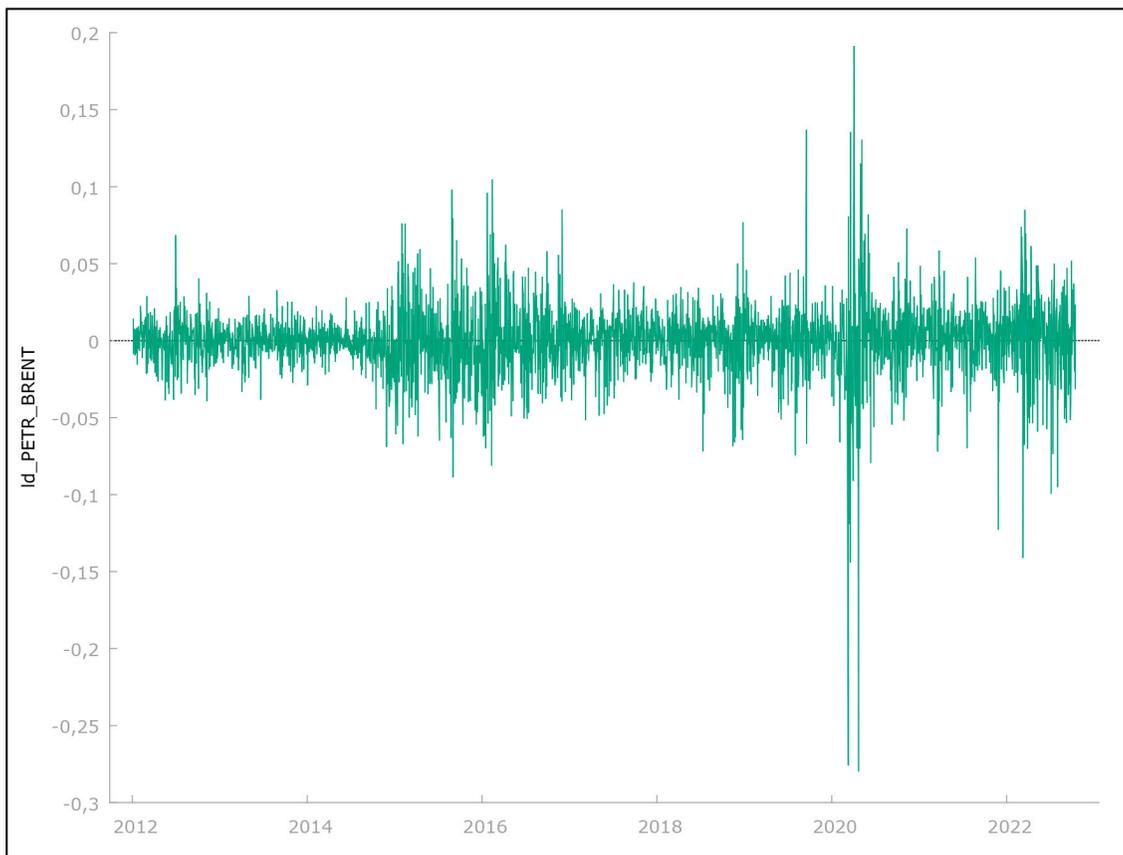


Gráfico 2: Taxa de retorno dos preços do barril de petróleo (Brent)

A partir da análise gráfica pode-se identificar pontos com grandes variações no gráfico, como em fevereiro de 2020 à maio de 2020. Estas variações significativas na série temporal são chamadas na econometria de *clusters* e referem-se a momentos críticos da *commodity* na economia internacional e podem indicar heterocedasticidade na série, ou seja, podem ajudar a identificar o efeito ARCH.

Ao traçar um paralelo a este trabalho pode-se relacionar estas variações significativas no tempo do preço do petróleo Brent ao impacto inicial que a pandemia do coronavírus causou em todo mundo, fazendo com que países decretassem *lockdowns*, diminuições nas produções, comércio, atividades externas e etc., com o principal intuito de diminuir o contágio do vírus. O impacto não perdurou nos preços do petróleo por muito tempo, tanto que pode-se identificar uma tendência

posterior a estes clusters de atingir as variações de período anteriores à 2020 ocasionadas pelos retornos periódicos das atividades econômicas, aumentando assim a demanda por bens originários do petróleo.

Após análise gráfica inicial deve-se testar se os resíduos são normalmente distribuídos utilizando como base a primeira defasagem da série em formato logaritmo ou retorno do ativo (como variável dependente) e a primeira diferença da taxa de retorno da *commodity* (variável explicativa). No quadro abaixo apresenta-se os resultados do teste de MQO (Mínimos Quadrados Ordinários):

Modelo 2: MQO, usando as observações 2012-01-05:2022-10-14 (T = 2812)				
Variável dependente: ld_PETR_BRENT				
	coeficiente	erro padrão	razão-t	p-valor
const	-7,61923e-05	0,000447439	-0,1703	0,8648
ld_PETR_BRENT_1	0,00911114	0,0188685	0,4829	0,6292
Média var. dependente	-0,000077	D.P. var. dependente		0,023724
Soma resid. quadrados	1,581924	E.P. da regressão		0,023727
R-quadrado	0,000083	R-quadrado ajustado		-0,000273
F(1, 2810)	0,233168	P-valor(F)		0,629222
Log da verossimilhança	6531,056	Critério de Akaike		-13058,11
Critério de Schwarz	-13046,23	Critério Hannan-Quinn		-13053,82
rô	0,000125	h de Durbin		NA

Quadro 1: Teste de MQO para *ld_BRENT_REAL*

No quadro identifica-se que a primeira defasagem do modelo identificada como *ld_PETR_BRENT_1* possui um p-valor de 0,6292, ou seja, a variável parece não ser estatisticamente significativa a 10% e identificar que o passado pode explicar o presente na série temporal diretamente, porém precisamos continuar com a metodologia seguindo outros testes para identificar a heterocedasticidade no modelo.

Pode-se salvar os resíduos ao quadrado do modelo MQO com o intuito de identificar se existem clusters nos resíduos apresentados também. No gráfico 3 apresentado a seguir identificam-se clusters nos resíduos ao quadrado (representado por *usq2*) da série temporal, o que pode indicar heterocedasticidade do modelo, apesar dos valores do MQO inicialmente não serem estatisticamente significativos:

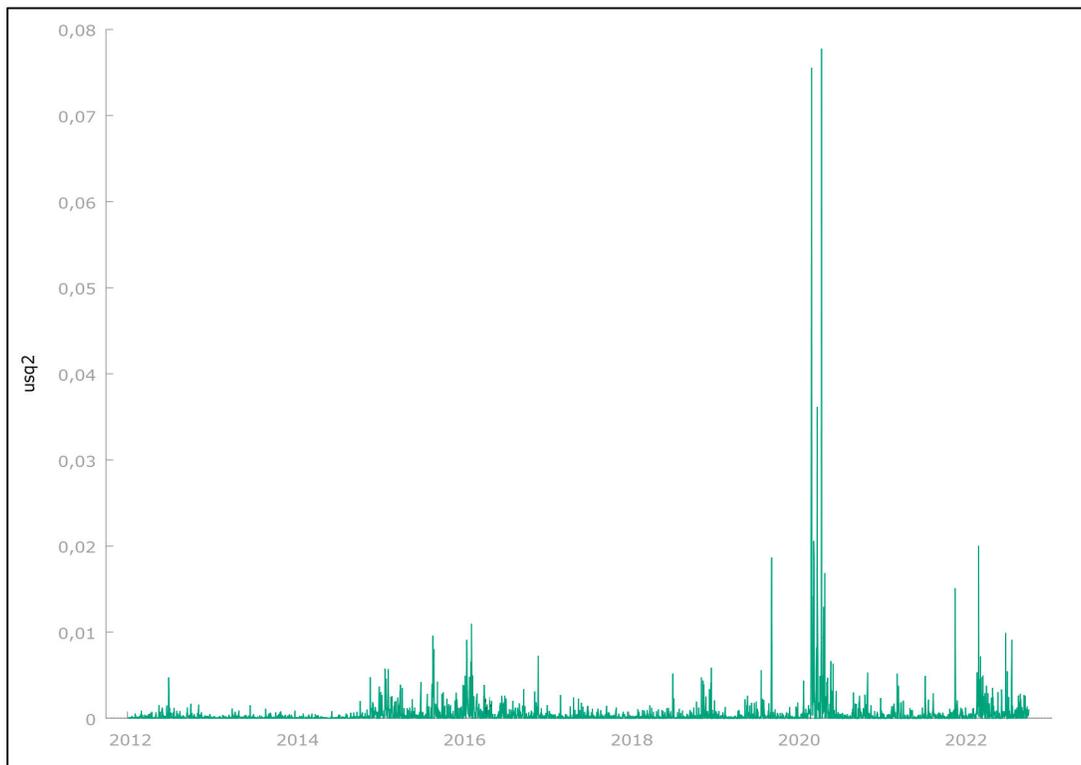


Gráfico 3: Taxa de retorno dos preços do barril de petróleo (Brent)

O passo seguinte sugerido para identificar se a série temporal possui características do modelo ARCH/GARCH apresenta-se no quadro abaixo. O teste de normalidade dos resíduos possui a intenção de identificar se os resíduos são

normalmente distribuídos ou se realmente existe problema de heterocedasticidade no modelo. O Gráfico 4 apresenta o teste de normalidade dos resíduos da série defasada:

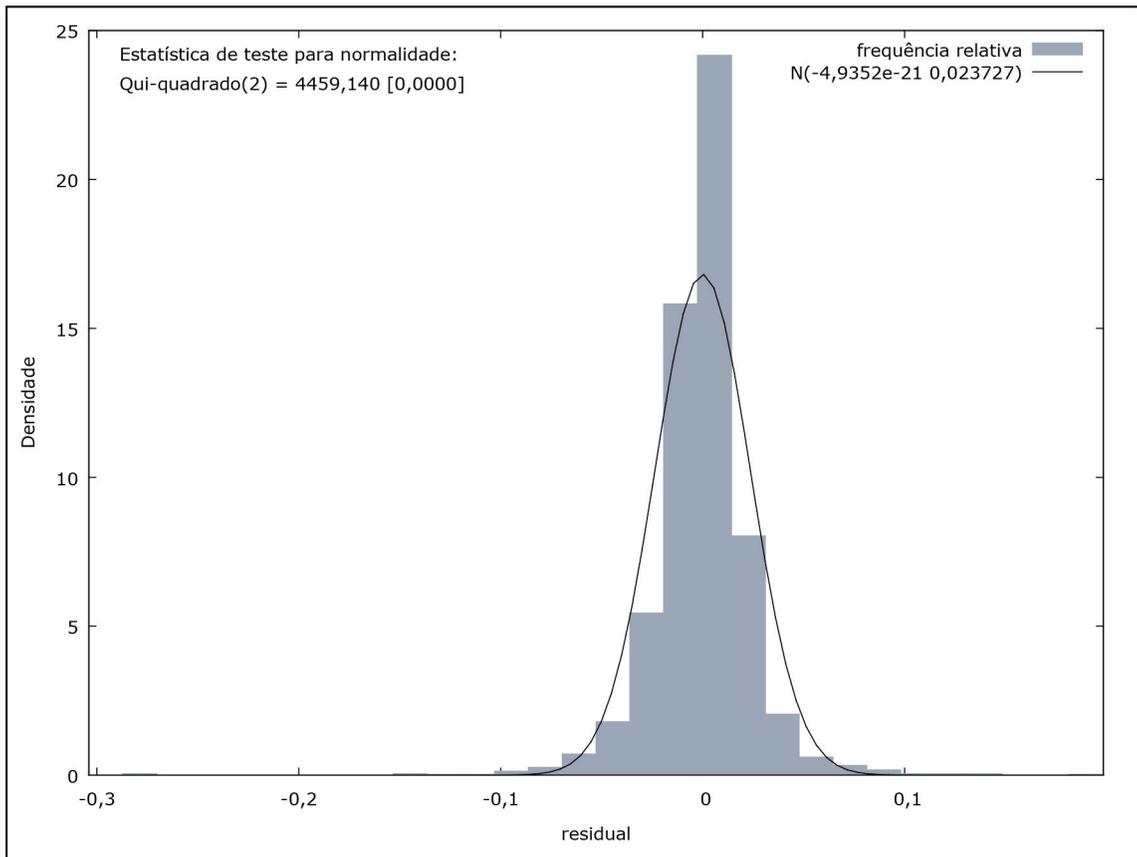


Gráfico 4: Teste de normalidade dos resíduos

A curva apresentada no gráfico sugere que os resíduos não são normalmente distribuídos pois as barras gráficas não são simétricas dos dois lados, resultando em curva leptocúrtica. O quadro a seguir apresenta os resultados do teste

Jaque-Bera⁵ para verificar se os resíduos são normalmente distribuídos:

⁵ Em estatística, o teste de Jarque-Bera é um teste de adequação para verificar se os dados da amostra têm a assimetria e curtose correspondentes a uma distribuição normal. O teste tem o nome de Carlos Jarque e Anil K. Bera.

Distribuição de frequência para residual, observações 3-2814
 número de classes = 29, média = -4,9352e-021, desvio padrão = 0,0237268

intervalo	pt. médio	frequência	rel.	acum.
< -0,27046	-0,27883	2	0,07%	0,07%
-0,27046 - -0,25371	-0,26209	0	0,00%	0,07%
-0,25371 - -0,23696	-0,24534	0	0,00%	0,07%
-0,23696 - -0,22022	-0,22859	0	0,00%	0,07%
-0,22022 - -0,20347	-0,21184	0	0,00%	0,07%
-0,20347 - -0,18672	-0,19510	0	0,00%	0,07%
-0,18672 - -0,16998	-0,17835	0	0,00%	0,07%
-0,16998 - -0,15323	-0,16160	0	0,00%	0,07%
-0,15323 - -0,13648	-0,14486	2	0,07%	0,14%
-0,13648 - -0,11974	-0,12811	1	0,04%	0,18%
-0,11974 - -0,10299	-0,11136	1	0,04%	0,21%
-0,10299 - -0,086242	-0,094616	6	0,21%	0,43%
-0,086242 - -0,069495	-0,077869	12	0,43%	0,85%
-0,069495 - -0,052748	-0,061122	33	1,17%	2,03%
-0,052748 - -0,036002	-0,044375	84	2,99%	5,01% *
-0,036002 - -0,019255	-0,027628	256	9,10%	14,12% ***
-0,019255 - -0,0025076	-0,010881	745	26,49%	40,61% *****
-0,0025076 - 0,014239	0,0058658	1138	40,47%	81,08% *****
0,014239 - 0,030986	0,022613	378	13,44%	94,52% *****
0,030986 - 0,047733	0,039360	96	3,41%	97,94% *
0,047733 - 0,064480	0,056107	28	1,00%	98,93%
0,064480 - 0,081227	0,072854	15	0,53%	99,47%
0,081227 - 0,097974	0,089601	8	0,28%	99,75%
0,097974 - 0,11472	0,10635	2	0,07%	99,82%
0,11472 - 0,13147	0,12309	2	0,07%	99,89%
0,13147 - 0,14821	0,13984	2	0,07%	99,96%
0,14821 - 0,16496	0,15659	0	0,00%	99,96%
0,16496 - 0,18171	0,17334	0	0,00%	99,96%
>= 0,18171	0,19008	1	0,04%	100,00%

Teste para a hipótese nula de distribuição normal:
 Qui-quadrado (2) = 4459,140 com p-valor 0,00000

Quadro 2: Teste de normalidade dos resíduos

A hipótese nula do teste Jaque-Bera é que os resíduos são normalmente distribuídos e, o quadro 2 indica-se que o p-valor deste teste é 0,00 e, portanto, os resíduos não são normalmente distribuídos, rejeitando assim a hipótese nula do teste.

Um dos últimos testes informais antes de testar efetivamente o teste ARCH na série temporal é identificar se o p-valor é estatisticamente significativo também no teste de White⁶ para heterocedasticidade. A hipótese nula neste caso é que os resíduos seriam normalmente distribuídos e homocedásticos com um resultado do p-valor > 0,1. No quadro 3 apresentam-se os resultados do teste:

Teste de White para a heteroscedasticidade
 MQO, usando as observações 2012-01-05:2022-10-14 (T = 2812)
 Variável dependente: uhat^2

	coeficiente	erro padrão	razão-t	p-valor
const	0,000444478	4,79208e-05	9,275	3,43e-020 ***
ld_PETR_BRENT_1	-0,00154829	0,00202169	-0,7658	0,4438
sq_ld_PETR_BRE~_1	0,209824	0,0188054	11,16	2,56e-028 ***

R-quadrado não-ajustado = 0,046034

Estatística de teste: TR^2 = 129,447204,
 com p-valor = P(Qui-quadrado (2) > 129,447204) = 0,000000

Quadro 3: Teste de White para heterocedasticidade

6 O teste de White é um teste estatístico para detectar a presença de heteroscedasticidade geral em um modelo matemático.

Conclui-se que a série temporal possui problema de heterocedasticidade em alguns dos testes apresentados. O próximo passo da análise é fazer o

teste para identificar o efeito ARCH. No quadro a seguir apresenta-se os resultados obtidos com o teste ARCH no MQO do modelo considerando 5 defasagens:

Teste ARCH de ordem 5					
	coeficiente	erro padrão	razão-t	p-valor	
alpha (0)	0,000338931	4,99698e-05	6,783	1,43e-011	***
alpha (1)	0,194839	0,0188257	10,35	1,16e-024	***
alpha (2)	0,00841383	0,0191661	0,4390	0,6607	
alpha (3)	0,0684081	0,0191230	3,577	0,0004	***
alpha (4)	0,0417120	0,0191659	2,176	0,0296	**
alpha (5)	0,0855044	0,0188254	4,542	5,81e-06	***

Hipótese nula: efeito ARCH não está presente
 Estatística de teste: LM = 177,972
 com p-valor = P(Qui-quadrado(5) > 177,972) = 1,45084e-36

Quadro 4: Teste ARCH (1)

No teste ARCH apresentado pode-se concluir que a série temporal possui efeito ARCH ao verificar o p-valor de um valor muito próximo de 0 (p-valor=1,45084e-36). Sendo assim, é possível rejeitar a hipótese nula de ausência do efeito ARCH no modelo.

A primeira etapa do enquadramento da série temporal ao modelo ARCH/GARCH foi concluído, pois entende-se a partir dos testes acima citados que o modelo possui heterocedasticidade e o efeito ARCH.

Dado que adotou-se a hipótese de normalidade dos resíduos dos modelos ajustados para a média condicional dos retornos na estimação

dos modelos e considerando a evidência de não normalidade fornecida pelo teste de Jarque & Bera (1987) para os resíduos de ambos os modelos (p-valor=0,000), adotou-se a matriz de variância covariância corrigida proposta por Bollerslev e Wooldridge (1992), no procedimento de estimação dos modelos da classe ARCH.

O modelo GARCH utiliza as variáveis retorno do ativo como variável dependente (*ld_PETR_BRENT*) e os resíduos ao quadro do modelo como variável explicativa (*usq2*). Na tabela a seguir apresentam-se os resultados do modelo GARCH (1,1) para análise da taxa efetiva de retorno, volatilidade e recuperação dos choques na série temporal:

Funções calculadas: 115					
Cálculos de gradientes: 25					
Modelo 4: GARCH, usando as observações 2012-01-05:2022-10-14 (T = 2812)					
Variável dependente: ld_PETR_BRENT					
Erros padrão baseados na Hessiana					
	coeficiente	erro padrão	z	p-valor	
const	0,000871538	0,000309844	2,813	0,0049	***
usq2	-2,28571	0,250058	-9,141	6,20e-020	***
alpha (0)	4,92657e-06	1,25574e-06	3,923	8,74e-05	***
alpha (1)	0,103931	0,0104321	9,963	2,22e-023	***
beta (1)	0,893310	0,00997413	89,56	0,0000	***
Média var. dependente	-0,000077		D.P. var. dependente	0,023724	
Log da verossimilhança	7167,064		Critério de Akaike	-14322,13	
Critério de Schwarz	-14286,48		Critério Hannan-Quinn	-14309,26	
Variância do erro incondicional = 0,00178601					
Teste de razão de verossimilhança para termos (G)ARCH:					
Qui-quadrado(2) = 1132,07 [1,49096e-246]					
Teste da normalidade dos resíduos -					
Hipótese nula: o erro tem distribuição Normal					
Estatística de teste: Qui-quadrado(2) = 1687,44					
com p-valor = 0					

Quadro 5: Modelo GARCH (1,1)

O passo seguinte foi modelar a volatilidade dos retornos condicionais do barril de petróleo Brent, levando em consideração o padrão heterocedástico da volatilidade. Isto foi implementado ajustando-se o modelo GARCH à volatilidade do modelo ajustado para a média condicional dos retornos. Dado que adotou-se a hipótese de normalidade dos resíduos do modelo ajustado para a média condicional dos retornos na estimação do modelo e considerando a evidência de não normalidade fornecida pelo teste de Jarque-Bera para os resíduos de ambos os modelos (p -valor=0,000), adotou-se a matriz de variância e covariância corrigida proposta por Bollerslev e Wooldridge (1992), no procedimento de estimação do modelo.

Os resultados da estimação para a média condicional e a volatilidade dos retornos do barril de o petróleo foram apresentados no Quadro 5. O valor de Alpha (α_1) é igual a 0,103931 e é considerado extremamente baixo para indicar o retorno do ativo, ou seja, o retorno do investimento desta *commodity* é baixo. O valor de Beta (β_1) no modelo GARCH (1,1) é igual a 0,893310, indicando que um choque na série dos retornos terá efeito por vários períodos na volatilidade destes retornos. Os indicadores da qualidade do ajuste mostraram que todos os modelos ajustados tiveram um desempenho bastante adequado pois, considerando que ($\alpha_1 + \beta_1 < 1$), identifica-se que o modelo é considerando estável estatisticamente. Além disso, para o modelo GARCH (1,1) todos os parâmetros apresentados no Quadro 5 são estatisticamente significativos a 1%, 5% e 10%.

6. CONCLUSÃO

Os resultados empíricos sugerem que um choque que gere um declínio do preço e, portanto dos retornos da *commodity* pode implicar em vários períodos de intensa volatilidade nos mercados desta *commodity* que, por sua vez, podem gerar perdas consideráveis para os respectivos setores e para a economia, devido à assimetria, que implica que choques negativos podem ter um impacto maior que choques positivos, e à persistência de choques sugerida pelos modelos estimados cuja implicação é a de que choques sobre a volatilidade podem levar vários períodos para dissiparem-se.

Neste estudo efetuou-se uma análise empírica da volatilidade dos retornos do barril de petróleo Brent utilizando modelos da classe ARCH/GARCH.

Verificou-se que choques sobre a série temporal no período analisado tendem a repercutir por longos períodos. A situação do mercado de petróleo nos últimos anos fornece evidências a favor deste resultado, pois parece ter havido um choque de oferta positivo que derrubou o preço no início da década seguidos de demandas significativas causados principalmente pelo início do período pandêmico do coronavírus. O efeito de tal choque sobre a volatilidade, pelos resultados empíricos, tende a levar vários períodos para dissipar-se. No que tange às implicações sobre formulação de políticas, os resultados empíricos sugerem que a criação e o fomento da utilização de instrumentos de *hedging* baseados no mercado podem ser estratégias adequadas diante da grande volatilidade e persistência acentuada de choques sobre a volatilidade verificadas para os retornos desta *commodity*.

7. REFERÊNCIAS

- BOLLERSLEV, Tim. Generalized autoregressive conditional heteroskedasticity. *Journal of econometrics*, v. 31, n. 3, p. 307-327, 1986.
- BOLLERSLEV, Tim; WOOLDRIDGE, Jeffrey M. Quasi-maximum likelihood estimation and inference in dynamic models with time-varying covariances. *Econometric reviews*, v. 11, n. 2, p. 143-172, 1992.
- BUENO, Rodrigo de Losso da Silveira. **Econometria de séries temporais**. São Paulo: Cengage Learning, 2. ed., 2015.
- ENGLE, Robert F. Autoregressive conditional heteroskedasticity with estimates of the variance of UK inflation. *Econometrica*, v. 50, p. 1-50, 1982.
- ENGLE, Robert F. A general approach to Lagrange multiplier model diagnostics. *Journal of Econometrics*, v. 20, n. 1, p. 83-104, 1982.
- GUJARATI, Damodar N.; PORTER, Dawn C. **Econometria básica**. Porto Alegre: Bookman, 5. ed. 2011.
- PORTAL INVESTING. Disponível em: <<https://br.investing.com/commodities/brent-oil>>. Acesso em 10/2022.
- SHARPE, William F. The capital asset pricing model: a "multi-beta" interpretation. In: **Financial Dec Making Under Uncertainty**. Academic Press, 1977. p. 127-135.