



## **Quebra Estrutural: Análise da influência das informações de mercado no preço de uma opção de Petrobrás**

**JOÃO PEDRO FERNANDES**

*Universidade de São Paulo (USP)*

**JARDEL CHAVES COSTA**

*Universidade de São Paulo (USP)*

**FABIANO GUAISTI LIMA**

*Universidade de São Paulo (USP)*

**ANTÔNIO CARLOS DA SILVA FILHO**

*Centro Universitário Municipal de Franca (Uni-FACEF)*

### **Resumo**

Esta pesquisa tem como objetivo realizar um estudo da opção PETRN265, opção de venda da Petrobras. A escolha dessa opção é justificada de acordo com Gaspar (2021) por uma suposta operação de *insider trading*. Buscar evidências diante das flutuações dos preços antes da data dos anúncios relevantes pode revelar as características das negociações com informações privilegiadas. Assim, coletou-se cotações *intraday* por meio plataforma ProfitChart Pro® durante o período de 04/01/2021 a 19/02/2021, obtendo um total de 4591 observações. Os resultados demonstram que as variáveis utilizadas apresentam fraca correlação e em sua maioria não significantes. Quanto as quebras estruturais, nota-se cinco quebras para o período de 1 semana e quatro quebras para o período de 3 dias, sendo originadas em determinados eventos históricos. A série apresentou uma modelagem ARIMA (0,0,2) – eGARCH (1,1) – GED, indicando que a variância dos retornos de PETRN265 está sujeita à assimetria, ou seja, tanto os choques positivos quanto os negativos terão um impacto significativo (assimétrico) na volatilidade. Por fim, notou-se que os retornos extrapolam o intervalo de confiança da previsão nas primeiras horas do dia 18, mas mantendo-se dentro do intervalo de confiança no dia 19. Quanto à previsão do VaR, o modelo apresenta uma capacidade limitada para prever os dados no período de 18 e 19 de fevereiro devido aos picos de volatilidade e às quebras estruturais encontradas, para mediar a acurácia das previsões utilizou-se as medidas MAE (erro absoluto médio), RMSE (raiz quadrada do erro médio quadrático) e o MAPE (erro percentual absoluto médio). Dentre as quais o RMSE foi escolhido por ser a medida mais sensível a grandes mudanças.

**Palavras-chave:** ARIMA-GARCH, Opção, Quebra Estrutural.



São Paulo 27 a 29 de julho 2022.

## 1. Introdução

No Brasil e no mundo, o volume de negócios de contratos futuros e de opções vem aumentando nos últimos anos, sendo o ano de 2020, de acordo com a FIA - *Futures Industry Association* (2021), à um novo recorde de negociação em bolsas globais de futuros e opções.

É comum os agentes do mercado financeiro, na busca pela proteção de carteira, utilizam desses derivativos como meio para realização de operações de proteção dos seus ativos financeiros. Obviamente, risco sempre foi um tema amplamente discutido no mercado financeiro, e a gestão de risco se desenvolveu como uma ferramenta de mitigação no processo de controle e monitoramento de diversos riscos nas operações de mercado. Lima (2018) destacou que, desde Jorion (2009) a evolução das ferramentas de gestão de risco existe, e se deve ao surgimento de métodos estatísticos e matemáticos, cuja motivação é mensurar possíveis perdas nas operações do mercado financeiro.

De acordo com o Valor Investe (2021) o mercado brasileiro de opções tem alta concentração de volume de negócios nos documentos da Petrobras e da Companhia Vale do Rio Doce. Cabe destacar que, conforme Exame (2021), a opção PETRN265 foi investigada pela CVM por suposta “operações atípicas, que sugerem o uso de informações privilegiadas (ou *insider trading*)” (Gaspar, 2021). Com a ajuda de informações confidenciais, como anúncios de fusões e mudanças de CEO, os *insiders* podem prever tendências do mercado financeiro e obter lucros excedentes comprando e vendendo ativos antes do anúncio (Eizirik, 1983).

Identificar negociações com informações privilegiadas não é fácil. No entanto, a busca por evidências por meio de flutuações de preços antes da data dos anúncios relevantes pode revelar as características das negociações com informações privilegiadas. Assim, esse artigo realiza um levantamento da opção de venda PETRN265 da Petrobras por meio de testes econométricos adequados para identificar quebras estruturais na série, modelagem ARIMA-GARCH e previsão dos retornos e VaR, de forma que eventos históricos possam ser inferidos e terem seus efeitos analisados.

Através dessa análise de quebras estruturais, é possível idealizar os fatores que possam ter ocasionado riscos envolvidos no papel, pois tais quebras significam a possibilidade da existência de um evento, potencialmente forte, que tenha alterado a sua tendência, tornando possível assimilar como tal fato contribuiu para o risco do papel. Entretanto, cabe destacar que a análise de aglomerações atípicas de volatilidade não implica, necessariamente, em quebras estruturais.

Assim, este artigo não apenas preenche a lacuna da pesquisa relacionadas a operações que envolvam *insider trading*, (Silva, 2014; Silva & Machado, 2014; e Martins, Paulo, & Girão, 2016), ao analisar derivativos (opções), e seus impactos nas projeções dos preços, mas como também realiza um estudo por meio de uma janela de negociação menor, ou seja, *intraday* minuto a minuto, como também adiciona novas análises para ajudar os investidores e agente de mercado a identificar riscos potenciais prevendo o desempenho desse ativo.

Este artigo está organizado em cinco seções. A primeira apresenta a introdução. A segunda seção evidencia o referencial teórico, juntamente com os estudos anteriores. A terceira seção descreve sobre a metodologia utilizada, identificando os dados utilizados na pesquisa e os procedimentos econométricos realizados. Por fim, as seções quatro e cinco abrangem as análises dos resultados e as considerações finais, respectivamente.

## 2. Referencial teórico

### 2.1. Mercado de opções

A popularidade do mercado de opções advém desde abril de 1973, ano de criação da *Chicago Board Options Exchange*. Essa bolsa tinha como objetivo específico realizar



São Paulo 27 a 29 de julho 2022.

negociações de opções de ações. Desde então, outras bolsas também deram início a esse mecanismo de negociação, tais como: *American Stock Exchange*, *Philadelphia Stock Exchange* e *Pacific Exchange* (Hull, 2005).

De acordo com Focaccia *et al.* (2002), o mercado de opções foi criado como um mecanismo de proteção ao mercado de ações, também conhecido como “operações de hedge”. Portanto, o objetivo é proteger o investidor contra possíveis perdas, assim os contratos de opções permitem que o investidor trave o preço de um ativo no futuro por um determinado tempo. Conforme Gonçalves e Sousa (2017), o titular (comprador) de uma opção adquire o direito, mas não a obrigação, de exercê-la sobre aquela opção cujo preço fora preestabelecido na negociação até o vencimento da opção. Já o lançador (vendedor) da opção de tem a obrigação de atender ao exercício caso o titular opte por exercer seu direito.

Os investidores que decidem por uma opção de compra (*call*) esperam obter ganho com o aumento do preço das ações associadas à opção. Para Júnior, Fonseca e Kamogawa (2006), o comprador de uma opção de compra espera que o preço do ativo associado à opção seja superior ao preço pelo qual a opção será exercida no futuro, ou seja, a diferença entre o preço de mercado e o preço do exercício permite ao comprador exercer o direito à opção de compra com lucro. O comprador de uma opção de venda (*put*) adota a premissa de que, no futuro, o preço de exercício da opção é superior ao preço de mercado do ativo que faz referência à opção e, portanto, os lucros podem ser obtidos a partir da diferença entre o preço de exercício e o preço de mercado.

As opções podem ser classificadas tanto como europeias ou americanas. Para a primeira, o titular da opção poderá exercer seu direito apenas na data de vencimento. As opções americanas, por sua vez, podem ser exercidas a qualquer momento dentro o período da compra até ao vencimento.

A literatura sobre opções é extensa no Brasil e no exterior. Observa-se que, no mercado, antes do vencimento das opções, compradores e vendedores se empenham em empurrar o preço da ação na direção mais conveniente. Nesse sentido, Sanvicente e Monteiro (2005) realizaram um estudo nos contratos de opções da Telemar S.A através do modelo de equação simultânea, e evidenciaram a existência de manipulação de preço no último dia de negociação do contrato de opção.

Diversos pesquisadores estudaram a volatilidade implícita como o poder preditivo da volatilidade futura e, em comparação com os resultados fornecidos por modelos baseados em dados históricos, os resultados da volatilidade implícita são mais promissores. Nesse sentido, Vicente e Guedes (2010) analisaram a relação entre a volatilidade implícita e o histórico de compra de opções pela Petrobras e a volatilidade realizada nos períodos subsequentes. Portanto, puderam concluir que não há correlação entre a volatilidade histórica e a volatilidade futura, ou seja, a volatilidade implícita contém mais informações sobre a volatilidade futura do que a volatilidade histórica.

Outras pesquisas relacionadas às opções também se concentram na previsão de preços e volatilidade. Há vários modelos de previsão de preços de opções, dentre os quais o mais popular é a fórmula de precificação de opções Black-Scholes. Além desta, alguns autores procuram usar o modelo GARCH para prever preços de opções. Gabe e Portugal (2004) estudaram a volatilidade futura por meio da volatilidade implícita usando o *procedimento back-out* do modelo Black-Scholes e previsão estatística da família ARCH, demonstrando que a previsão por meio do FIGARCH corresponde melhor as expectativas. No entanto, estudos realizados por Zhang, Sun e Meng (2019), Jiratumpadu e Chavanasporn (2016) e Bhat e Arekar (2016) mostram que o modelo de Black Scholes apresenta resultados melhores do que o modelo GARCH. Ao mesmo tempo, os resultados obtidos pelos pesquisadores Narayana, Liu e



São Paulo 27 a 29 de julho 2022.

Westerlund (2016) e Hendrawan (2010) foram contrários, comprovando que o modelo GARCH e seus derivados são superiores ao modelo Black Scholes na previsão de preços.

## 2.2. Insider trading

*Insiders* são aqueles que têm acesso direto às informações privilegiadas, geralmente diretores, gerentes, advogados e contadores. Portanto, os *insiders* tiram proveito dessas informações para obter vantagem indevida no mercado. De acordo com Knewtson e Nofsinger (2013), *insider trading* compreende a um modelo de negociação executado por detentores informações privilegiadas de mercado relevantes que podem gerar retornos anômalos para os mesmos.

Tendo em conta que as violações de informações privilegiadas cometidas por *insiders*, que são obrigados a agir no interesse dos acionistas e não nos interesses próprios, constituem atos ilegais em vários mercados e podem ser processados por esse motivo (Cohen, Malloy, & Pomorski, 2012). No Brasil, o uso de informações privilegiadas é crime desde a promulgação da Lei nº 10.303 / 2011, porém, após a edição da Instrução Normativa nº 358/2002, o uso de informações privilegiadas passou a ser mais notório. Escândalos e fraudes no mercado financeiro não são incomuns. Nesse sentido, pesquisa de Farias, Freitas e Vicente (2015) mostra que, de 2000 a 2013, ocorreram 39 casos de manipulação de mercado e abuso de informação privilegiada, dos quais 61% tiveram pelo menos um réu condenado, no mesmo período, também foram aplicadas 69 multas.

O objetivo de algumas pesquisas é detectar operações envolvendo *insider trading* por meio de detecção informações que posteriormente são divulgadas ao mercado. A pesquisa do autor Givoly e Palmon (1985) é exatamente assim. Eles realizaram uma pesquisa para identificar as subseqüentes divulgações das informações ocasionadas ao retorno anormal obtido com a variação do preço, sendo comprovado que o retorno era muito significativo antes da divulgação da informação. Chen e Chen (2007) descobriram que o mercado chinês teve um desempenho negativo em torno da data do anúncio relacionado ao mercado, mas respondeu positivamente durante o período pós-anúncio. Lorie e Niederhoffer (1968) mostraram que os proprietários que possuem 10% ou mais das ações em circulação tendem a comprar mais do que o normal antes do aumento do preço e a vender mais do que o normal antes que o preço caia.

No Brasil, Medeiros e Matsumoto (2006) estudaram retornos de ações relacionados a emissões públicas de 1992 a 2002. Eles usaram OLS para medir retornos anormais e os modelos de volatilidade de ARCH e GARCH para comprovar que havia evidências de informações privilegiadas antes da data do anúncio. Martins et al. (2016) analisaram a relação entre o preço das ações da OGX, divulgação de informações da empresa e a probabilidade de usar transações de informações privilegiadas (PIN) de 2008 a 2014, indicando que os preços dos ativos foram afetados positivamente por notícias do site, notificações da empresa e do mercado e fatos relacionados e negativamente pelos fatos relevantes e formulário ICVM 358.

## 3. Metodologia

Este trabalho análise os preços da opção PETRN265, essa opção, de estilo europeu, ou seja, o titular dessa opção só poderá exercer seu direito na data de vencimento, é referente a uma *put* da Petrobrás com o valor do exercício de R\$ 26,50, cujo vencimento deu-se em 22/02/2021, sendo o último dia de negociação em 19/02/2021. No delineamento da pesquisa, observou como lacuna a necessidade em analisar o risco inerente ao ativo em possível envolvimento no informações privilegiadas, demonstrando as limitações nas previsões em decorrência das quebras estruturais.

São Paulo 27 a 29 de julho 2022.

Os dados foram coletados através da plataforma ProfitChart Pro<sup>®</sup> da Neológica e todos os cálculos necessários foram realizados por meio do software livre R<sup>®</sup>, através do ambiente integrado de desenvolvimento RStudio<sup>®</sup>. Entre os pacotes básicos e específicos para análise de séries temporais foram utilizados os seguintes pacotes: "dgoj", "fBasics", "fGarch", "FinTS", "forecast", "fpp2", "graphs", "MTS", "quantmod", "stats", "strucchange", "tseries" e "urca". Coletou-se as cotações *intraday* (1 minuto) da PETRN265 entre o período de 04/01/2021 a 19/02/2021, sendo a janela de abertura e fechamento da opção, obtendo um total de 4591 observações.

A maioria das pesquisas financeiras concentra-se na análise de séries de retorno, em oposição às séries de preços de ativos. Tal explicação tem como base de que as informações sobre retornos são do interesse dos investidores e as séries de retornos têm características estatísticas mais interessantes do que as séries de preços. A Equação 1 representa a equação do log-retorno.

$$x_t = \ln(p_t) - \ln(p_{t-1}) \quad (1)$$

Sendo  $p_t$  o preço do ativo no período  $t$ , e  $x_t$  é a série dos retornos do período.

### 3.1. Análise de Correlação

A primeira análise a ser realizada neste trabalho é a correlação de *Spearman*. Nesse sentido, aplicou-se a correlação entre os fechamentos e retornos para com o volume de negociação e a quantidade de negócios. O período para análise ocorreu entre os dias 04/01/2021 até 19/02/2021, possuindo um total de 4591 observações, as quais foram comparadas com os resultados das correlações entre os dias 17, 18 e 19 de fevereiro, sendo antes, durante e depois do evento relacionado a possível negociação de informação privilegiada (Exame, 2021) compreendendo um total de 448 observações.

O Coeficiente de correlação de *Spearman* é um método não-paramétrico que o resultado pode variar de -1.00 a +1.00, quanto mais próximo de 1.00 maior será o nível de correlação. Na Equação 2 pode ser observado o cálculo do coeficiente de correlação de *Spearman*.

$$r_R = 1 - \frac{6 \sum_i d_i^2}{n(n^2 - 1)} \quad (2)$$

Sendo o  $n$  igual o numero de pontos de dados das duas variáveis e  $d_i^2$  a diferença de alcance do elemento "n".

### 3.2. Análise de quebra estrutural

A segunda parte da pesquisa buscou testar a hipótese de quebra estrutural. Portanto, separou a série em dois períodos, a primeira parte a série semanal, sendo do dia 10 ao dia 19 de fevereiro – não havendo negociações entre os dias 15 e 16 de fevereiro e dia 17 de fevereiro (até às 13h), por tanto com 890 observações. A segunda parte utilizou somente período de 3 dias, referindo-se aos dias 17, 18 e 19 de fevereiro, compreendendo um total de 448 observações.

A análise e pesquisa de quebra estrutural está relacionada à econometria por meio de dados de séries temporais, e uma ou mais mudanças na dispersão e/ou inclinação da sequência da série podem ser entendidas por meio de quebra estrutural. A base para os primeiros fundamentos relacionados a quebra estrutural foi dada por Bai (1994) e estendida por Bai (1997) e Bai e Perron (2003). A forma operacional do teste Bai-Perron busca datar as quebras, a amostra é dividida em subamostras nos candidatos a quebra, as quebras estruturais existentes

São Paulo 27 a 29 de julho 2022.

são tratadas através de um algoritmo de programação dinâmica (MQO - Método dos Mínimos Quadrados), em seguida, o teste busca as datas das quebras que minimiza a soma dos quadrados dos resíduos (SQR). A Equação para a metodologia Bai e Perron (2003) segue abaixo:

$$y_t = x_t' \beta^0 + z_t' \delta_j^0 + u_t \quad (t = T_{j-1} + 1, \dots, T_j) \quad (3)$$

Em que  $j = 1, \dots, m + 1$ ,  $T_0^0 = 0$  e  $T_m^0 = T$ . Nesse modelo,  $y_t$  é a variável dependente,  $x_t$  e  $z_t$  são dois vetores de covariadas com a dimensão  $(p \times 1)$  e  $(q \times 1)$ , respectivamente e  $\beta^0$  e  $\delta_j^0$  ( $j = 1, \dots, m + 1$ ) são vetores de coeficientes;  $u_t$  é o termo de erro.

### 3.3. Modelagem ARIMA-GARCH e previsão

A modelagem ARIMA-GARCH foi realizada com o objetivo de prever os retornos, para tanto, os dados foram separados em dois períodos, sendo: o período de teste de 04/01/2021 até 17/02/2021, antes do evento, possuindo um total de 4232 observações e o período real o qual inclui os dias 18 e 19 de fevereiro de 2021, período durante e depois do evento, com 358 observações. Em seguida, realizou-se o teste de Jarque e Bera (1980) para avaliar a normalidade da série e os testes de Dickey e Fuller (1979) e Phillips e Perron (1988) para testar a estacionariedade.

O teste de Jarque-Bera baseia-se na assimetria dos dados  $y_1, y_2, \dots, y_n$  e na diferença entre o coeficiente de curtose e o coeficiente de distribuição normal para testar a hipótese nula de que as amostras são retiradas de uma distribuição normal (Jarque & Bera, 1980). A seguir, tem-se a Equação 4 que representa o modelo.

$$JB = n \left[ \frac{S^2}{6} + \frac{(C - 3)^2}{24} \right] \quad (4)$$

Onde  $JB$  é o teste de Jarque-Bera,  $S$  é o coeficiente de assimetria observado,  $C$  é o coeficiente de curtose observado e  $n$  é o número de observações. Se o  $p$ -value da estatística qui-quadrado calculado for baixo de 5% ( $p < 0,05$ ), a suposição de que os resíduos têm uma distribuição normal pode ser rejeitada. Caso contrário,  $p$ -value maior que 5%, a suposição de normalidade é aceita.

O modelo proposto por Dickey e Fuller (1979) é utilizado para verificar a existência ou não de raízes unitárias nas séries temporais, através da Equação 5.

$$\Delta Y_t = \alpha + \beta t + \gamma Y_{t-1} + \sum_{i=1}^p \delta_i \Delta Y_{t-1} + \varepsilon_t \quad (5)$$

Sendo  $\Delta Y_t$  o operador de diferenças ( $Y_t - Y_{t-1}$ ),  $\alpha$  uma constante,  $\beta$  o coeficiente de tendência do modelo que permite testar a estacionariedade,  $\gamma$  o coeficiente da presença de raiz unitária,  $\sum_{i=1}^p \delta_i \Delta Y_{t-1}$  são as defasagens incluídas no modelo e  $\varepsilon_t$  é o termo de erro aleatório.

No teste de Phillips e Perron (1988), considera-se a mesma regressão como uma generalização do teste de Dickey-Fuller, a diferença entre eles é que o primeiro garante que os resíduos não são correlacionados e têm uma variância constante. Nestes dois testes, a hipótese nula sugere que a série é estacionária, ou seja, não possui raízes unitárias.

Em seguida, o modelo ARIMA foi estimado com o objetivo de compreender a dependência do tempo nas séries. A modelagem ARIMA é baseada nas quatro etapas básicas propostas por Box e Jenkins (1976), a saber: identificação, estimativa, verificação e previsão.

São Paulo 27 a 29 de julho 2022.

De acordo com Morettin e Toloi (2006) o modelo pode ser descrito conforme as Equações a seguir:

$$\text{AR}(p) \quad z_t = \Phi_1 * z_{t-1} + \Phi_2 * z_{t-2} + \dots + \Phi_p * z_{t-p} + \varepsilon_t \quad (6)$$

Em que  $\Phi_p$  são parâmetros reais e  $\varepsilon_t$  são i.i.d (independentes e identicamente distribuídas), com  $E(\varepsilon_t) = 0$  e  $var(\varepsilon_t) = \sigma^2$ .

$$\text{MA}(q) \quad z_t = \mu + \alpha_t - \theta_1 * \alpha_{t-1} + \theta_2 * \alpha_{t-2} - \dots - \theta_q * \alpha_{t-q} \quad (7)$$

Em que  $\mu, \theta_q$  são constantes reais,  $\alpha_t$  é i.i.d. e  $\alpha_t \sim N(0, \sigma^2)$ .

$$\text{ARMA}(p,q) \quad z_t = \Phi_1 * z_{t-1} + \Phi_2 * z_{t-2} + \dots + \Phi_p * z_{t-p} - \theta_1 * \alpha_{t-1} + \theta_2 * \alpha_{t-2} - \dots - \theta_q * \alpha_{t-q} + \alpha_t \quad (8)$$

$$\text{ARIMA}(p,d,q) \quad W_t = z_t - z_{t-d} \quad (9)$$

Para melhor identificação da estrutura do modelo faz-se necessário a utilização de recursos computacionais específicos, devido a estrutura complexa do modelo. Neste trabalho, o Rstudio foi utilizado para identificar automaticamente a estrutura do modelo ARIMA, evitando as etapas mais complicadas de análise. Ressalta-se que a identificação pode ser realizada por meio dos gráficos das funções de autocorrelação (FAC) e autocorrelação parcial (FACP).

Antes de estimar a classe de modelos ARCH, testou se há heterocedasticidade condicional nos resíduos do modelo, através do teste ARCH-LM (Multiplicador de Lagrange) de Engle (1982), cuja a hipótese nula indica que os resíduos são homocedásticos, e a hipótese alternativa que os resíduos são heterocedástico. O Equação 10 descreve o teste.

$$\varepsilon_t^2 = \beta_0 + \sum_{s=1}^q \beta_s \varepsilon_{t-s}^2 + v_t \quad (10)$$

Onde  $\varepsilon$  é o resíduo, os  $\beta$  são os parâmetros da regressão e  $v_t$  um processo de ruído branco.

Após a análise da presença de heterocedasticidade, e antes de estimar a previsão, realizou-se a análise dos modelos da família ARCH para identificar qual captaria melhor os efeitos na série, sendo: Heterocedasticidade Condicional Autorregressiva Generalizada (GARCH) desenvolvido por Bollerslev (1986), que generaliza o tratamento da variância condicional como uma função linear dos quadrados dos erros passados e das variâncias condicionadas passadas.

$$\text{GARCH}(q, p) \quad \sigma_t^2 = \Phi + \sum_{i=1}^q \omega_i u_{t-1}^2 + \sum_{j=1}^p \varphi_j \sigma_{t-1}^2 \quad (11)$$

Onde  $\sigma$  é a variância condicionada e  $\Phi, \omega_i$  e  $\varphi$  são os parâmetros dos termos interceptos erro aleatórios, sendo,  $\Phi > 0$  e  $\omega_i, \varphi \geq 0$ .

O modelo de Heteroscedasticidade Condicional Autorregressiva Generalizada Exponencial (eGARCH), desenvolvido posteriormente por Nelson (1991), tem o objetivo de

São Paulo 27 a 29 de julho 2022.

descrever as diferenças das respostas na rentabilidade em detrimento a choques positivos e negativos, sem necessidade de qualquer restrição paramétrica (Equação 12).

$$\text{eGARCH} \quad \ln(\sigma_t^2) = \alpha + \sum_{j=1}^q (\beta_j \ln \sigma_{t-j}^2) + \sum_{i=1}^p \left[ a_i \left( \frac{|\varepsilon_{t-i}|}{\sqrt{\sigma_{t-i}}} - \sqrt{\frac{2}{\pi}} \right) + \gamma_i \left( \frac{\varepsilon_{t-i}}{\sqrt{\sigma_{t-i}}} \right) \right] + v_t \quad (12)$$

Sendo  $\alpha$  o valor constante;  $\beta_j$ ,  $\alpha_i$ ,  $\gamma_i$  os parâmetros do modelo;  $\varepsilon_{t-i}$  é o erro observado em  $t - i$ ; e  $\sigma_{t-i}$  é o desvio-padrão observado em  $t - i$ .

O modelo de Heteroscedasticidade Condicional Autorregressiva Generalizada com Limiar (tGARCH) foi desenvolvido por Zakoian (1994) e permite deletar igualmente a assimetria na volatilidade, sendo que as boas notícias e as más notícias podem provar diferentes impactos na volatilidade. Este modelo é calculado conforme a Equação 13.

$$\text{tGARCH} \quad \sigma_t^2 = w + \sum_{i=1}^p \alpha \varepsilon_{t-1}^2 \sum_{j=1}^q \beta \sigma_{t-1}^2 + \gamma_i d_{t-i} \varepsilon_{t-1}^2 + v_t \quad (13)$$

Onde  $\gamma_i$  mede o efeito assimetria,  $d_{t-i}$  é uma variável *dummy*, que toma o valor de 1, se  $\mu_t > 0$  e de 0, para  $\mu_t \leq 0$ , e, por fim,  $\varepsilon_{t-1}^2$  é o termo de erro no tempo  $t - i$ , com  $i$  a denotar a defasagem.

O modelo tGARCH considera que o impacto na variância condicional é diferente, dependendo se são "boas notícias" ( $\varepsilon_{t-1}^2 > 0$ ) ou "más notícias" ( $\varepsilon_{t-1}^2 < 0$ ). Portanto, notícias positivas de mercado influenciam  $\alpha$ , e notícias negativas influenciam  $\alpha + \gamma$ . Se  $\gamma_i > 0$ , existe o chamado efeito de alavancagem. Em comparação com  $\gamma \neq 0$ , a influência da difusão de novas notícias constitui um efeito assimétrico.

Para cada modelo – GARCH, eGARCH e tGARCH – serão ajustadas as distribuições Gaussiana (Normal), *t-Student* e *Generalized Error Distribution* (GED). Para estimar o modelo mais adequado para previsão, ou seja, aquele capaz de captar melhor os efeitos, utilizou-se os critérios de seleção *Akaike Information Criterion* (AIC), proposto por Akaike (1974), e o *Bayes Information Criterion* (BIC), proposto por Schwarz (1978). O melhor modelo é definido como o de menor valor de AIC e BIC.

$$AIC = 2k - 2\ln(L) \quad (14)$$

$$BIC = -2 \ln(L) + k \ln(n) \quad (15)$$

Sendo  $k$  o número de parâmetros do modelo,  $L$  como o valor maximizado da função de verossimilhança e  $n$  o número de observações.

Após a seleção do melhor modelo, foi realizada a previsão dos dados para 358 "passos" a frente, afim de comparar com os dados reais. Este tipo de previsão é conhecido como previsão *ex-post*, pois já existem valores dentro da série estudada, sendo os dias 18 e 19 de fevereiro de 2021, com 358 dados. O objetivo foi testar a capacidade do modelo em prever potenciais valores futuros em relação a série estudada.

Além da previsão pelo eGARCH, utilizou também da previsão do VaR. O *Value-at-Risk* (VaR, "Valor em Risco") é uma medida estatística cujo o objetivo é determinar o risco associado a um ativo. Jorion (2009) aponta que em finanças o VaR é conhecido como métrica para identificar perda máxima esperada de um ativo.

O VaR é calculado de acordo com a Fórmula abaixo:



$$VaR = \alpha * \sigma * W \quad (16)$$

Sendo  $\alpha$  o nível de confiança escolhido,  $\sigma$  como o desvio padrão dos retornos do ativo e o  $W$  valor inicial do investimento. Assim, para previsão em  $n$  períodos, de acordo com Lima (2018), utiliza-se  $VaR(n \text{ períodos}, Z_{\alpha\%}) = VaR(1 \text{ período}) * \sqrt{n}$ .

Para a seleção da métrica de desempenho da precisão, de acordo com a literatura, algumas métricas já foram propostas e analisadas para avaliar a previsão, entretanto nenhuma medida foi reconhecida como padrão universal (Li & Shi, 2010). Para este estudo utiliza-se o RMSE (*root-mean-square error*) por ser uma medida frequentemente utilizada (Andersen, Bollerslev, & Lange, 1999; Poon & Granger, 2003; Shareef, Thanoon, & Abdulhussien, 2015). Sua equação é definida como:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Q_f(i) - (Q_0(i)))^2} \quad (17)$$

Em que  $(Q_f(i) - (Q_0(i)))^2$  são as diferenças ao quadrado e  $n$  o tamanho da amostra.

Cabe ressaltar que além da RMSE, outra medida muito utilizada é o MAPE (*The Mean Absolute Percentage Error*), entretanto ela não foi utilizada devido a vários retornos iguais a zero, ou seja, resultando em uma divisão por zero.

#### 4. Análise de resultados

As análises aqui observadas foram realizadas em escala logarítmica. É comum em séries financeiras, de acordo com a literatura econômica, a transformação logarítmica. Partindo-se do pressuposto de que essas variáveis podem ser correlacionadas, a relação linear entre as variáveis foi estudada por meio de uma análise simples do coeficiente de correlação de *Spearman*, anteposto, ressalta que esse modelo foi utilizado devido a rejeição de normalidade da série, que de acordo com Miot (2018) o modelo de correlação de *Spearman* é um dos modelos recomendados para variáveis que não apresentam distribuição normal, conforme mostrado na Tabela 1.

**Tabela 1** – Matriz de correlação entre as variáveis

	Período completo (04/01/2021 a 19/02/2021)		Três dias (17, 18 e 19/02/2021)	
	Fechamento	Retornos	Fechamento	Retornos
<b>Volume Financeiro</b>	0.4004836	0.007967377	0.2676953	-0.02481626
<i>P-value</i>	<i>2.2e-16</i>	<i>0.5894</i>	<i>8.31e-09</i>	<i>0.6004</i>
<b>Títulos Negociados</b>	0.07491896	-0.007953242	-0.03674462	-0.05445939
<i>P-value</i>	<i>3.734e-07</i>	<i>0.5901</i>	<i>0.4373</i>	<i>0.25</i>

Fonte: Elaborada pelos autores com base nos dados da amostra.

Conforme aponta Miot (2018) o coeficiente de correlação de *Spearman* é uma medida não paramétrica da correlação de postos ordenados (*ranks*), completa ainda Siegel e Castellan (2017) que essa correlação estima que as duas variáveis apresentam em escala original, ou seja, mesmo sentido (ascente ou descendente). Através da matriz de correlação, pode-se notar que para o período completo somente o fechamento apresentou correlação significativa, mostrando uma forte correlação entre volume financeiro e o fechamento durante e uma fraca correlação

São Paulo 27 a 29 de julho 2022.

entre títulos negociados e o fechamento. Entretanto, quando analisado somente o período de três dias, pode-se notar uma redução da correlação volume financeiro e o fechamento, e ainda a correlação de títulos negociados com o fechamento passou para uma correlação fraca negativa, mas não significativa.

Devido à alta volatilidade apresentada nos últimos dias de cotação da PETRN265, dois grupos foram separados para identificar a possibilidade de quebra estrutural. O primeiro grupo contém os dados de uma semana, do dia 10 ao dia 19 de fevereiro – não havendo negociações entre os dias 15 e 16 de fevereiro e dia 17 de fevereiro (até às 13h). O segundo refere-se aos mesmos períodos do evento a ser estudado, sendo os dias 17, 18 e 19 de fevereiro.

A primeira parte, conforme Tabela 2, buscou-se realizar o teste de estacionariedade através dos testes de Dickey-Fuller e Phillips-Perron, onde é possível identificar, com significância, que a série é estacionária. Após essa análise o próximo passo foi verificar a existência de quebras estruturais na série conforme Figura 1.

**Tabela 2**– Teste de estacionariedade

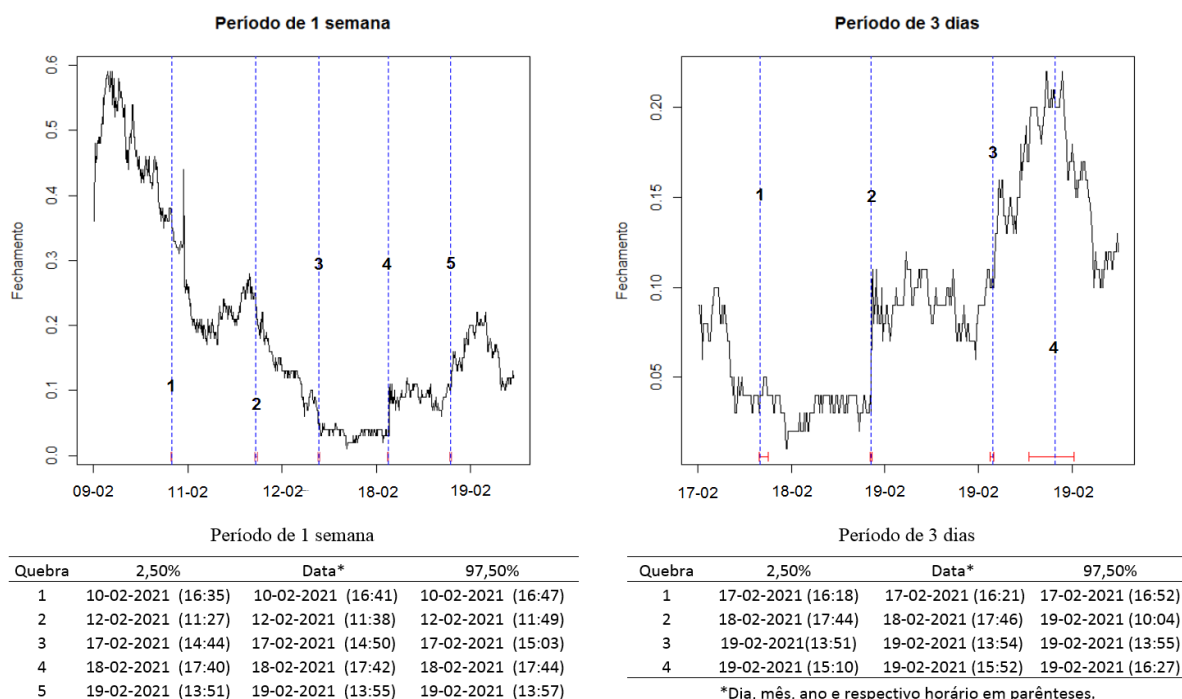
	Uma Semana (10/02 a 19/02/2021)		Três Dias (17, 18 e 19/02/2021)	
	Estatística - t	p-value	Estatística - t	p-value
<b>ADF</b>	-26.7245	2.2e-16***	-19.0088	2.2e-16***
<b>PP</b>	- 0.219665	3.6e-11***	- 0.2186523	3.09e-06***

Nota: Códigos de significância: '0'\*\*\*'; 0.001'\*\*\*'; 0.01'\*\*\*'; 0.05'.

Fonte: Elaborada pelos autores com base nos dados da amostra.

Diante disso, executou-se o teste proposto por Bai e Perron (2003), permitindo a identificação das quebras com seus devidos intervalos de confiança onde a série apresenta padrões incomum. Os resultados podem ser observados na Figura 1, apresentando 5 quebras para período de 1 semana e 4 quebras para período de 3 dias.

**Figura 1** – Quebras estruturais encontradas



Fonte: Elaborada pelos autores com base nos dados da amostra.

São Paulo 27 a 29 de julho 2022.

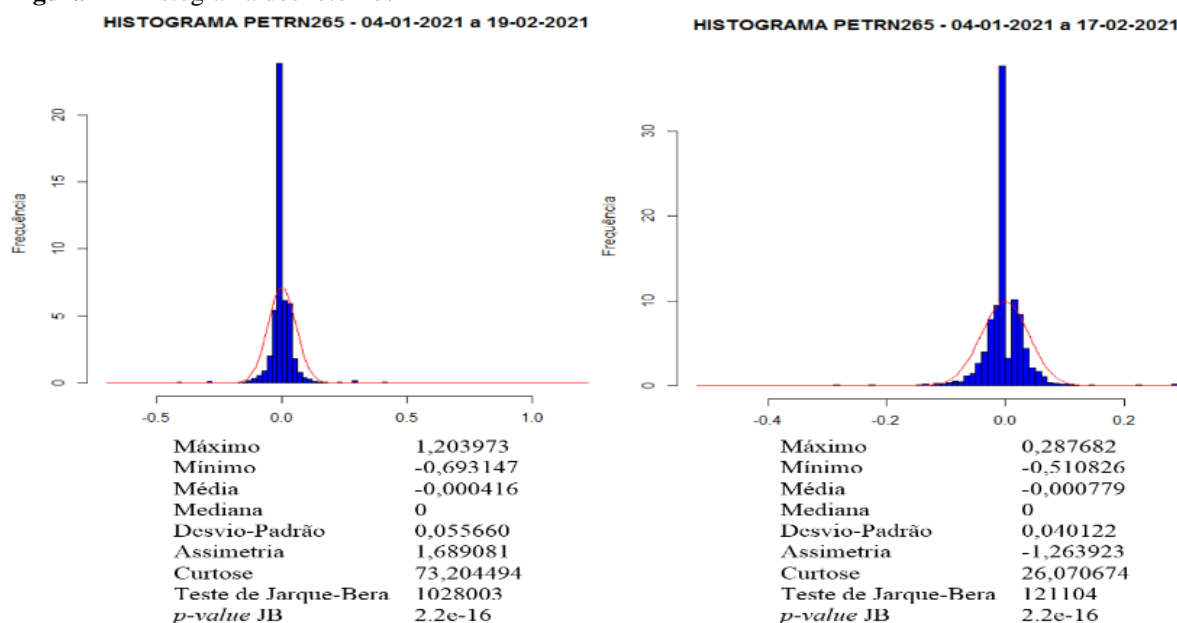
Os resultados demonstram duas quebras do dia 10 ao dia 12 de fevereiro de 2021 no período de 1 semana, ressalta-se que não foi encontrado na base da Thomson Reuters notícias relevantes para essas datas. Entretanto, é possível observar que no dia 17 de fevereiro apresenta-se duas quebras em horários distintos quando observados os resultados de 1 semana e 3 dias. Ao verificar notícias próximas a esses horários na Thomson Reuters, observou-se que as 16h:04min:12seg foi noticiado a oitava alta consecutiva do combustível, de acordo com a ValeCard.

A próxima quebra encontrada foi no dia 18 de fevereiro, sendo que os horários observados no período de 1 semana e 3 dias são bem próximos. Ressalta-se que as 17h:10min:43seg foi divulgado: “Petroleiros aponta forte adesão em greve na Bahia; Petrobras nega impacto na produção”, pela Thomson Reuters. Ainda, Gaspar (2021) informou que o presidente da República se reuniu com ministros para discussão sobre redução dos preços dos combustíveis, conforme reunião agendada para as 16h:45min e finalizada as 17h:15m, em concordância com agenda oficial do Palácio do Planalto.

A última quebra encontrada foi no dia 19 de fevereiro em horários distintos, ao observar os resultados de 1 semana e 3 dias. De acordo com a Thomson Reuters, foi noticiado às 13h:31min:26seg que “Bolsonaro reitera que haverá mudanças na Petrobras sem dar detalhes” e as 16h:02min:04seg que “CEO da Petrobras não planeja deixar a empresa por pressões de Bolsonaro”. Com base nisso, Gaspar (2021) comenta que “No dia seguinte, 19 de fevereiro, após fechamento do pregão, Bolsonaro anunciou que Roberto Castello Branco seria substituído pelo general Joaquim da Silva e Luna”.

As quebras estruturais nas séries possuem características que não são típicas aos dados, visto que decorrem de choques exógenos. Stock e Watson (2004) confirmam que essas mudanças estão relacionadas às influências econômicas, políticas ou choques de forças externas, e esses choques podem evoluir gradualmente dentro de uma data ou período de tempo específico. Assim, as quebras estruturais podem vir a comprometer a modelagem de previsão dos dados.

**Figura 2** – Histograma dos retornos



Fonte: Elaborada pelos autores com base nos dados da amostra.

Antes de realizar a previsão, inicialmente foi realizada a modelagem ARIMA-GARCH no período de *Backtesting* entre 04/01/2021 e 17/02/2021, e em seguida realizou-se a previsão para 358 “passos à frente”, compreendendo os períodos reais, nos dias 18 e 19 de fevereiro de 2021. Para realizar a modelagem ARIMA-GARCH, faz-se necessário analisar a normalidade e estacionariedade da série. A Figura 2 indica que, por meio do teste de normalidade proposto por Jarque e Bera (1987), ambos os períodos rejeitaram a hipótese nula de retornos normais ( $p$ -value <0,05).

Dentre os estudos financeiros realizados, observa-se que a série de retornos financeiros apresenta algumas características exclusivas quando comparada com retornos de outras naturezas, como por exemplo a existência de caudas mais longas. Isso posto, observa-se no histograma da Figura 2, que o nível de curtose - grau de concentração dos valores da distribuição em torno do centro - é maior que três para os dois períodos, portanto, apresenta-se como uma distribuição leptocúrtica, ou seja, apresenta uma curva mais afunilada. Entretanto, para o primeiro histograma demonstra-se um elevado valor para a curtose. De acordo com Moldes (2005), em seu estudo sobre a econofísica, o excesso de curtose para a distribuição dos retornos em série financeira é maior para os ativos menos líquidos. Nesse sentido, até o dia 17 de fevereiro demonstrava-se uma maior liquidez no mercado, mas, ao incluir os dias 18 e 19 de fevereiro na análise, o número da curtose é aumentado consideravelmente, o que indica uma menor liquidez no mercado, podendo presumir que o dinheiro fica concentrado na mão de poucos agentes de mercado.

Pode-se concluir pelo histograma que há possíveis indícios de que há algum impacto nas notícias observadas nos dias 17, 18 e 19 de fevereiro, evidenciado na Figura 2, e verifica-se na Figura 2 um impacto na assimetria quando adicionados os dias 18 e 19 de fevereiro, resultando num valor positivo para assimetria, o que aponta que a cauda do lado direito é superior ao lado esquerdo, ou seja, indica a ocorrência de valores altos com baixa frequência.

Para verificar se a série de *Backtesting* - 04/01/2021 e 17/02/2021 - é estacionária, foram realizados os testes de Dickey-Fuller aumentado e de Phillips-Perron. A Tabela 3 apresenta os resultados encontrados em cada um dos testes. De acordo com testes apresentados, rejeita-se da hipótese nula de existência de raiz unitária, ou seja, a série é estacionária.

**Tabela 3**– Teste de estacionariedade

	Estatística - t	<i>p</i> -value
ADF	- 51.5008	2.2e-16***
PP	- 4532.267	3.98e-15***

Nota: Códigos de significância: ‘0’\*\*\*; 0.001’\*\*; 0.01’\*’; 0.05’.’

Fonte: Elaborada pelos autores com base nos dados da amostra.

Após a confirmação da estacionariedade, procurou-se determinar o melhor modelo ARIMA. Dentre os modelos analisados, foi escolhido o modelo ARIMA (0,0,2) com AIC (-15277.88) e BIC (-15252.49), visto que o mesmo obteve o menor valor, com base nos critérios de informação de Akaike (AIC) e Schwartz (BIC).

Em seguida, antes de estimar os modelos GARCH, eGARCH e tGARCH, o teste ARCH foi realizado, vide Tabela 4. Para identificar se existe efeitos ARCH em uma série de resíduos do modelo autorregressivo, Engle (1982) propôs o teste ARCH-LM (multiplicador de Lagrange). Neste teste, a hipótese nula indica que os resíduos são homocedásticos, ou seja, não existe efeitos ARCH no modelo ARCH. O  $p$ -value apresentado no teste ARCH-LM indica rejeição à hipótese nula de que os resíduos são homocedásticos, ou seja, existe efeitos ARCH sobre a série.

São Paulo 27 a 29 de julho 2022.

**Tabela 4 – Teste ARCH-LM**

	Chi-squared	p-value
<b>Lag1</b>	176.15	2.2e-16***
<b>Lag5</b>	378.56	2.2e-16***
<b>Lag10</b>	439.56	2.2e-16***

Nota: Códigos de significância: ‘0’\*\*\*; 0.001’\*\*; 0.01’\*’; 0.05’.’

Fonte: Elaborada pelos autores com base nos dados da amostra.

Após a confirmação da heterocedasticidade, o próximo passo foi modelar a persistência e assimetria, por meio dos modelos GARCH, eGARCH e tGARCH, utilizando três tipos de critério de seleção das distribuições dos erros no modelo GARCH: distribuição gaussiana (normal), *t-Student* e GED. De acordo com Morettin e Toloi (2006), geralmente é difícil identificar a ordem dos modelos da família GARCH sendo recomendado o uso de modelos de baixa ordem. A família de modelos GARCH é utilizada, principalmente, para modelar a variância heterocedástica da série de retornos financeiros, especialmente para identificar, dentre outras coisas, aglomerações de volatilidade.

**Tabela 5 – Critério de seleção do modelo**

Modelo	Distribuição de Erros	AIC	BIC
ARIMA (0,0,2) - GARCH (1,1)	Normal	-3,9717	-3,9627
	t-student	-4,3503	-4,3398
	<b>GED</b>	<b>-6,1300</b>	<b>-6,1195</b>
ARIMA (0,0,2) - eGARCH (1,1)	Normal	-3,9294	-3,9189
	t-student	-4,3548	-4,3428
	<b>GED</b>	<b>-7,0886</b>	<b>-7,0766</b>
ARIMA (0,0,2) - tGARCH (1,1)	Normal	-3,9299	-3,9193
	t-student	<b>-4,3552</b>	<b>-4,3432</b>
	GED	-2,3107	-2,2987

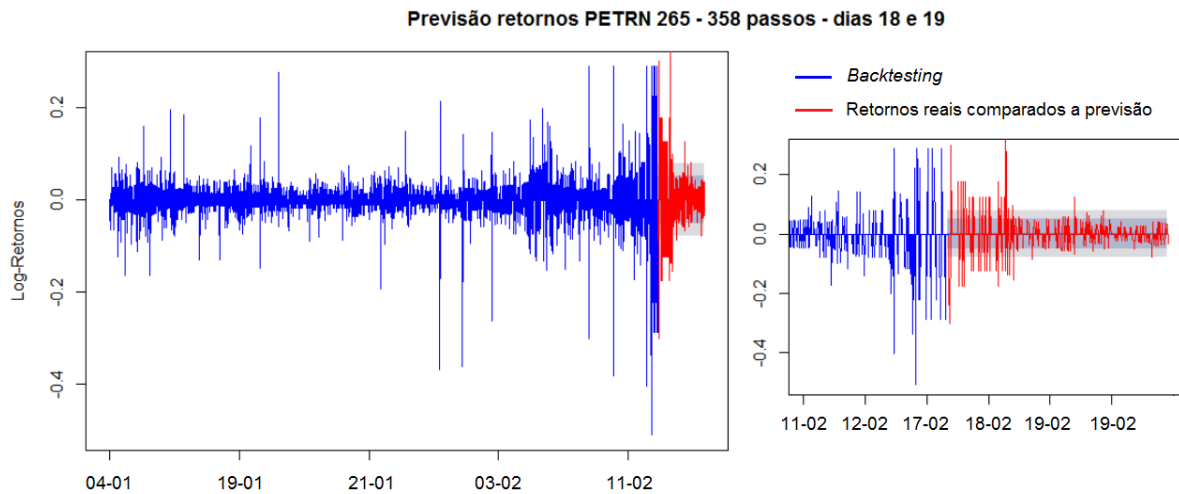
Fonte: Elaborada pelos autores com base nos dados da amostra.

Dessa forma, o melhor modelo para a previsão dos retornos e o *Value at Risk* (VaR) da PETRN265, conforme Tabela 4, foi o modelo ARIMA (0,0,2) - eGARCH (1,1) - GED. O *gamma* do modelo ( $\gamma = 0.282747$ ) indica que a variância dos retornos de PETRN265 está sujeita à assimetria, ou seja, tanto os choques positivos quanto os negativos tiveram um impacto significativo (assimétrico) na volatilidade. No entanto, por ser positivo, não implica alavancagem. De acordo com Pinho et. at. (2011),  $\gamma_i = 0$  indica ausência de assimetria na volatilidade. Se  $\gamma_i > 0$ , existe um impacto diferenciado de choques negativos e positivos na volatilidade. Se  $\gamma_i < 0$  há um choque negativo indicando a presença do “efeito alavancagem”.

Com base na Figura 3 e levando em consideração o critério de previsão supracitado, pode-se observar a previsão para os próximos dois dias (18 e 19 de fevereiro) (cotação *intraday* – 1 min.), posteriores à última informação da amostrada (dia 17 de fevereiro). Através da análise gráfica dos retornos, nota-se que durante o período real, os retornos apontam alguns picos de alta volatilidade, principalmente nos dias finais de negociação, concentrado no dia 17 de fevereiro, podendo impactar no resultado final da previsão. Observando-se o quadro menor da Figura 3, pode-se notar mais detalhadamente os resultados da previsão comparados com o período dos dias 18 e 19 de fevereiro. É possível observar que, nas primeiras horas do dia 18 os retornos extrapolaram o intervalo de confiança da previsão, no entanto, no dia 19, mantiveram-se dentro do intervalo de confiança, esse ocorrido resultou em um RMSE de 0.1438.

São Paulo 27 a 29 de julho 2022.

**Figura 3** – Previsão dos retornos




Nota: RMSE = 0.1438095; MAPE = Inf

Fonte: Elaborada pelos autores com base nos dados da amostra.

Segundo Crouhy (2004), a métrica VaR (*Value at Risk*) é uma medida de risco que busca determinar a perda máxima do valor financeiro de uma carteira em detrimento a um certo nível de confiança e um período sem mudança na carteira. Pautando-se na Figura 4, percebe-se que o cálculo realizado por meio da metodologia eGARCh parece ter uma boa dinâmica de ajustamento.

**Figura 4** – Previsão do VaR



Nota: RMSE = 2.383813; MAPE = 242.471; MAE: 0.7248

Fonte: Elaborada pelos autores com base nos dados da amostra.

Observa-se que, nos momentos de maiores volatilidades, as estimativas do VaR se ajustaram dinamicamente. Contudo, o modelo apresenta uma capacidade limitada para prever os dados no período de 18 e 19 de fevereiro devido aos picos de volatilidade, apresentando um RMSE de 2.383813, MAE de 0.7248 e MAPE de 242.471. As métricas utilizadas correspondem a raiz quadrada do erro médio quadrático (RMSE), erro absoluto médio (MAE) e o erro percentual médio absoluto (MAPE). Tanto o RMSE quanto o MAE possuem valores iniciais que começam a partir de 0 e vão até infinito, ou seja, quanto mais próximo de 0 melhor, sendo o RMSE mais sensível a *outliers*, já que é a média dos erros elevados ao quadrado. Já o MAPE indica a porcentagem de quanto os valores previstos estão errando em relação aos valores reais.



São Paulo 27 a 29 de julho 2022.

Conforme aponta Armstrong e Collopy (1992) a medida MAPE é a mais usada e serve para comparar previsores. Porém, “a medida RMSE é a que penaliza mais os erros maiores, permitindo assim avaliar a qualidade de um previsor em relação aos dados” (Mancuso, 2013, pp. 51).

Tal situação pode ser explicada por meio da Figura 1, ao analisar as quebras estruturais, como também quando observados os picos de alta volatilidade da série, ocasionando altos valores para o RMSE. Por meio da Figura 1, nota-se que a análise e gestão de riscos é fundamental para o investidor que quer diversificar seu risco e ter uma maior assertividade em suas previsões.

## 5. Conclusão

O mercado financeiro não está livre de movimentos atípicos provocados por influências externas, tais como econômicas, políticas, dentre outras. Dessa forma, a análise de modelos que buscam mitigar riscos proporciona boas práticas para análise e gestão de risco do ativo. Sendo assim, o objetivo deste artigo foi realizar um estudo da opção PETRN265, opção de venda da Petrobras.

Dentre os resultados, nota-se a possível relevância do noticiário na análise de quebra estrutural, principalmente durante a reunião presidencial sobre possível mudança na presidência da Petrobrás, que viera de fato ocorrer no dia 19 de fevereiro. Dessa forma, a análise da quebra estrutural da PETRN265 a partir de uma notícia pode impactar na modelagem e previsão de um mercado no futuro.

Por meio da modelagem ARIMA (0,0,2) – eGARCH (1,1) – GED, observou-se que não foi implicada alavancagem para a série. Entretanto, influências, sejam elas positivas ou negativas, produziram um impacto significativo (assimétrico) na volatilidade. Por meio da análise de previsão, observou-se que a identificação da quebra resultou num grande impacto na previsão dos retornos da opção para as primeiras horas. Ao observar o VaR, nota-se que a previsão apresentou limitações, visto o alto valor para RMSE.

É importante observar que as explicações expostas nas Figuras 3 e 4 são baseadas nas informações obtidas e os exemplos utilizados refletem o período em que a série se encontrava em alta volatilidade, provocada pelas notícias que possivelmente ocasionaram quebras estruturais na série. Portanto, não pode ser generalizado que o modelo usado aqui é mais ou menos eficiente do que outros modelos, visto que diferenças nas mudanças dinâmicas do mercado e outras variáveis (como tamanho da amostra, risco do ativo, etc.) podem levar a conclusões distintas.

A principal contribuição deste estudo aqui é enfatizar a capacidade de identificar probabilidade de negociação com informações privilegiadas por meio da relação entre as quebras estruturais e os noticiários. Ainda buscando originalidade por meio de janelas *intraday* minuto a minuto, sendo diferente de estudos anteriores que voltam para retornos anormais, período diário ou trimestral. É importante salientar que não é a intenção dos autores fazer qualquer juízo de valor sobre os fatos mencionados no texto. Os mesmos são aqui referenciados conforme retirados das plataformas de negociação sendo coletados apenas para cunho de pesquisa realizada.

A principal limitação deste trabalho foi realizar a pesquisa com base em um único ativo. Dessa forma, toma-se como sugestão em pesquisas futuras replicar essas análises em outras opções de venda (*put*) que estejam fora do dinheiro, ou seja, abaixo do preço do ativo objeto da opção de Petrobras. Além disso, a opção é o derivativo do preço da ação da Petr4, portanto, os preços da ação também podem ser analisados, e não somente uma série de opção.



São Paulo 27 a 29 de julho 2022.

## Referências

- Akaike, H. (1974). A new look at the statistical model identification. *IEEE Transactions on Automatic Control*, 19(6), 716-723. doi:<http://dx.doi.org/10.1109/TAC.1974.1100705>
- Andersen, T. G., Bollerslev, T., & Lange, S. (1999). Forecasting financial market volatility: Sample frequency vis-à-vis forecast horizon. *Journal of Empirical Finance*, 6(5), 457-477. doi:[https://doi.org/10.1016/S0927-5398\(99\)00013-4](https://doi.org/10.1016/S0927-5398(99)00013-4)
- Armstrong, J. S., & Collopy, F. (1992). Error Measures for Generalizing About Forecasting Methods: Empirical Comparisons. *International Journal of Forecasting*, 8(1), 69-80. doi:[https://doi.org/10.1016/0169-2070\(92\)90008-W](https://doi.org/10.1016/0169-2070(92)90008-W)
- Bai, J. (1994). Least squares estimation of a shift in linear processes. *Journal of Time Series Analysis*, 15(5), 453-472. doi:<https://doi.org/10.1111/j.1467-9892.1994.tb00204.x>
- Bai, J. (1997). Estimating multiple breaks one at a time. *Econometric Theory*, 13(3), 315-352. doi:<https://doi.org/10.1017/S0266466600005831>
- Bai, J., & Perron, P. (2003). Computation and analysis of multiple structural. *Journal of Applied Econometrics*, 18(1), 1-22. doi:<https://doi.org/10.1002/jae.659>
- Bhat, A., & Arekar, K. (2016). Empirical performance of Black Scholes and GARCH option pricing models during turbulent time: The Indian evidence. *International Journal of Economics and Finance*, 123-136. doi:<https://doi.org/10.5539/ijef.v8n3p123>
- Bollerslev, T. (1986). Generalized autoregressive conditional heteroskedasticity. *Journal of Econometrics*, 21(3), 307-327. doi:[https://doi.org/10.1016/0304-4076\(86\)90063-1](https://doi.org/10.1016/0304-4076(86)90063-1)
- Box, G. E., & Jenkins, G. M. (1976). *Time Series Analysis: Forecasting and Control, Revised Edition*. San Francisco: Holden Day.
- Chen, C., & Chen, X. (2007). The information content of rights offerings in China. *Research in International Business and Finance*, 21(3), 414-427. doi:<https://doi.org/10.1016/j.ribaf.2006.12.006>
- Cohen, L., Malloy, C., & Pomorski, L. (2012). Decoding inside information. *The Journal of Finance*, 67(3), 1009-1043. doi:<https://doi.org/10.1111/j.1540-6261.2012.01740.x>
- Crouhy, M., Galai, D., & Mark, R. (2004). *Gerenciamento de Risco: abordagem conceitual e prática: uma visão integrada dos riscos crédito operacional e de Mercado*. Rio de Janeiro: Qualitymark.
- Dickey, D. A., & Fuller, W. A. (1979). Distribution of the estimators for autoregressive time series with a unit root. *Journal of the American Statistical Association*, 74(336), 427-431. doi:<https://doi.org/10.2307/2286348>
- Eizirik, N. (1983). "Insider Trading" e responsabilidade de administrador de companhia aberta. (W. Bulgarelli, Ed.) *Revista de Direito Mercantil Industrial, Econômico e Financeiro* nº 50(22), pp. 42-56.
- Engle, R. F. (1982). Autoregressive Conditional Heteroscedasticity with Estimates of the Variance of United Kingdom Inflation. *The Econometric Society*, 50(4), 897-1007. doi:<https://doi.org/10.2307/1912773>





São Paulo 27 a 29 de julho 2022.

- Exame. (5 de Março de 2021). *Insider na Petrobras? CVM abre processo para investigar operações suspeitas*. Acesso em 19 de Maio de 2021, disponível em Invest Exame: <https://invest.exame.com/me/insider-na-petrobras-cvm-abre-processo-para-investigar-operacoes-suspeitas>
- Farias, R. A., Freitas, M. M., & Vicente, E. F. (2015). Insider Trading: Como a CVM atuou entre 2000 e 2013 para inibir essa prática? *Revista Reuna*, 20(4), 27-50.
- FIA. (21 de Janeiro de 2021). *Global futures and options trading reaches record level in 2020*. Acesso em 16 de Fevereiro de 2020, disponível em Futures Industry Association: <https://www.fia.org/resources/global-futures-and-options-trading-reaches-record-level-2020>
- Focaccia, A. M., Rocha, D. F., Heineck, R. H., Cechin, S. G., & Añaña, E. d. (2002). Mercado de Opções. (U. EDIURCAMP, Ed.) *Revista do CCEI - Centro de Ciências da Economia e Informática*, 6(10), 56.
- Gabe, J., & Portugal, M. S. (2004). Implicit Volatility versus Statistical Volatility: an Exercise Using Options and Telemar S.A. Stock. *Brazilian Review of Finance*, 2(1), 47-71. doi: <https://doi.org/10.12660/rbfin.v2n1.2004.1135>
- Gaspar, M. (02 de Março de 2021). *Operação sugere insider trading com ações da Petrobras*. Acesso em 19 de Maio de 2021, disponível em O Globo: <https://blogs.oglobo.globo.com/malu-gaspar/post/operacao-sugere-insider-trading-com-acoes-da-petrobras.html>
- Givoly, D., & Palmon, D. (1985). Insider Trading and the Exploitation of Inside Information: Some Empirical Evidence. *The Journal of Business*, 58(1), 69-87. doi: <http://dx.doi.org/10.1086/296283>
- Gonçalves, A. P., & Sousa, F. A. (2017). *Avaliação de uma operação de lançamento coberto de opções para ações da empresa VALE5 no ano de 2017*. São Paulo: International Symposium on Project Management, Innovation and Sustainability.
- Hendrawan, R. (2010). Perbandingan Model Opsi Blacksholes Dan Model Opsi Garch Di Bursa Efek Indonesia. *Jurnal Keuangan dan Perbankan*, 14(1), 12-23.
- Hull, J. C. (2005). *Fundamentos dos Mercados Futuros e de Opções*, (4 ed.). São Paulo: Bolsa de Mercadorias & Futuros.
- Jarque, C. M., & Bera, A. K. (1980). Efficient tests for normality, homoscedasticity and serial independence of regression residuals. *Economics letters*, 6(3), 255-259. doi: [https://doi.org/10.1016/0165-1765\(80\)90024-5](https://doi.org/10.1016/0165-1765(80)90024-5)
- Jiratumpradu, N., & Chavanasporn, W. (2016). Forecasting option price by GARCH model. *8th International Conference on Information Technology and Electrical Engineering (ICITEE)*, 1-5. doi: <https://doi.org/10.1109/icitee.2016.7863257>
- Jorion, P. (2009). *Financial Risk Manager Handbook* (5<sup>a</sup> ed.). Canadá: John Wiley & Sons.
- Knewtson, H., & Nofsinger, J. R. (2013). Why Are CFO Insider Trades More Informative? *Managerial Finance*, 40(2). doi: <http://dx.doi.org/10.2139/ssrn.1800202>



São Paulo 27 a 29 de julho 2022.

- Lei n. 10.303, de 31 de outubro de 2001. (s.d.). Altera e acrescenta dispositivos na Lei no 6.404, de 15 de dezembro de 1976, que dispõe sobre as Sociedades por Ações, e na Lei no 6.385, de 7 de dezembro de 1976, que dispõe sobre o mercado de valores mobiliários e cria a Comissão de Valores Mobiliários. Acesso em 23 de julho de 2021, disponível em [http://www.planalto.gov.br/ccivil\\_03/leis/leis\\_2001/l10303.htm](http://www.planalto.gov.br/ccivil_03/leis/leis_2001/l10303.htm)
- Li, G., & Shi, J. (2010). On comparing three artificial neural networks for wind speed forecasting. *Applied Energy*, 87(7), 2313-2320. doi:<https://doi.org/10.1016/j.apenergy.2009.12.013>
- Lima, F. G. (2018). *Análise de Riscos* (2<sup>o</sup> ed.). São Paulo: Atlas.
- Lorie, J. H., & Niederhoffer, V. (1968). Predictive and Statistical Properties of Insider Trading. *The Journal of Law & Economics*, 11(1), 35-53.
- Mancuso, A. C. (2013). *Uma investigação do desempenho de métodos de combinação de previsões: simulada e aplicada*. Dissertação de mestrado, Universidade Federal do Rio Grande do Sul. Porto Alegre, RS. Acesso em 2022 de fevereiro de 20, disponível em <https://www.lume.ufrgs.br/bitstream/handle/10183/75918/000891325.pdf?sequence=1>
- Martins, O. S., Paulo, E., & Girão, L. F. (2016). Preço da ação, disclosure e assimetria de informação: O caso OGX. *Revista Universo Contábil*, 12(1), 6-24.
- Medeiros, O. R., & Matsumoto, A. S. (2006). Emissões públicas de ações, volatilidade e insider information na Bovespa. *Revista Contabilidade & Finança*, 17(40), 25-36. doi:<https://doi.org/10.1590/S1519-70772006000100003>
- Miot, H. A. (2018). Análise de correlação em estudos clínicos e experimentais. *Jornal Vascular Brasileiro*, 17(4), 275-279. doi:<https://doi.org/10.1590/1677-5449.174118>
- Moldes, M. (2015). *Econofísica e o Estudo da Complexidade em Mercados Financeiros*. Niterói: Dissertação de mestrado, Universidade Federal Fluminense.
- Morettin, P. A., & Toloi, C. M. (2006). *Análise de Séries Temporais*. São Paulo: Blücher.
- Narayana, P. K., Liu, R., & Westerlund, J. (2016). A GARCH model for testing market efficiency. *Journal of International Financial Markets, Institutions and Money*, 41, 121-138. doi:<https://doi.org/10.1016/j.intfin.2015.12.008>
- Nelson, D. B. (1991). Conditional Heteroskedasticity in Asset Returns: A New Approach. *Econometrica*, 59(2), 347-370. doi:<https://doi.org/10.2307/2938260>
- Phillips, P. C., & Perron, P. (1988). Testing for a Unit Root in Time Series Regression. *Biometrika*, 335-346. doi:<https://doi.org/10.2307/2336182>
- Pinho, C., Valente, R., Madaleno, M., & Vieira, E. (2011). *Risco Financeiro Medida e Gestão* (2<sup>a</sup> ed.). Lisboa: Edições Sílado.
- Poon, S.-H., & Granger, C. W. (2003). Forecasting Volatility in Financial Markets: A Review. *Journal of Economic Literature*, 41(2), 478-539. doi:<https://doi.org/10.1257/002205103765762743>



São Paulo 27 a 29 de julho 2022.

- Sanvicente, A. Z., & Monteiro, R. d. (2005). A guerra entre comprados e vendidos no mercado de opções de compra da Bolsa de Valores de São Paulo. *Revista de Administração - RAUSP*, 40(1), 34-43.
- Schwarz, G. (1978). Estimating the Dimension of a Model. *The Annals of Statistics*, 6(2), 461-464.
- Shareef, J. K., Thanoon, M. A., & Abdulhussien, W. R. (2015). Forecasting USD/IQD Future Values According to Minimum RMSE Rate. *International Journal of Computer Science and Mobile Computing*, 4(4), 271-285.
- Silva, C. C. (2014). Insider Trading no Anúncio de Fusões e Aquisições: Um Estudo de Eventos. *In.: XVII SemeAd Seminários em Administração*.
- Silva, C. C., & Machado, M. A. (2014). Insider Trading no Anúncio de Ofertas Subsequentes de Ações: Um Estudo de Eventos. *In.: XVII SemeAd Seminários em Administração*.
- Stock, J. H., & Watson, M. W. (2004). *Econometria* (1 ed.). São Paulo: Pearson Education do Brasil.
- Valor Investe. (19 de Abril de 2021). *Exercício de opções sobre ações e ETF movimentada R\$ 17,2 bilhões na B3*. Acesso em 19 de Maio de 2021, disponível em Valor Investe: <https://valorinveste.globo.com/mercados/derivativos/noticia/2021/04/19/exercicio-de-opcoes-sobre-acoes-e-etf-movimentada-r-172-bilhoes-na-b3.ghtml>
- Vicente, J. V., & Guedes, T. d. (2010). A Volatilidade implícita contém informações sobre a volatilidade futura? Evidências do mercado de opções de ações da Petrobras. *Brazilian Business Review*, 7(1), 48-65. doi:<http://dx.doi.org/10.15728/bbr.2010.7.1.3>
- Zakoian, J.-M. (1994). Threshold heteroskedastic models. *Journal of Economic Dynamics and Control*, 18(5), 931-955. doi:[https://doi.org/10.1016/0165-1889\(94\)90039-6](https://doi.org/10.1016/0165-1889(94)90039-6)
- Zhang, H., Sun, C., & Meng, W.-Y. (2019). Empirical research of the pricing of Shanghai 50 ETF options based on volatility and fractional B-S Model. *DEStech Transactions on Economics, Business and Management*, 317-321. doi:[10.12783/dtem/emba2019/29378](https://doi.org/10.12783/dtem/emba2019/29378)