

RELAÇÃO ENTRE VARIÁVEIS MACROECONÔMICAS E IBOVESPA EM DIFERENTES CONTEXTOS DE VOLATILIDADE

RELATIONSHIP BETWEEN MACROECONOMIC VARIABLES AND IBOVESPA UNDER DIFFERENT VOLATILITY REGIMES

Recebido em 27.11.2025 Aprovado em 24.03.2026

Avaliado pelo sistema double blind review

DOI: <https://doi.org/10.12712/rpca.v.194.69935>

Bruno Milani

brunoprofess@gmail.com

Universidade Federal de Santa Maria (UFSM) – Santa Maria – RS, Brasil

<https://orcid.org/0000-0003-4445-789X>

Keler Eliana Correa Bitencourt

kelercorreac@gmail.com

Universidade Federal de Santa Maria (UFSM) – Santa Maria – RS, Brasil

<https://orcid.org/0000-0002-9373-6281>

Adriano Mendonça Souza

amsouza.sm@gmail.com

Universidade Federal de Santa Maria (UFSM) – Santa Maria – RS, Brasil

<https://orcid.org/0000-0002-1562-2246>

Cleber Bisognin

cleber.bisognin@ufsm.br

Universidade Federal de Santa Maria (UFSM) – Santa Maria – RS, Brasil

<https://orcid.org/0000-0002-0714-3739>

Resumo

Este estudo investiga se fatores macroeconômicos possuem relação de causalidade no sentido de Granger em direção ao Ibovespa, considerando diferentes regimes de volatilidade de Markov e os efeitos da pandemia de COVID-19. Estima-se inicialmente um modelo Markov-Switching GARCH que identifica dois regimes distintos. Em seguida, aplicam-se testes de Causalidade de Granger a cada regime e período para avaliar o poder preditivo de dez variáveis macroeconômicas. Os resultados mostram que a estrutura de causalidade é altamente dependente do regime e que houve mudanças estruturais consideráveis após a pandemia.

Palavras-chave: Ibovespa. Regimes de Markov. Volatilidade. Causalidade de Granger. Pandemia COVID-19.

Abstract

This study investigates whether macroeconomic factors exhibit Granger causality toward the Ibovespa, taking into account different Markov volatility regimes and the effects of the COVID-19 pandemic. We first estimate a Markov-Switching GARCH model that identifies two distinct regimes. Next, Granger causality tests are applied to each regime and period to assess the predictive power of ten macroeconomic variables. The results indicate that the causality structure is highly regime-dependent and that substantial structural changes occurred after the pandemic.

Keywords: Ibovespa. Markov Regimes. Volatility. Granger Causality. COVID-19 Pandemic.

Introdução

O estudo da relação entre variáveis macroeconômicas e índices de bolsas de valores tem longo histórico na pesquisa em finanças. Ross (1976) é considerado seminal nesta área e buscou explorar a possibilidade de que o retorno dos índices de mercado pudesse ser explicado por variáveis macroeconômicas, de forma que deu origem ao chamado Arbitrage Pricing Theory (APT). Mais tarde, Chen, Roll e Ross (1986) efetivamente testaram diversas variáveis representativas de inflação, taxa de juros e produção industrial, com base em regressões lineares múltiplas que utilizaram o retorno das ações como variáveis dependentes. Estes estudos construíram as bases deste ramo de pesquisa, que continua relevante.

No Brasil, estudos como os de Bernardelli e Bernardelli (2016) e Bernardelli e Castro (2020) aplicaram modelos lineares multifatoriais para explicar o retorno do Ibovespa, principal indicador do retorno das ações do país, com base em variáveis macroeconômicas, que incluem Taxa de Câmbio, PIB, Taxa Selic, indicadores de Inflação e outras. Outros estudos avançaram com o uso de modelos de Vetores Autoregressivos (Vector Autoregressive - VAR) e Vetor de Correção de Erros (Vector Error Correction - VEC), como os de Bernardelli et al. (2018), Ribeiro et al. (2016), Santana et al. (2018), Souza e Silva (2021), Pereira et al. (2020), incluindo outras variáveis como Produção Industrial, Commodities e índices de bolsas internacionais. Análises baseadas na regressão linear supõem que as variáveis mantêm estruturas constantes ao longo do tempo, o que nem sempre é plausível. Um exemplo é o que ocorre em crises econômicas ou sanitárias, como no caso da COVID-19. Nestas situações, podem haver mudanças de comportamento dos investidores que fazem com que as relações entre variáveis financeiras se alterem. A regressão linear pressupõe ainda homoscedasticidade e ausência de autocorrelação, características que frequentemente não são encontradas em séries temporais financeiras.

Parte destes problemas podem ser atenuados com o uso de modelos de volatilidade, como em Magnani et al. (2025), ou com modelos que se valem dos regimes de Markov, como Lewin e Campani (2020). Os modelos de volatilidade ampliam a discussão para o risco associado aos retornos, enquanto os regimes de Markov permitem considerar mudanças estruturais em uma série temporal, o que pode significar que sua relação com outras variáveis muda ao longo do tempo. Outra alternativa interessante é o uso do teste de causalidade de Granger, que embora seja frequentemente utilizado de forma associada aos modelos VEC, pode ser utilizado simplesmente para analisar a causalidade entre variáveis, com a vantagem de ter pressupostos menos exigentes do que a regressão linear.

Essa abordagem permite aprimorar a análise da influência de fatores macroeconômicos no Ibovespa, entregando uma alternativa mais adequada à dados com características como a volatilidade. Partindo desta problemática, o presente estudo tem como objetivo examinar se as variáveis Certificado de Depósito Bancário (CDI), índices de bolsas internacionais, preço do petróleo, taxa de câmbio e volatilidade possuem relação de causalidade no sentido de Granger em direção ao Ibovespa — ou seja, se contribuem para prever suas variações —, considerando diferentes regimes de volatilidade de Markov e os efeitos da pandemia de COVID-19.

A contribuição deste estudo é tripla: Primeiro, avança metodologicamente ao integrar à análise modelos Markov-Switching com testes de causalidade de Granger, permitindo capturar não-linearidades e mudanças estruturais na relação entre variáveis macroeconômicas e o Ibovespa. Embora estudos brasileiros tenham aplicado modelos lineares e VAR, poucos consideraram explicitamente a possibilidade de mudanças de regime na relação entre o Ibovespa e variáveis macroeconômicas, lacuna que esta pesquisa busca preencher. Segundo, oferece insights aplicados ao identificar como estas relações se modificam entre regimes de alta e baixa volatilidade, fornecendo aos gestores as bases para ajustar estratégias conforme o ambiente de mercado. Terceiro, analisa um período crítico que inclui a pandemia COVID-19, evento com potencial de alterar permanentemente as dinâmicas de mercado.

Foram utilizados dados diários de janeiro de 2017 a dezembro de 2023, cobrindo períodos pré e pós-pandemia. A modelagem segue uma abordagem em quatro etapas: (i) identificação de regimes de

volatilidade por meio de modelos Markov-Switching GARCH; (ii) análise descritiva; (iii) aplicação de testes de causalidade de Granger condicionais a cada regime; e (iv) aplicação dos testes para cada período identificado.

Os resultados indicam a existência de dois regimes de volatilidade para a variação do Ibovespa: um associado a períodos de baixa volatilidade e outro a períodos de alta volatilidade, cuja alternância resultou na definição de cinco períodos distintos. Na análise por regime, verificou-se que a volatilidade condicional e a variação do preço do petróleo WTI apresentaram capacidade preditiva sobre a variação do Ibovespa em ambos os regimes. O CDI, por sua vez, apresentou causalidade de Granger apenas no Regime 1, sugerindo que, em períodos de menor volatilidade, o mercado acionário brasileiro responde mais intensamente às condições monetárias internas. Em contraste, as variações dos índices Dow Jones, Nasdaq e S&P 500 mostraram causalidade de Granger exclusivamente no Regime 2, indicando que, em momentos de maior volatilidade, o Ibovespa se torna mais sensível ao comportamento das principais bolsas internacionais.

A análise por períodos revelou que, no Período 1 — associado ao Regime 2 e abrangendo o momento inicial do choque da COVID-19 —, a maior parte das variáveis macroeconômicas apresentou causalidade de Granger sobre o Ibovespa. Nos períodos subsequentes, contudo, esse padrão se enfraqueceu: a partir do Período 2, observou-se redução significativa no número de variáveis com capacidade preditiva, permanecendo relevantes, de forma mais pontual, a variação do petróleo WTI e, em determinados momentos, o índice Dow Jones. Esse comportamento sugere uma reorganização na dinâmica de precedência temporal entre as séries, possivelmente associada às transformações estruturais nos mercados globais durante e após a pandemia.

Referencial Teórico

Estudos Anteriores

No contexto brasileiro, diversos estudos associam o Ibovespa a variáveis macroeconômicas, empregando diferentes abordagens metodológicas. Bernardelli e Bernardelli (2016) estimaram um modelo de regressão linear com dados mensais (2004-2014) utilizando câmbio, PIB, Selic e inflação como variáveis explicativas. Embora todas tenham se mostrado estatisticamente significativas - com o PIB apresentando sinal positivo e as demais negativo - elevados valores de Fator de Inflacionamento da Variância (FIV) e R^2 indicaram potencial problema de multicolineariedade.

Posteriormente, Bernardelli e Castro (2020) expandiram a análise incluindo maior número de variáveis explicativas, vetor autorregressivo e tendência temporal. A 5% de significância, câmbio e Selic mostraram-se negativas e significativas, enquanto Resultado Primário, Dow Jones, tendência, vetor autorregressivo e constante foram positivos e significativos. O PIB mostraria significância apenas a 10%, enquanto a Necessidade de Financiamento do Setor Público não se mostrou significativa.

Aplicações metodológicas similares aparecem na análise de fundos de investimento. Milani e Ceretta (2014) identificaram significância estatística entre retornos de fundos e produção industrial, inflação e, em menor escala, prêmio de risco. Contudo, em estudo posterior, Milani e Ceretta (2019a) incorporaram fatores de momentos superiores e modelos multifatoriais (Fama e French, 1993; Carhart, 1997), constatando que variáveis macroeconômicas perderam significância em regressões stepwise.

Uma abordagem alternativa comum para esse tipo de análise é a utilização de Modelos Vetoriais Autoregressivos (VAR) e Modelos de Correção de Erros Vetoriais (VEC), estratégia utilizada por Bernardelli et al. (2018). O estudo analisou o impacto de variáveis macroeconômicas — Taxa de Câmbio, PIB, Reservas Internacionais, Taxa Selic e Índice de Confiança do Consumidor — no valor das empresas listadas no Ibovespa, utilizando a causalidade de Granger e o modelo VEC. Para o período de 2000 a 2017, que foi marcado por uma significativa valorização das empresas de capital aberto, os resultados

mostraram que todas as variáveis macroeconômicas analisadas têm impacto sobre o Ibovespa, com exceção do PIB, cuja influência foi mais limitada do que o esperado pelos autores.

O modelo VAR também foi utilizado por Ribeiro et al. (2016) para investigar o impacto das variáveis Taxa de Câmbio, Taxa Selic, Produção Industrial e o Índice Dow Jones sobre o Ibovespa. Após transformações para garantir a estacionariedade das séries temporais, foi realizado o teste de Johansen para verificar a existência de relação de longo prazo entre as variáveis, análise que excluiu a taxa Selic, devido à testes prévios de causalidade realizados de forma bivariada mostrarem não haver relação de longo prazo entre ela e o Ibovespa. Os resultados indicaram que o Ibovespa reage negativamente a variações positivas na Taxa de Câmbio, mas positivamente a variações no Índice Dow Jones e na Produção Industrial.

Santana et al. (2018) investigaram a relação entre o Ibovespa e as variáveis Taxa de Juros, Inflação e Taxa de Câmbio durante os 20 anos pós-estabelecimento do Plano Real, utilizando modelos VAR e VECM. Com base no VAR, foi verificado que não há causalidade entre as variáveis macroeconômicas e o Ibovespa e nem o Ibovespa é seu próprio preditor, mas indicou que tal índice explica as variações na Taxa de Câmbio e na Taxa Selic, com sinal negativo. Porém, a análise do VECM evidenciou que há cointegração entre as variáveis do sistema. Nessa perspectiva, Ibovespa é explicado pelas três variáveis em questão, com destaque para a forte correlação negativa entre Ibovespa e Taxa de Câmbio

Souza e Silva (2021) utilizaram o modelo de correção de erros para analisar a relação entre o Ibovespa e as variáveis macroeconômicas — Taxa de Juros, Taxa de Câmbio, Inflação e Risco País — no período de janeiro de 1995 a 2016. O teste de cointegração demonstrou que todos os coeficientes foram estatisticamente significativos, com o Risco Brasil e a Taxa Selic impactando negativamente o Ibovespa, enquanto Inflação e Taxa de Câmbio tiveram efeitos positivos. O teste de causalidade de Granger revelou que nenhuma das variáveis analisadas Granger-cause o Ibovespa, embora o contrário seja verdadeiro, ou seja, o Ibovespa Granger-cause elas.

Dado que existem diferenças significativas entre diferentes intervalos de tempo, uma estratégia comum para incorporar essas variações nas estimativas de séries temporais é a utilização de variáveis dummy, que funcionam como marcadores de eventos específicos. Essa abordagem foi adotada por Pereira et al. (2020), os quais utilizaram dados mensais de dezembro de 1998 a setembro de 2018 de várias variáveis macroeconômicas, incluindo índices de mercados internacionais, commodities, produção industrial e Dólar, além de dummies para controlar ciclos de recessão e eleições — fatores que podem gerar heteroscedasticidade e influenciar as estimativas. Foram estimados modelos VECM com diversas combinações de variáveis, sendo que apenas o Ouro Futuro e o Ibovespa apresentaram equilíbrio de longo prazo. Embora os autores acreditem que a inserção de dummies possa ter prejudicado alguns modelos, testes adicionais indicaram que essas inserções, por si só, não resolveriam problemas nos resíduos. O teste de causalidade de Granger rejeitou a hipótese de que a variação do Ouro não Granger-cause a variação do Ibovespa.

A volatilidade, característica bem conhecida das séries financeiras, é essencial para a análise de risco, sendo comumente modelada por modelos da família GARCH. Magnani et al. (2025) estudaram a relação entre credibilidade fiscal e monetária e a volatilidade do Ibovespa. A volatilidade foi estimada por meio de um modelo GARCH(1,1) e utilizada como variável dependente em estimativas OLS e GMM de um modelo VAR. As análises, complementadas pela decomposição da variância e análise de impulso-resposta, mostraram que, além das variáveis diretamente relacionadas com o objetivo do estudo, outras variáveis macroeconômicas, como o PIB, a Taxa Selic, o índice EMBI+ e uma dummy para a crise do subprime, também explicam a volatilidade do Ibovespa.

Uma abordagem interessante para lidar com alterações estruturais ao longo do tempo é o uso de regimes de Markov. Lewin e Campani (2020) aplicaram essa técnica para analisar a performance de carteiras compostas por quatro classes de ativos de risco, geradas com base na análise de múltiplos regimes. Para

o período de 2001 a 2019, com dados de fechamento semanal, foram identificados três regimes. A performance das carteiras foi significativamente superior à do Ibovespa e à da Taxa Selic em testes fora da amostra. O uso de regimes de Markov pode ser associado a outros métodos comuns na pesquisa em finanças, como em Milani e Ceretta (2019b), que estimam um modelo análogo ao CAPM com o uso de cointegração com regimes de Markov aplicados a fundos de investimento brasileiros.

Como já mencionado, o uso de regimes de Markov é uma estratégia interessante para analisar séries temporais financeiras com estruturas que se alteram ao longo do tempo, o que justifica a escolha deste método neste estudo. É preciso considerar que a relação entre as variáveis pode ser alterada em diferentes regimes de volatilidade. Em momentos de maior volatilidade o retorno do Ibovespa pode ser causado por variáveis diferentes em relação à momentos de baixa volatilidade. Adicionalmente, quebras estruturais podem indicar que o retorno do Ibovespa pode passar a ser causado por variáveis diferentes. A dinâmica dos regimes é apresentada na Seção 2.2.

A revisão da literatura evidencia limitações metodológicas importantes nos enfoques tradicionais: (i) modelos estáticos que ignoram a dinâmica temporal; (ii) pressuposto de parâmetros constantes incapaz de capturar mudanças estruturais; (iii) dificuldade em modelar adequadamente a volatilidade condicional. Neste contexto, a utilização de modelos com regimes de Markov justifica-se pela capacidade de capturar endogenamente mudanças estruturais nos parâmetros, permitir que as relações de causalidade variem entre regimes de alta e baixa volatilidade e incorporar a natureza dinâmica e não-linear típica de séries financeiras. A Seção 2.2 detalhará a fundamentação teórica desta abordagem.

Regimes de Markov

Uma contribuição importante para a evolução dos modelos GARCH foi a introdução dos processos de Markov por Hamilton (1989). A modelagem foi adaptada em Hamilton e Susmel (1994), em que processos ARCH foram estimados com regimes. Klaassen (2002) utilizou a abordagem de regimes em um modelo GARCH, de forma que a persistência da volatilidade passou a ser considerada dentro de cada regime. Surge então o Markov-Switching GARCH (MS-GARCH).

A estimação da variância condicional permite a mudança de regimes, conforme definido por Ardia et al. (2019). Assim, denota-se $\mathcal{I}_{t-1}$ o conjunto de informações observado até o tempo $t - 1$, de forma que $\mathcal{I}_{t-1} \equiv \{y_{t-i}; i > 0\}$. A especificação geral do modelo MS-GARCH pode então ser expressa como na Equação [01].

$$y_t | (s_t = k, \mathcal{I}_{t-1}) \sim D(0, h_{k,t}, \xi_k), k = 1, \dots, K. \quad [01]$$

Onde $D(0, h_{k,t}, \xi_k)$ é uma distribuição contínua com média zero, variância condicional dependente do tempo $h_{k,t}$ e parâmetros adicionais de forma reunidos no vetor ξ_k . A variável estocástica discreta s_t , definida no espaço $\{1, \dots, K\}$, caracteriza o modelo Markov-switching GARCH. As inovações padronizadas podem ser definidas como na Equação [02].

$$\eta_t = \frac{y_t}{\sqrt{h_{s_t,t}}} \sim i.i.d. D(0,1, \xi_{s_t}) \quad [02]$$

Essa formulação evidencia que cada regime k possui não apenas uma dinâmica própria da variância condicional, mas também especificações particulares para a distribuição dos erros, permitindo capturar diferentes padrões de volatilidade e caudas pesadas ao longo do tempo. A dinâmica da mudança de regimes é formalizada por uma cadeia de Markov de primeira ordem, na qual assume-se que s_t evolui de acordo com uma cadeia de Markov não observada, ergódica e homogênea, com matriz de transição de probabilidades $K \times K$, definida pela Equação [03].

$$P = \begin{bmatrix} p_{1,1} & \cdots & p_{1,K} \\ \vdots & \ddots & \vdots \\ p_{K,1} & \cdots & p_{K,K} \end{bmatrix} \quad [03]$$

Onde $p_{i,j} = P(s_t = j | s_{t-1} = i)$ representa a probabilidade de transição do estado $s_{t-1} = i$ para o estado $s_t = j$. As seguintes restrições devem ser satisfeitas: $0 < p_{i,j} < 1 \forall i, j \in \{1, \dots, K\}$ e $\sum_{j=1}^K p_{i,j} = 1 \forall i \in \{1, \dots, K\}$. Dada a parametrização de $D(\cdot)$, tem-se a Equação [04].

$$\mathbb{E}[y_t^2 | s_t = k, \mathcal{I}_{t-1}] = h_{k,t}, \quad [04]$$

Na Equação [04], $h_{k,t}$ corresponde à variância condicional de y_t , dado o regime $s_t = k$.

No modelo MSGARCH de Haas et al. (2004), as variâncias condicionais $h_{k,t}$, para $k = 1, \dots, K$, são assumidas como seguindo K processos do tipo GARCH distintos, que evoluem em paralelo, o que permite que a volatilidade seja modelada de forma distinta em diferentes estados da economia, refletindo, por exemplo, períodos de alta ou baixa incerteza nos mercados financeiros.

Assume-se que a variância condicional de y_t segue um modelo da família GARCH, de forma que no regime $s_t = k$, $h_{k,t}$ pode ser definida como uma função de y_{t-1} , $h_{k,t-1}$ e também pelo vetor de parâmetros θ_k , que varia conforme o regime e é definido pela Equação [05].

$$h_{k,t} \equiv h(y_{t-1}, h_{k,t-1}, \theta_k) \quad [05]$$

Onde $h(\cdot)$ é uma função mensurável em relação a $\mathcal{I}_{t-1}$, que define o filtro para a variância condicional e também garante sua positividade.

Enquanto os modelos de regimes de Markov ampliam a flexibilidade na modelagem da volatilidade, o entendimento de sua dinâmica ainda se apoia nos modelos GARCH e em suas extensões clássicas, cuja evolução é revisitada na Seção 2.3.

Modelos GARCH

O estudo da volatilidade condicional teve início com Engle (1982), que introduziu o processo Autoregressive Conditional Heteroskedastic (ARCH). Posteriormente, Bollerslev (1986) estendeu o

modelo ao incluir termos que capturam a persistência da variância condicional, originando o Generalized Autoregressive Conditional Heteroskedastic (GARCH). A modelagem da volatilidade com base no GARCH e em seus derivados consolidou-se como uma das principais ferramentas da Teoria Moderna de Finanças.

No contexto de regimes de Markov, assume-se que a dinâmica da volatilidade pode mudar conforme o regime ativo $k = 1, \dots, K$. Assim, cada regime possui um conjunto específico de parâmetros θ_k . De forma resumida, o modelo GARCH(p,q) neste contexto pode ser expresso pelas equações [05] e [06]:

$$y_t = \mu_{k,t} + \varepsilon_t, \varepsilon_t = \sqrt{h_{k,t}} z_t, z_t \sim i.i.d. (0,1) \quad [05]$$

$$h_{k,t} = \alpha_{0,k} + \alpha_{1,k} y_{t-1}^2 + \beta_k h_{k,t-1}. \quad [06]$$

Onde y_t é a série observada (por exemplo, retornos financeiros); $\mu_{k,t}$ é a média condicional no regime k ; ε_t é o termo do erro; $h_{k,t}$ é a variância condicional no regime k ; $\alpha_{0,k}$ é uma constante; $\alpha_{1,k}$ e β_k são coeficientes associados, respectivamente, aos resíduos ao quadrado e às variâncias condicionais defasadas. Para garantir a positividade do modelo, impõem-se as restrições usuais: $\alpha_{0,k}; \alpha_{1,k}; \beta_k > 0$ e $\alpha_{1,k} + \beta_k < 1$.

Diversas extensões foram propostas ao longo do tempo, visando aprimorar a estimação da volatilidade condicional e adequá-la a características específicas dos dados. Entre elas, destaca-se o EGARCH, proposto por Nelson (1991). Diferentemente do GARCH tradicional, o EGARCH modela o logaritmo da variância, permitindo capturar assimetrias entre choques positivos e negativos e dispensando restrições de não-negatividade nos parâmetros. Sua formulação no contexto de regimes (ARDIA et al., 2019) é dada pela Equação [07]:

$$\ln(h_{k,t}) = \alpha_{0,k} + \alpha_{1,k} (|\eta_{k,t-1}| - E|\eta_{k,t-1}|) + \alpha_{2,k} \eta_{k,t-1} + \beta_k \ln(h_{k,t-1}). \quad [07]$$

Nesta especificação, β_k mede a persistência da volatilidade no regime k ($|\beta_k| < 1$ para estacionariedade), $\alpha_{1,k}$ captura o efeito da magnitude dos choques e $\alpha_{2,k}$ o efeito assimétrico. Assim, quando $\alpha_{2,k} < 0$, choques negativos ($\eta_{k,t-1} < 0$) aumentam mais a volatilidade do que choques positivos de mesma magnitude.

Embora o GARCH tradicional capture o fenômeno de clustering da volatilidade, ele impõe que choques positivos e negativos tenham efeitos idênticos sobre a variância condicional — hipótese frequentemente violada em dados financeiros. Empiricamente, observa-se que choques negativos tendem a elevar mais a volatilidade do que choques positivos de mesma magnitude, fenômeno denominado efeito alavancagem (leverage effect). Para tratar essa assimetria, surgiram modelos assimétricos, entre os quais se destacam o GJR-GARCH, de Glosten, Jagannathan e Runkle (1993). No caso com regimes, o GJR-GARCH(p,q) é dado pela Equação [08].

$$h_{k,t} = \alpha_{0,k} + (\alpha_{1,k} + \alpha_{2,k} \mathbb{I}\{y_{t-1} < 0\}) y_{t-1}^2 + \beta_k h_{k,t-1}, k = 1, \dots, K. \quad [08]$$

Onde $\mathbb{I}\{\cdot\}$ é uma função indicadora que assume valor 1 para choques negativos e 0 caso contrário; $\alpha_{2,k}$ mede a assimetria (efeito alavancagem).

Nesse modelo, um choque positivo impacta a variância em $\alpha_{1,k}$, enquanto um choque negativo a afeta em $\alpha_{1,k} + \alpha_{2,k}$, acomodando explicitamente o efeito alavancagem em cada regime. O termo adicional com indicador permite capturar a assimetria de resposta da volatilidade, representando o efeito alavancagem frequentemente observado em séries de retornos.

O Threshold GARCH (TGARCH) foi introduzido por Zakoïan (1994) como alternativa para modelar assimetrias. Diferentemente do GJR-GARCH, formulado em termos da variância, o TGARCH foi originalmente especificado em termos do desvio padrão condicional. No contexto de regimes (ARDIA et al., 2019), sua formulação está representada pela Equação [09].

$$h_{k,t}^{1/2} = \alpha_{0,k} + (\alpha_{1,k}\mathbb{I}\{y_{t-1} \geq 0\} - \alpha_{2,k}\mathbb{I}\{y_{t-1} < 0\})y_{t-1} + \beta_k h_{k,t-1}^{1/2} \quad [09]$$

Na Equação [09], $h_{k,t}^{1/2}$ representa o desvio-padrão condicional no regime k . O modelo TGARCH permite que choques positivos e negativos tenham impactos distintos sobre a volatilidade, por meio dos coeficientes $\alpha_{1,k}$ e $\alpha_{2,k}$, ponderados pelas funções indicadoras $\mathbb{I}\{y_{t-1} \geq 0\}$ e $\mathbb{I}\{y_{t-1} < 0\}$, respectivamente. Assim, $\alpha_{1,k}$ mensura o efeito de um choque positivo (retorno não negativo), enquanto $\alpha_{2,k}$ captura o impacto de um choque negativo (retorno negativo). Quando $\alpha_{2,k} > \alpha_{1,k}$, choques negativos produzem maior aumento na volatilidade condicional, refletindo o efeito alavancagem (leverage effect) comumente observado em séries financeiras.

Diferentemente do GJR-GARCH, cuja especificação se dá em termos da variância condicional, o TGARCH é formulado diretamente sobre o desvio-padrão, permitindo uma representação alternativa da assimetria. Na prática, ambos os modelos são estruturalmente semelhantes e frequentemente levam a resultados empíricos equivalentes, embora o TGARCH ofereça interpretação mais intuitiva para o efeito dos choques positivos e negativos sobre a volatilidade instantânea. No contexto de regimes de Markov, esses parâmetros variam conforme o estado k , possibilitando capturar diferentes intensidades de assimetria e persistência em períodos de estabilidade e de turbulência nos mercados.

Procedimentos metodológicos

Os dados utilizados neste estudo possuem frequência diária e abrangem o período de 08/01/2019 a 28/02/2025. A base contempla o Ibovespa – principal objeto de análise –, além de variáveis macroeconômicas e índices de bolsas de valores internacionais. As variáveis foram previamente transformadas por meio do cálculo da primeira diferença dos seus logaritmos naturais, a fim de garantir a estacionariedade. Todas as variáveis utilizadas estão descritas na Tabela 1.

Tabela 1 – Descrição das variáveis do estudo

Variável	Descrição	Fonte
Δ Ibovespa	Variação do índice Ibovespa	B3
CDI	Certificado de Depósito Interbancário (CDI)	
Δ CDI	Variação do CDI	
Δ Dow Jones	Variação do índice Dow Jones	Instituto de Pesquisa Econômica Aplicada (IPEA)
Δ Nasdaq	Variação do índice Nasdaq	
Δ Petróleo Brent	Variação da cotação do Petróleo Brent	
Δ Petróleo WTI	Variação da cotação do Petróleo WTI	
Δ Câmbio	Variação da taxa de Câmbio Real/Dólar	
Δ S&P500	Variação do índice S&P500	S&P Dow Jones Indices
Volatilidade	Volatilidade condicional do Ibovespa	Elaborado pelos autores
Δ Volatilidade	Variação da volatilidade condicional	

Fonte: elaborado pelos autores

As séries financeiras costumam apresentar heterocedasticidade, associada à volatilidade dos mercados. Para capturar essa característica, na primeira etapa da análise a volatilidade condicional da variável Δ Ibovespa foi estimada por meio da abordagem Markov-Switching GARCH (MS-GARCH), que modela a volatilidade de séries temporais financeiras utilizando diferentes especificações da família GARCH sob regimes distintos, definidos por um processo de Markov (ARDIA et al., 2019). Essa abordagem requer, além da modelagem da volatilidade, identificar a presença de regimes, ou seja, períodos ocorridos entre quebras estruturais e dentro dos quais a volatilidade apresenta dinâmicas diferentes.

A verificação da existência de regimes requer a identificação prévia de quebras estruturais, realizadas com a função `Fstats` do pacote `strucchange` do R. Esta função calcula a estatística F do teste de quebra estrutural de Chow para cada potencial ponto de quebra da série de Δ Ibovespa. Os resultados de teste apontaram a existência de quatro quebras, ocorridas nas datas 27/04/2020, 15/09/2020, 23/11/2023 e 13/11/2024. Estas quatro quebras permitiram separar a série em cinco períodos distintos.

Com base na existência de quatro quebras e de cinco períodos distintos, a variável Δ Ibovespa foi modelada avaliando 12 combinações de dois diferentes modelos da família GARCH, sendo eles: GARCH (Equação 06), EGARCH (Equação 07), GRJ-GARCH (Equação 08) e TGARCH (Equação 09). As estimações assumem podem assumir dois tipos de distribuição: normal (*norm*) e t de Student (*std*). A combinação selecionada foi aquela que apresentou, simultaneamente, os menores valores dos critérios de informação de Akaike (AIC) e Bayesiano (BIC), além do maior valor do logaritmo da verossimilhança (*log-likelihood – LL*).

O modelo escolhido consiste na combinação de um GARCH com distribuição normal dos resíduos no Regime 1 e um GJR-GARCH com distribuição t de Student dos resíduos no Regime 2. Cada quebra estrutural corresponde a uma troca de regime. As estimações foram realizadas com o pacote MSGARCH

no software R, utilizando o método da máxima verossimilhança. A identificação dos regimes de volatilidade e de suas variações é fundamental para compreender as mudanças na dinâmica do mercado ao longo do tempo.

Com base na determinação dos regimes e pontos de quebra, a segunda etapa da análise consiste na descrição dos dados, que inclui a análise gráfica e as estatísticas descritivas de cada regime. Optou-se por apresentar as estatísticas descritivas e a análise gráfica após a segmentação dos regimes, de forma a evidenciar as diferenças entre cada regime e a amostra total.

Na terceira etapa, foram geradas duas novas séries de retorno: a do Regime 1, contendo todas as observações associadas a esse regime, e, analogamente, a do Regime 2. As demais variáveis apresentadas na Tabela 1 também foram segmentadas conforme os mesmos critérios. Em seguida, realizaram-se testes de causalidade de Granger para verificar se as variáveis macroeconômicas causam a variável $\Delta Ibovespa$ em cada um dos dois regimes. Neste contexto, todas as variáveis cuja relação causal com $\Delta Ibovespa$ foi analisada serão referidas, de forma simplificada, como variáveis macroeconômicas.

Os testes de causalidade foram conduzidos com o uso do pacote vars no software R. A análise foi unidirecional, ou seja, voltada exclusivamente à investigação de causalidade das variáveis macroeconômicas sobre o Ibovespa, em linha com os objetivos do estudo. Os testes foram realizados separadamente para cada uma das dez variáveis macroeconômicas. O número de defasagens foi sugerido automaticamente por uma função do próprio pacote, com base nos critérios de informação de Akaike (AIC), Bayesiano (BIC) e Log-Verossimilhança. Em caso de empate entre ordens de defasagem, optou-se, por parcimônia, pela menor.

A quarta e última etapa do trabalho consistiu em uma análise de causalidade similar àquela da terceira etapa, com a diferença de que a amostra original foi segregada em cinco períodos ao invés de dois regimes. A existência de cinco períodos é oriunda das quatro quebras estruturais identificadas na primeira etapa. Dessa forma, foram calculados testes de causalidade de forma unidirecional para verificar se as variáveis macroeconômicas causam $\Delta Ibovespa$ em cada um dos cinco períodos. A seção 4 apresenta os resultados estimados.

Apresentação e análise dos resultados

Com relação aos resultados da primeira etapa, partindo das quebras estruturais previamente identificadas, a estimação do MS-GARCH revelou a presença de dois regimes distintos na dinâmica da variável $\Delta Ibovespa$, denominados Regime 1 e Regime 2. A volatilidade de $\Delta Ibovespa$ foi modelada com 12 combinações de especificações aplicadas a esses dois regimes. As estatísticas dos testes correspondentes a cada uma destas estimações estão apresentadas na Tabela 2.

Tabela 2 – Resumo da adequação dos modelos de volatilidade estimados para $\Delta Ibovespa$

Modelo	LL	AIC	BIC
GARCH_std - GARCH_std	4580,23	-9140,45	-9087,12
GARCH_std - GJR-GARCH_std	4585,65	-9149,31	9090,64
GARCH_std - EGARCH_std	4582,68	-9143,36	-9084,69
GARCH_std - TGARCH_std	4584,73	-9147,47	-9088,80
GARCH_norm - GARCH_norm	4574,11	-9132,23	-9089,56

GARCH_norm - EGARCH_norm	4581,10	-9144,21	-9096,21
GARCH_norm - TGARCH_norm	4578,91	-9139,82	-9091,82
GARCH_norm - GJR-GARCH_norm	4575,84	-9133,68	-9085,68
GARCH_norm - GARCH_std	4577,82	-9137,64	-9089,64
GARCH_std - GARCH_norm	4579,97	-9141,94	-9093,94
GARCH_norm - EGARCH_std	4585,08	-9150,15	-9096,82
GARCH_norm - TGARCH_std	4583,40	-9146,80	-9093,46
GARCH_norm - GJR-GARCH_std	4585,85	-9151,69	-9098,35

Fonte: elaborado pelos autores

A análise dos critérios de informação evidencia que a combinação de modelos com o melhor ajuste é composta por um GARCH com distribuição normal dos resíduos para o Regime 1 e um GJR-GARCH com distribuição t de student dos resíduos para o Regime 2. A identificação prévia dos regimes permite que as análises subsequentes sejam conduzidas separadamente para cada regime. Os coeficientes estimados para a combinação de modelos escolhidos estão apresentados na Tabela 3.

Tabela 3 – Coeficientes estimados para o modelo MS-GARCH

Parâmetro	Coeficiente	Erro Padrão	t-valor	p-valor
$\alpha_{0,1}$	0,00	0,00	1,39	0,08
$\alpha_{1,1}$	0,00	0,01	0,71	0,24
$\beta_{1,1}$	0,98	0,01	104,30	< 0.01
$\alpha_{0,2}$	0,00	0,00	2,73	0,00
$\alpha_{1,2}$	0,00	0,00	0,06	0,48
$\alpha_{2,2}$	0,14	0,05	2,78	0,00
$\beta_{1,2}$	0,86	0,03	33,46	< 0.01
ν_2	9,57	2,35	4,06	< 0.01
$P_{1,1}$	0,99	0,00	516,97	< 0.01
$P_{2,1}$	0,00	0,01	0,36	0,36

Fonte: elaborado pelos autores


Os coeficientes estimados evidenciam as diferentes características de cada regime. No Regime 1, tanto o coeficiente linear ($\alpha_{0,1}$) quanto o coeficiente associado aos choques recentes ($\alpha_{1,1}$) não se mostraram estatisticamente significativos, sugerindo que os retornos defasados têm impacto limitado na volatilidade imediata. Contudo, o coeficiente β_1 , muito próximo de 1 e altamente significativo, indica elevada persistência da volatilidade, característica típica de períodos de baixa turbulência, em que a variância depende fortemente de sua própria dinâmica passada.

No Regime 2, o coeficiente linear $\alpha_{0,2}$ é estatisticamente significativo, embora numericamente pequeno, indicando um efeito constante marginal sobre a variância condicional. Assim como no Regime 1, o coeficiente $\alpha_{1,2}$ não apresentou significância estatística, mas o parâmetro $\alpha_{2,2}$ é significativo e positivo, revelando a presença de efeito alavancagem, isto é, choques negativos ampliam mais a volatilidade do que choques positivos de mesma magnitude.

O coeficiente ν_2 determina os graus de liberdade da distribuição t utilizada para os resíduos padronizados no Regime 2. O valor estimado ($\nu_2 = 9,57$) indica uma distribuição com caudas moderadamente pesadas — mais pesadas que a normal, mas mais leves que uma t padrão com baixos graus de liberdade — permitindo capturar episódios de variações extremas sem introduzir assimetria, que é tratada pelo termo $\alpha_{2,2}$.

A segunda etapa da análise corresponde à descrição dos dados. Dessa forma, as características da série e da volatilidade estimada são apresentadas de forma visual nas Figuras 1 e 2.

Figura 1 – Índice Ibovespa não diferenciado




Fonte: elaborado pelos autores no software R

A Figura 1 apresenta o gráfico da série em nível do Ibovespa, complementado pelos limites em que os regimes de volatilidade acontecem. O intervalo de tempo onde o Regime 1 surge pela primeira vez é claramente associado aos meses que se seguiram após o início da Pandemia de COVID-19,

correspondendo à evolução da recuperação do índice após queda abrupta. Este intervalo finda ainda em 2020, permitindo a volta do Regime 2.

O Regime 1 aparece novamente no final de 2023 e perdura até o final de 2024. Durante este período, o índice alcançou sua máxima histórica, em 07/06/2024. Um dos motivos para o encerramento deste ciclo próximo ao final de 2024 pode ser a eleição de Donald Trump nos Estados Unidos. A volatilidade estimada e a série de retornos $\Delta Ibovespa$ são apresentadas na Figura 2.

Figura 2 – Retorno e volatilidade condicional do Ibovespa



Fonte: elaborado pelos autores no software R

Na Figura 2, a linha vermelha corresponde à série de volatilidade. Percebe-se claramente o pico de volatilidade no início da pandemia COVID-19. Os momentos de menor volatilidade estão associados ao Regime 1, cujos retornos são apresentados em cinza, enquanto os períodos de maior volatilidade estão associados ao Regime 2, cujos retornos são apresentados em preto. As estatísticas descritivas, expostas na Tabela 4, complementam a descrição das séries.

Tabela 4 – Estatísticas Descritivas

Regime	Variável	Média	Desvio Padrão	Mínimo	Máximo	Amplitude	Assimetria	Curtose
Regime 1 n=344	Δ Ibovespa	0,00	0,01	-0,03	0,05	0,08	0,59	1,49
	Volatilidade	0,01	0,00	0,01	0,03	0,02	1,63	2,59
	Δ Volatilidade	0,00	0,03	-0,06	0,28	0,35	3,27	21,75
	CDI	0,03	0,01	0,01	0,05	0,04	-0,92	-1,06
	Δ CDI	0,00	0,02	-0,30	0,04	0,34	-11,05	132,44
	Δ Dow Jones	0,00	0,01	-0,05	0,04	0,09	-0,50	4,72
	Δ Nasdaq	0,00	0,01	-0,05	0,04	0,09	-0,77	2,01
	Δ Petróleo Brent	0,00	0,03	-0,07	0,22	0,29	2,50	18,61
	Δ Petróleo WTI	0,00	0,03	-0,27	0,25	0,52	0,49	28,71
	Δ Câmbio	0,00	0,01	-0,04	0,03	0,07	-0,03	1,83
	Δ S&P500	0,00	0,01	-0,05	0,03	0,08	-0,83	3,54
Regime 2 n=1187	Δ Ibovespa	0,00	0,02	-0,16	0,13	0,29	-1,61	21,37
	Volatilidade	0,01	0,01	0,01	0,09	0,08	6,39	47,49
	Δ Volatilidade	0,00	0,08	-0,08	0,83	0,90	4,16	24,37
	CDI	0,03	0,02	0,01	0,05	0,04	-0,07	-1,57
	Δ CDI	0,00	0,02	-0,13	0,33	0,45	9,31	126,33
	Δ Dow Jones	0,00	0,01	-0,14	0,11	0,25	-1,10	24,48
	Δ Nasdaq	0,00	0,02	-0,13	0,09	0,22	-0,67	8,05
	Δ Petróleo Brent	0,00	0,03	-0,26	0,30	0,56	-1,05	20,80
	Δ Petróleo WTI	0,00	0,03	-0,28	0,37	0,66	0,14	30,12
	Δ Câmbio	0,00	0,01	-0,05	0,04	0,09	0,11	2,46
	Δ S&P500	0,00	0,01	-0,13	0,09	0,22	-0,90	15,85
Série Completa n=1531	Δ Ibovespa	0,00	0,02	-0,16	0,13	0,29	-1,50	22,05
	Volatilidade	0,01	0,01	0,01	0,09	0,08	6,42	51,99
	Δ Volatilidade	0,00	0,07	-0,08	0,83	0,90	4,50	29,55
	CDI	0,03	0,02	0,01	0,05	0,04	-0,22	-1,48
	Δ CDI	0,00	0,02	-0,30	0,33	0,62	3,67	130,47
	Δ Dow Jones	0,00	0,01	-0,14	0,11	0,25	-1,09	24,53
	Δ Nasdaq	0,00	0,02	-0,13	0,09	0,22	-0,71	7,95
	Δ Petróleo Brent	0,00	0,03	-0,26	0,30	0,56	-0,64	21,45
	Δ Petróleo WTI	0,00	0,03	-0,28	0,37	0,66	0,21	29,85
	Δ Câmbio	0,00	0,01	-0,05	0,04	0,09	0,08	2,31
	Δ S&P500	0,00	0,01	-0,13	0,09	0,22	-0,94	16,22

Fonte: elaborado pelos autores

As estatísticas descritivas confirmam que o Regime 2 está associado a períodos de queda e maior volatilidade no mercado. Nesses momentos, a variação do Ibovespa apresenta menor média, maior desvio padrão e maior amplitude. Comportamentos semelhantes foram observados nas variáveis relacionadas às variações dos índices e preços internacionais, como Dow Jones, Nasdaq, Petróleo Brent, Petróleo WTI

e S&P 500. A volatilidade estimada pelos modelos GARCH, bem como sua variação, também exibiram médias, desvios-padrão e amplitudes mais elevadas no Regime 2 em comparação ao Regime 1.

Outro ponto relevante é a trajetória da taxa CDI: enquanto no Regime 1 ela esteve em queda, no Regime 2 observou-se movimento de alta, o que reforça a interpretação de que o Regime 1 está relacionado a períodos de maior estabilidade econômica, ao passo que o Regime 2 está vinculado a momentos de crise.

Embora o número de observações atribuídas ao Regime 2 seja substancialmente superior ao do Regime 1, a análise da série completa revelou que tanto o Ibovespa quanto as demais variáveis analisadas apresentaram médias positivas ao longo do período.

Com os regimes estabelecidos a partir das probabilidades suavizadas do modelo MS-GARCH, procedeu-se à terceira etapa da análise, na qual foram avaliadas as relações de causalidade de Granger das séries macroeconômicas para o Ibovespa em cada regime. Para isso, a base de dados foi segmentada em duas subamostras: uma composta pelas observações classificadas no Regime 1 e outra pelas observações do Regime 2. Em seguida, os testes foram aplicados separadamente para cada uma das dez variáveis macroeconômicas selecionadas, de modo a identificar sua capacidade preditiva sobre o Ibovespa tanto em cada regime quanto na amostra total. Os resultados estão apresentados na Tabela 5.

Tabela 5 – Relações de causalidade entre as variáveis macroeconômicas e a variação do Ibovespa

Variável	Regime 1			Regime 2			Completo		
	Lags	Estatística_F	P_valor	Lags	Estatística_F	P_valor	Lags	Estatística_F	P_valor
Volatilidade	1	5,66	0,02	9	3,42	0,00	9	12,41	0,00
Δ Volatilidade	1	0,89	0,35	7	1,99	0,06	2	4,61	0,01
CDI	1	4,04	0,05	1	0,05	0,83	1	0,11	0,75
Δ CDI	1	1,99	0,16	1	1,14	0,29	1	0,00	0,98
Δ Dow Jones	1	0,01	0,92	9	5,30	0,00	9	5,30	0,00
Δ Nasdaq	1	1,57	0,21	9	3,32	0,00	9	3,32	0,00
Δ Petróleo Brent	1	0,00	0,95	7	1,13	0,36	7	1,13	0,36
Δ Petróleo WTI	1	9,98	0,00	10	2,09	0,02	7	2,61	0,01
Δ Câmbio	1	0,16	0,69	1	0,25	0,61	1	0,63	0,43
Δ S&P500	1	0,19	0,66	9	4,66	0,00	9	4,66	0,00

Fonte: elaborado pelos autores

Com base nos p-valores apresentados na Tabela 5, observa-se que a volatilidade condicional e a variação do preço do Petróleo WTI rejeitam a hipótese nula de ausência de causalidade de Granger em ambos os regimes. Esses resultados indicam que tais variáveis possuem capacidade preditiva sobre a variação do Ibovespa independentemente do estado da economia. A significância da volatilidade condicional permanece mesmo com diferentes ordens de defasagem entre os regimes, reforçando a robustez desse efeito.

Por outro lado, o CDI apresenta causalidade de Granger apenas no Regime 1, enquanto as variações dos índices Dow Jones, Nasdaq e S&P 500 Granger-causam o Ibovespa exclusivamente no Regime 2. Esses resultados sugerem que, em períodos associados a menor volatilidade — caracterizados como Regime 1, conforme evidenciado pelas estimativas de variância condicional — o mercado doméstico responde de forma mais intensa às condições monetárias internas, representadas pelo CDI. Já em momentos de maior

volatilidade ou instabilidade (Regime 2), o comportamento do Ibovespa passa a refletir de maneira mais direta o desempenho das principais bolsas internacionais.

Para aprofundar a interpretação temporal desses resultados, a amostra completa foi segmentada de acordo com os intervalos de tempo em que cada regime esteve vigente, com base nas probabilidades suavizadas do modelo MS-GARCH. Assim, o Período 1 corresponde à primeira ocorrência do Regime 2 no início da série; o Período 2 refere-se à transição posterior para o Regime 1; o Período 3 marca o retorno ao Regime 2, e assim sucessivamente. Essa estrutura permite analisar a dinâmica temporal da causalidade de Granger de forma mais refinada e identificar padrões associados às transições entre regimes.

Tabela 6 – Testes de causalidade por período

Teste	Variável	Período 1 – Regime 2 (08/01/2019 a 24/04/2020)			Período 2 – Regime 1 (27/04/2020 a 14/09/2020)		
		Lags	Estatística_F	P_valor	Lags	Estatística_F	P_valor
Volatilidade	Volatilidade	10	9,49	0,00	1	0,52	0,47
Δ Volatilidade	Variação da						
	Volatilidade	2	5,96	0,00	1	2,09	0,15
CDI	CDI	1	2,76	0,10	1	2,24	0,14
Δ CDI	Variação do CDI	7	3,64	0,00	1	0,41	0,52
Δ Dow Jones	Dow Jones	9	3,42	0,00	1	0,01	0,93
Δ Nasdaq	Nasdaq	9	2,91	0,00	1	1,27	0,26
Δ Petróleo Brent	Petróleo Brent	7	4,90	0,00	1	0,30	0,58
Δ Petróleo WTI	Petróleo WTI	10	2,09	0,02	1	7,87	0,01
Δ Câmbio	Câmbio	7	1,99	0,06	1	0,01	0,92
Δ S&P500	S&P 500	9	3,62	0,00	1	0,04	0,85
Teste	Variável	Período 3 – Regime 2 (15/09/2020 a 22/11/2023)			Período 4 – Regime 1 (23/11/2023 a 12/11/2024)		
		Lags	Estatística_F	P_valor	Lags	Estatística_F	P_valor
Volatilidade	Volatilidade	1	0,83	0,36	8	1,27	0,26
Δ Volatilidade	Variação da						
	Volatilidade	1	0,00	0,95	1	0,74	0,39
CDI	CDI	1	0,05	0,83	1	0,07	0,80
Δ CDI	Variação do CDI	1	1,19	0,28	1	1,01	0,32
Δ Dow Jones	Dow Jones	1	0,00	0,98	1	0,07	0,79
Δ Nasdaq	Nasdaq	1	0,47	0,49	1	0,11	0,74
Δ Petróleo Brent	Petróleo Brent	1	0,27	0,60	1	0,92	0,34
Δ Petróleo WTI	Petróleo WTI	1	0,22	0,64	1	0,23	0,63
Δ Câmbio	Câmbio	1	0,25	0,61	1	0,40	0,53
Δ S&P500	S&P 500	1	0,07	0,79	1	0,00	0,95
Teste	Variável	Período 5 – Regime 2 (14/11/2024 a 28/02/2025)					
		Lags	Estatística_F	P_valor			
Volatilidade	Volatilidade	1	0,03	0,87			
Δ Volatilidade	Variação da						
	Volatilidade	1	0,85	0,36			
CDI	CDI	1	0,07	0,79			

Δ CDI	Variação do CDI	1	1,14	0,29
Δ Dow Jones	Dow Jones	1	4,61	0,04
Δ Nasdaq	Nasdaq	1	2,06	0,16
Δ Petróleo Brent	Petróleo Brent	1	0,45	0,51
Δ Petróleo WTI	Petróleo WTI	1	3,72	0,06
Δ Câmbio	Câmbio	1	0,81	0,37
Δ S&P500	S&P 500	1	2,53	0,12

Fonte: elaborado pelos autores

A análise dos resultados da Tabela 6 revela que, no Período 1 — caracterizado pelo predomínio do Regime 2, associado a níveis mais elevados de volatilidade condicional — a maior parte das variáveis macroeconômicas apresenta causalidade de Granger para o retorno do Ibovespa. Esse padrão, no entanto, não se repete nos intervalos subsequentes.

A partir do Período 2, que coincide com a fase inicial de acomodação dos mercados após o choque provocado pela COVID-19, observa-se uma redução significativa na quantidade de variáveis com capacidade preditiva sobre o Ibovespa. Nos Períodos 2, 3, 4 e 5, apenas a variação do Petróleo WTI e o índice Dow Jones aparecem, de forma pontual, como estatisticamente relevantes. Esse comportamento sugere uma mudança na dinâmica de precedência temporal entre as séries, possivelmente associada às transformações estruturais nos mercados globais durante e após a pandemia.

Ressalta-se ainda que, no Período 5, a variação do índice Dow Jones rejeita a hipótese nula de ausência de causalidade no sentido de Granger para o Ibovespa. Embora esse resultado possa refletir a sensibilidade do mercado brasileiro a movimentos do mercado norte-americano, não se descarta a possibilidade de que esteja relacionado a eventos específicos, como a eleição presidencial dos Estados Unidos em 06/11/2024, uma vez que o período analisado se inicia poucos dias após esse evento. Tal interpretação, contudo, deve ser vista com cautela, já que não foram realizados testes formais de quebras estruturais associados a esse episódio.

Considerações finais

A relação entre variáveis macroeconômicas e índices de mercado acionário não é recente, remontando aos estudos de Ross (1976), cuja proposta originou o modelo APT. Apesar do extenso histórico de pesquisas sobre o tema, revisitar essa relação mostra-se pertinente diante de mudanças estruturais relevantes — como as decorrentes da pandemia de COVID-19 — e do surgimento de novos métodos, bases de dados e ferramentas analíticas. Com base nessa motivação, o presente estudo teve como objetivo identificar quais variáveis macroeconômicas apresentam capacidade preditiva, no sentido de Granger, sobre o Ibovespa sob diferentes regimes de volatilidade de Markov e investigar de que forma a pandemia e o período subsequente se associaram a alterações nessa dinâmica.

Do ponto de vista metodológico, destacam-se duas abordagens principais. Em primeiro lugar, a modelagem da volatilidade condicional via modelos GARCH em mudança de regimes de Markov (MS-GARCH), o que permitiu identificar diferentes conjunturas de mercado, caracterizadas por padrões distintos de volatilidade. Em segundo lugar, a utilização de testes de causalidade de Granger, que, ao exigir menos pressupostos estruturais do que modelos de regressão linear, mostraram-se adequados para dados de séries temporais e com presença de heterocedasticidade condicional. Essa combinação de técnicas possibilitou analisar não apenas a volatilidade, mas a forma como variáveis macroeconômicas se relacionam com o Ibovespa em diferentes estados da economia.

Os resultados indicaram a existência de dois regimes de volatilidade para a variação do Ibovespa (Δ Ibovespa): um regime associado a menor volatilidade (Regime 1) e outro caracterizado por volatilidade

mais elevada (Regime 2). As estatísticas descritivas mostraram que, no Regime 2, o retorno do Ibovespa apresenta maior desvio-padrão e amplitude, bem como maior assimetria e curtose, refletindo episódios de choques mais intensos. A volatilidade condicional estimada e sua variação também exibem valores médios e dispersão superiores no Regime 2, reforçando a interpretação de que esse regime está relacionado a períodos de maior incerteza e turbulência, enquanto o Regime 1 corresponde a fases relativamente mais estáveis. A trajetória da taxa CDI, em queda predominante no Regime 1 e em patamar mais elevado no Regime 2, é coerente com essa leitura, sugerindo condições monetárias mais apertadas em momentos de maior instabilidade.

No que se refere às relações de causalidade de Granger, os resultados mostraram que a volatilidade condicional e a variação do preço do Petróleo WTI apresentaram capacidade preditiva sobre a variação do Ibovespa em ambos os regimes. Em outras palavras, independentemente do estado de volatilidade — mais estável ou mais turbulento — essas variáveis mantiveram relevância para explicar, em termos de precedência temporal, o comportamento do índice acionário. No caso da volatilidade condicional, a significância se manteve mesmo com ordens de defasagem distintas entre os regimes, o que reforça a robustez desse efeito.

Os demais resultados evidenciaram certa assimetria entre fatores domésticos e externos. O CDI apresentou causalidade de Granger apenas no Regime 1, sugerindo que, em períodos de menor volatilidade, o mercado acionário brasileiro responde mais intensamente às condições monetárias internas. Em contraste, as variações dos índices Dow Jones, Nasdaq e S&P 500 mostraram causalidade de Granger exclusivamente no Regime 2, indicando que, em momentos de maior volatilidade, o Ibovespa torna-se mais sensível ao comportamento das principais bolsas internacionais. Esse padrão é compatível com a ideia de que, em cenários de estresse e incerteza global, o mercado brasileiro tende a reagir de forma mais pronunciada aos choques externos.

A análise adicional por períodos, construída a partir da sequência temporal em que cada regime predominou, permitiu um refinamento dessa interpretação. No Período 1, associado ao Regime 2 e abrangendo o intervalo que inclui o choque inicial da COVID-19, verificou-se que a maior parte das variáveis macroeconômicas consideradas apresentava causalidade de Granger para o Ibovespa. Nos períodos subsequentes, entretanto, esse padrão se enfraqueceu: a partir do Período 2, observou-se redução significativa no número de variáveis com capacidade preditiva, permanecendo relevantes, de forma mais pontual, a variação do Petróleo WTI e, em determinados momentos, o índice Dow Jones. Esse comportamento sugere uma mudança na dinâmica de precedência temporal entre as séries, possivelmente associada às transformações estruturais nos mercados globais durante e após a pandemia. No Período 5, por exemplo, a significância do Dow Jones pode refletir a sensibilidade do mercado brasileiro a eventos específicos no cenário norte-americano, como o ciclo eleitoral, ainda que tal interpretação deva ser encarada com cautela, na ausência de testes formais de quebras estruturais.

Em conjunto, os resultados evidenciam que a volatilidade do Ibovespa não é apenas um fenômeno de segunda ordem, mas um elemento central na forma como o índice incorpora informações macroeconômicas. A presença de regimes distintos de volatilidade altera tanto a intensidade quanto a composição dos fatores com capacidade preditiva sobre o retorno do índice. Em períodos de menor volatilidade, fatores domésticos como a taxa CDI tendem a exercer papel mais relevante, ao passo que, em períodos de maior turbulência, fatores externos — notadamente os índices acionários internacionais e o preço do petróleo — ganham protagonismo. Além disso, a comparação entre o período inicial da amostra e o período pós-choque da COVID-19 sugere que eventos de grande magnitude podem reconfigurar de maneira duradoura as relações entre o mercado acionário e variáveis macroeconômicas.

Por fim, é importante reconhecer algumas limitações do estudo. A análise concentrou-se em um conjunto específico de variáveis macroeconômicas e em um único índice de mercado, de modo que os resultados não devem ser extrapolados automaticamente para outros mercados ou para horizontes temporais distintos. Ademais, embora a segmentação por regimes e períodos permita uma leitura rica da dinâmica

temporal, não foram realizados testes formais de quebras estruturais associados a eventos específicos, o que abre espaço para investigações futuras. Estudos posteriores podem incorporar outras variáveis financeiras e macroeconômicas, explorar modelos com parâmetros variando no tempo ou testar explicitamente o impacto de eventos pontuais, como mudanças de política econômica e episódios de crise global, sobre a relação entre volatilidade e variáveis macroeconômicas. Essas extensões podem contribuir para uma compreensão ainda mais abrangente da forma como o mercado acionário brasileiro reage a choques internos e externos em diferentes estados da economia.

Referências

- ARDIA, D., BLUTEAU, K., BOUALLEGUE, R., & BURI, M. (2019). The R package MSGARCH: Markov-switching GARCH models. *Journal of Statistical Software*, 91(4), 1–38. <https://doi.org/10.18637/jss.v091.i04>
- BERNARDELLI, L. V., & BERNARDELLI, A. G. (2016). The analysis about the relation between the stock market with the macroeconomic variable in the period from 2004 to 2014. *Revista Evidenciação Contábil & Finanças*, 4(1), 4–17. <https://doi.org/10.18405/recfin20160101>
- BERNARDELLI, L. V., BORGES, M. J., SANCHES, S. L. R., & SBARDELLATI, E. C. de A. (2018). Relação entre as variáveis macroeconômicas e o valor das empresas do IBOVESPA: uma abordagem de vetores autorregressivos de 2000 a 2017. In *USP International Conference in Accounting* (18th ed.). <https://congress USP.fipecafi.org/anais/18UspInternational/ArtigosDownload/1204.pdf>
- BERNARDELLI, L. V., & CASTRO, G. H. L. (2020). Mercado acionário e variáveis macroeconômicas: evidências para o Brasil. *Revista Catarinense da Ciência Contábil*, (19), 1–20. <https://doi.org/10.16930/2237-766220202892>
- BOLLERSLEV, T. (1986). Generalized autoregressive conditional heteroskedasticity. *Journal of Econometrics*, 31(3), 307–327. <https://www.sciencedirect.com/science/article/pii/0304407686900631>
- CARHART, M. M. (1997). On persistence in mutual fund performance. *Journal of Finance*, 52(1), 57–82. <https://doi.org/10.1111/j.1540-6261.1997.tb03808.x>
- CHEN, N.-F., ROLL, R., & ROSS, S. A. (1986). Economic forces and the stock market. *Journal of Business*, 59(3), 383–403. <https://www.jstor.org/stable/2352710>
- ENGLE, R. F. (1982). Autoregressive conditional heteroskedasticity with estimates of the variance of United Kingdom inflation. *Econometrica*, 50(4), 987–1007. <https://www.jstor.org/stable/1912773>
- FAMA, E. F., & FRENCH, K. R. (1993). Common risk factors in the returns on stocks and bonds. *Journal of Financial Economics*, 33(1), 3–56. [https://doi.org/10.1016/0304-405X\(93\)90023-5](https://doi.org/10.1016/0304-405X(93)90023-5)
- GLOSTEN, L. R., JAGANNATHAN, R., & RUNKLE, D. E. (1993). On the relation between the expected value and the volatility of the nominal excess return on stocks. *Journal of Finance*, 48(5), 1779–1801. <https://doi.org/10.1111/j.1540-6261.1993.tb05128.x>
- GRANGER, C. W. J. (1969). Investigating causal relations by econometric models and cross-spectral methods. *Econometrica*, 37(3), 424–438. <https://www.jstor.org/stable/1912791>
- HAAS, M., MITNIK, S., & PAOLELLA, M. S. (2004). A new approach to Markov-switching GARCH models. *Journal of Financial Econometrics*, 2(4), 493–530. <https://doi.org/10.1093/jjfinec/nbh020>
- HAMILTON, J. D. (1989). A new approach to the economic analysis of nonstationary time series and the business cycle. *Econometrica*, 57(2), 357–384. <https://www.jstor.org/stable/1912559>
- HAMILTON, J. D., & SUSMEL, R. (1994). Autoregressive conditional heteroskedasticity and changes in regime. *Journal of Econometrics*, 64(1–2), 307–333. [https://doi.org/10.1016/0304-4076\(94\)90067-1](https://doi.org/10.1016/0304-4076(94)90067-1)
- KLAASSEN, F. (2002). Improving GARCH volatility forecasts with regime-switching GARCH. *Empirical Economics*, 27(2), 363–394. <https://doi.org/10.1007/s001810100100>
- LEWIN, M., & CAMPANI, C. H. (2020). Gestão de carteiras sob múltiplos regimes: performance fora da amostra. *Brazilian Review of Finance*, 18(3), 52–79. <https://doi.org/10.12660/rbfin.v18n3.2020.81210>

- MAGNANI, V. M., CALUZ, A. D. R., GATSIOS, R. C., & LIMA, F. G. (2025). The relationship of monetary and fiscal policy credibility with the stock market volatility in a developing country. *Global Business Review*, 26(1), 55–68. <https://doi.org/10.1177/0972150920982513>
- MILANI, B., & CERETTA, P. S. (2014). O modelo de precificação por arbitragem no contexto dos fundos de investimento brasileiros. *Estudos do CEPE*, (39), 55–78. <https://doi.org/10.17058/cepe.v0i39.3806>
- MILANI, B., & CERETTA, P. S. (2019a). Precificação de ETFs Brasileiros. *Revista Gestão & Tecnologia*, 19(2), 126–148. <https://doi.org/10.20397/2177-6652/2019.v19i2.1373>
- MILANI, B., & CERETTA, P. S. (2019b). Análise dos Fundos de Investimento brasileiros através do CAPM cointegrado com regimes de Markov. *Revista Economia & Gestão*, 19(53). <https://doi.org/10.5752/P.1984-6606.2019v19n53p40-54>
- NELSON, D. B. (1991). Conditional heteroskedasticity in asset returns: A new approach. *Econometrica*, 59(2), 347–370. <https://doi.org/10.2307/2938260>
- PEREIRA, M. V. L., ARAÚJO, L. C. de, & IQUIAPAZA, R. A. (2020). Cointegração e previsibilidade de abordagens VECM para o Ibovespa. *Brazilian Review of Finance*, 18(2), 82–121. <https://doi.org/10.12660/rbfin.v18n2.2020.79162>
- RIBEIRO, A. A. da S., LEITE, Á. R., & JUSTO, W. R. (2016). Análise de cointegração e causalidade entre variáveis macroeconômicas e o índice Dow Jones sobre o Ibovespa. *Revista de Administração da Universidade Federal de Santa Maria*, 9(1), 121–137. <https://doi.org/10.5902/1983465911741>
- ROSS, S. A. (1976). The arbitrage theory of capital asset pricing. *Journal of Economic Theory*, 13(3), 341–360. https://doi.org/10.1142/9789814417358_0001
- SANTANA, H. N., LIMA, S. A. de, & FERREIRA, B. P. (2018). 20 anos de Real: uma análise da relação entre câmbio, inflação, taxa de juros e o Ibovespa. *Revista Gestão & Tecnologia*, 18(2), 44–69. <https://doi.org/10.20397/2177-6652/2018.v18i2.1224>
- SOUZA, F. H. D. de, & SILVA, C. A. G. da. (2021). Análise dinâmica da relação entre as variáveis macroeconômicas e o mercado acionário brasileiro: uma abordagem do modelo de correção de erros. *Brazilian Journal of Business*, 3(4), 2908–2935. <https://doi.org/10.34140/bjbv3n4-011>
- ZAKOIAN, J.-M. (1994). Threshold heteroskedastic models. *Journal of Economic Dynamics and Control*, 18(5), 931–955. [https://doi.org/10.1016/0165-1889\(94\)90039-6](https://doi.org/10.1016/0165-1889(94)90039-6)