



ISBN nº 978-65-01-11585-6

## **EFEITOS DA POLÍTICA FISCAL SOBRE O IBOVESPA: ESTUDO EMPÍRICO DE 2002 A 2023**

Adilson Padovan Junior <sup>1</sup>  
Joilson Giorno <sup>2</sup>

### **Área 3 – Macroeconomia, Economia Monetária, Finanças e Economia Internacional**

**RESUMO:** Este estudo visa analisar os efeitos das políticas fiscais sobre o Ibovespa entre 2002 e 2023, com dados mensais, verificando como mudanças nas finanças públicas brasileiras influenciam a volatilidade e os retornos do mercado de ações. A pesquisa utiliza métodos empíricos, como Análise de Componentes Principais (PCA) e modelos ARMAX-GARCHX com extensões (S-GARCH, E-GARCH E GJR-GARCH), para examinar a dinâmica entre variáveis fiscais e o Ibovespa. Foram estimados 243 modelos (combinações de defasagens), e os resultados indicam que arrecadação líquida e despesas governamentais têm impacto significativo nos retornos do índice, enquanto incentivos fiscais e despesas obrigatórias também influenciam, embora de maneira diferente. A análise mostra que as políticas fiscais afetam tanto os retornos quanto a volatilidade do Ibovespa, sendo mais notáveis os efeitos sobre a média dos retornos.

**Palavras-chave:** Política Fiscal, Volatilidade, Ibovespa.

**ABSTRACT:** *This study aims to analyze the effects of fiscal policies on the Ibovespa between 2002 and 2023, using monthly data to examine how changes in Brazilian public finances influence the volatility and returns of the stock market. The research employs empirical methods such as Principal Component Analysis (PCA) and ARMAX-GARCHX models with extensions (S-GARCH, E-GARCH, and GJR-GARCH) to explore the dynamics between fiscal variables and the Ibovespa. A total of 243 models (combinations of lags) were estimated, and the results indicate that net revenue and government expenditures have a significant impact on the index's returns, while tax incentives and mandatory expenses also influence, albeit in different ways. The analysis shows that fiscal policies affect both the returns and volatility of the Ibovespa, with the effects on the average returns being the most noticeable.*

**Keywords:** *Fiscal Policy, Volatility, Ibovespa.*

**Classificação JEL:** E62, G10, C58.

---

<sup>1</sup> Doutorando em Economia pelo Programa de Pós-Graduação em Ciências Econômicas da Universidade Estadual de Maringá (PCE/UEM), Maringá, Paraná, Brasil e Bolsista CAPES (Coordenação de Aperfeiçoamento de Pessoal de Nível Superior). E-mail: padovanjr@gmail.com

<sup>2</sup> Ph.D. in Economics at the University of South Carolina, USC, USA e Professor na Universidade Estadual de Maringá (PCE/UEM), Maringá, Paraná, Brasil. E-mail: jgiorno@uem.com

# 1 INTRODUÇÃO

A interação entre políticas fiscais do governo e o desempenho do mercado de ações constitui um campo de estudo relevante na economia, atraindo a atenção de economistas, investidores e formuladores de política ao redor do mundo. Essa questão ganha ainda mais importância em economias emergentes, como a do Brasil, onde o mercado de ações pode ser particularmente sensível às mudanças que impactam a sustentabilidade econômica e, consequentemente, as expectativas dos investidores.

As políticas fiscais (como forma de aumentos dos gastos e receitas do governo que podem interferir em indicadores econômicos) tendem a exercer influência direta sobre a estabilidade do mercado de capitais, um fenômeno respaldado pela Hipótese dos Mercados Eficientes (HME) que, de acordo com Fama (1970), propõe que os preços dos ativos financeiros integram todas as informações disponíveis, ajustando-se prontamente a quaisquer novos dados. Isso implica que a tentativa de gerar retornos superiores ao mercado, baseando-se em informações publicamente acessíveis, é fútil.

Fama descreve a eficiência do mercado em três categorias: fraca, semi-forte e forte, cada uma refletindo o grau em que diferentes tipos de informação (desde dados históricos de preços até informações internas) são incorporados aos preços dos ativos. Nesse contexto, alterações nos gastos públicos e políticas fiscais introduzem novas informações que, segundo a HME, são prontamente assimiladas pelo mercado. Assim, em tese, qualquer ajuste nas políticas fiscais ou variação nos gastos governamentais reflete-se imediatamente nos preços dos ativos, incluindo os do Ibovespa, o principal índice do mercado acionário brasileiro.

Essa relação pode sublinhar então, a importância de monitorar as políticas fiscais para análise de mercado. Embora a HME sugira que superar o mercado regularmente é um desafio, entender o impacto dos gastos públicos nos preços dos ativos pode fornecer percepções valiosas sobre as tendências econômicas e expectativas dos investidores. Apesar das críticas e desafios empíricos enfrentados pela HME, sua teoria sobre a assimilação rápida de informações pelos mercados financeiros continua sendo um ponto de referência para a análise de investimentos.

Este estudo busca investigar os efeitos das políticas fiscais sobre o desempenho do Ibovespa durante o período de 2002 a 2023, utilizando métodos empíricos. Os objetivos gerais incluem analisar como mudanças nas políticas fiscais do governo brasileiro influenciam a volatilidade e os retornos do mercado de ações. Além disso, pretende-se avaliar se as premissas da Hipótese dos Mercados Eficientes (HME), que sugerem uma rápida incorporação de novas informações pelos preços dos ativos, são válidas no contexto das políticas fiscais brasileiras.

Para além da presente seção introdutória, o estudo está estruturado em várias partes específicas. A seção 2 investiga as políticas fiscais e os índices de mercado ao redor do mundo, destacando a importância do tema e os objetivos da pesquisa. A seção 3 detalha os dados utilizados e a metodologia aplicada, com ênfase na Análise do Componente Principal (PCA), bem como nos métodos ARMAX-GARCHX e ARMAX-GJR-GARCHX, além de incluir uma análise descritiva dos dados. A seção 4 apresenta e discute os resultados da pesquisa, abordando os achados da análise do componente principal (PCA) e os resultados dos modelos ARMAX-GARCHX com dimensões PCA. Finalmente, a seção 5 oferece as considerações finais, sintetizando as conclusões do estudo e propondo recomendações para futuras investigações e práticas de gestão no mercado financeiro global.

## 2 POLÍTICAS FISCAIS E OS ÍNDICES DE MERCADO

A relação entre políticas fiscais e o comportamento dos índices de mercado tem sido amplamente discutida na literatura econômica. Chatziantoniou, Duffy e Filis (2013), utilizando

um modelo VAR estrutural, investigaram os efeitos das políticas monetária e fiscal sobre o desempenho do mercado de ações na Alemanha, Reino Unido e EUA, identificando que ambas as políticas, especialmente quando interagem, exerceram influência significativa sobre o mercado de ações. De maneira semelhante, Foresti e Napolitano (2017), por meio de uma análise de painel, exploraram o impacto das políticas fiscais sobre os índices de mercado de ações na Zona do Euro, concluindo que as políticas fiscais afetaram os índices de mercado e que variações no déficit público tenderam a reduzir esses índices.

Por outro lado, Hsing (2013) destacou que, no caso da Polônia, o índice do mercado de ações não foi afetado pela razão entre déficits ou dívida governamental e o PIB, mas foi negativamente influenciado pelas taxas de juros do mercado monetário, apontando para a relevância da política monetária sobre a política fiscal no contexto polonês. Enquanto isso, Hu, Han e Zhang (2018) encontraram, no caso da China, que políticas fiscais e monetárias, assim como a interação entre elas, exerceram efeitos significativos e diretos sobre o desempenho do mercado de ações, reforçando a importância da consideração conjunta dessas políticas para a compreensão dos mercados de ações.

Esses estudos ilustraram a complexidade da relação entre políticas fiscais, políticas monetárias e o mercado de ações, sublinhando que os impactos podem variar significativamente entre diferentes economias. Ademais, a pesquisa de Laopodis (2009) sugeriu que os mercados podem ser ineficientes em relação às informações sobre ações fiscais futuras, indicando que notícias sobre política fiscal podem não ser totalmente absorvidas ou valorizadas pelo mercado de ações. Em síntese, enquanto a política fiscal exerceu um papel significativo na dinâmica dos mercados de ações, conforme demonstrado por estudos anteriores, a variabilidade na eficiência com que o mercado absorve essas informações sublinhou a importância de uma investigação detalhada. Isso inclui não apenas uma compreensão das condições econômicas e políticas específicas a cada contexto nacional, mas também uma análise metodológica rigorosa capaz de captar essas nuances.

Com base nesse entendimento, a próxima seção deste trabalho dedica-se à apresentação dos dados e à descrição da metodologia empregada. Serão abordados os processos de coleta e análise dos dados para explorar o impacto das políticas fiscais sobre os índices de mercado de ações, adotando uma abordagem que permita avaliar a rapidez e a eficácia com que as informações são assimiladas pelos mercados em diferentes contextos econômicos ao longo do período estudado.

### **3 DADOS E METODOLOGIA**

A presente seção é dedicada à análise da inter-relação entre os retornos do Ibovespa e as dinâmicas fiscais do governo brasileiro, especificamente em relação às receitas, gastos e transferências. Os dados mensais, deflacionados pelo Índice Nacional de Preços ao Consumidor Amplo (IPCA) e ajustados sazonalmente, abrangem o período de janeiro de 2002 a dezembro de 2023. Esta ampla janela temporal visa oferecer uma visão aprofundada das interações econômicas e financeiras no Brasil, englobando momentos de volatilidade do mercado e variações significativas nas políticas fiscais do governo.

Para a análise, considerou-se um conjunto de variáveis principais que englobam aspectos distintos das finanças públicas e da política fiscal do governo brasileiro, tais como Arrecadação Líquida, Incentivos Fiscais, Receitas Não Administradas pela Receita Federal, Receitas Administradas pela Receita Federal, Transferências, Benefícios Previdenciários, Despesas do Poder Executivo, Outras Despesas Obrigatórias e Despesas com Pessoal (Ver Tabela 1 para mais detalhes).

Para capturar os retornos do Ibovespa, recorreu-se à API do *Yahoo Finance* (2024), enquanto os dados fiscais foram obtidos por meio do portal Tesouro Nacional (2024). Na

metodologia, inicialmente realizou-se uma Análise de Componentes Principais (PCA) dos dados fiscais, que foram previamente deflacionados pelo IPCA e ajustados sazonalmente, para condensar a informação contida nas diversas variáveis fiscais em componentes principais.

**Tabela 1** – Descrição dos componentes das Contas Públicas Federais do Brasil.

Variável	Descrição
<b>Arrecadação Líquida</b>	Total de recursos financeiros arrecadados pelo governo, já descontando as restituições, incentivos fiscais e outras deduções.
<b>Incentivos Fiscais</b>	Benefícios concedidos pelo governo para estimular atividades ou setores específicos, geralmente na forma de reduções ou isenções de impostos.
<b>Rec. Não Adm. Rec. Federal</b>	Receitas arrecadadas por entidades que não fazem parte da administração direta da Receita Federal, como taxas, contribuições e outras entradas.
<b>Rec. Adm. Receita Federal</b>	Receitas arrecadadas diretamente pela Receita Federal, geralmente impostos federais e contribuições sociais.
<b>Transferências</b>	Recursos financeiros enviados pelo governo federal para estados, municípios e outras entidades, incluindo transferências constitucionais e voluntárias.
<b>Benefícios Previdenciários</b>	Pagamentos feitos pelo sistema de previdência social a aposentados, pensionistas e outros beneficiários, conforme os critérios estabelecidos por lei.
<b>Despesas do Poder Executivo</b>	Gastos realizados pelas diversas secretarias e ministérios que compõem o poder executivo, excluindo-se despesas de outros poderes e obrigações específicas.
<b>Outras Despesas Obrigatórias</b>	Despesas que o governo é obrigado a realizar por força de lei, contratos ou decisões judiciais, excluindo benefícios previdenciários e despesas com pessoal.
<b>Despesas com Pessoal</b>	Gastos do governo com salários, benefícios, encargos sociais e outras compensações para os funcionários públicos.

Fonte: Autoria própria.

Após essa etapa, as três primeiras dimensões obtidas pela PCA, que capturam a maior parte da variância nos dados fiscais, foram incluídas como variáveis exógenas<sup>3</sup> nos modelos ARMAX-S-GARCHX, ARMAX-E-GARCHX e ARMAX-GJR-GARCHX sendo estimadas 243 variações de ordens (n, o, p, q) a fim de se encontrar o menor valor do critério Akaike (AIC) para cada extensão GARCH (Ver Anexo “A” – Modelos ARMAX-GARCHX do Ibovespa e Política Fiscal). Vale observar que esses modelos são capazes de capturar a volatilidade condicional e os efeitos assimétricos das séries, permitindo uma análise mais precisa da influência das condições fiscais do governo sobre a volatilidade dos retornos do Ibovespa.

<sup>3</sup> Essa abordagem utilizando PCA permite uma redução da dimensionalidade dos dados e a incorporação de informações fiscais de forma condensada.

### 3.1 MÉTODO PCA (ANÁLISE DO COMPONENTE PRINCIPAL)

A Análise de Componentes Principais (PCA) é uma técnica estatística que permite reduzir a dimensionalidade dos dados enquanto preserva o máximo de variância possível. Este método transforma variáveis correlacionadas em um conjunto de variáveis linearmente desconrelacionadas chamadas componentes principais. A fundamentação teórica do PCA foi desenvolvida por Pearson (1901) e mais tarde formalizada por Hotelling (1933), constituindo um marco na análise multivariada (Jolliffe, 2002).

O método é frequentemente aplicado para análise exploratória de dados e para fazer previsões em modelos de aprendizado de máquina, pois simplifica a complexidade dos dados sem perder informações críticas. A dedução pode ser iniciada pela matriz de covariância  $\Sigma$  dos dados originais  $X$ , seguida pela busca dos autovalores ( $\lambda$ ) e autovetores ( $v$ ) dessa matriz, que satisfazem a Equação (1).

$$\Sigma v = \lambda v \quad (1)$$

Os componentes principais são então formados a partir dos autovetores associados aos maiores autovalores, indicando as direções de maior variância nos dados. O primeiro componente principal é a direção que maximiza a variância dos dados projetados, o segundo é ortogonal ao primeiro e maximiza a variância restante, e assim por diante. A escolha do número de componentes a reter é crucial e geralmente determinada por critérios como a proporção de variância explicada, onde o objetivo é manter os que contribuem significativamente para a variância total dos dados.

Por fim, a incorporação do PCA em análises complexas de dados tem por objetivo oferecer uma base robusta para entender as estruturas subjacentes das variáveis, facilitando, por exemplo, a identificação de padrões em grandes conjuntos de amostras ou a redução de dimensionalidade para algoritmos de aprendizado de máquina. Assim, o método não apenas simplifica a análise, mas também melhora a eficiência computacional.

### 3.2 MÉTODOS ARMAX-GARCHX E ARMAX-GJR-GARCHX

Este estudo revisita os modelos de Engle (1982) e Bollerslev (1986), enriquecendo-os com a incorporação de componentes ARMA na média condicional e a introdução de variáveis exógenas, evoluindo para o modelo ARMAX-GARCHX. Este avanço é alinhado com os trabalhos de Suhartono (2015), Apergis e Rezitis (2011), e Han e Kristensen (2014), proporcionando uma base robusta para explorar o impacto da política monetária no índice Ibovespa. Ao considerar tanto a volatilidade condicional quanto fatores externos, a análise se aprofunda na dinâmica dos retornos das ações no tempo  $t$ , que refletem o desempenho do Ibovespa, através da Equação da média condicional (Equação 1). Este enfoque permite uma compreensão mais completa das variações do mercado acionário brasileiro e de seus determinantes.

$$R_t = \mu_0 + \sum_{i=1}^n \phi R_{t-i} + \sum_{j=1}^o \theta e_{t-j} + \rho X_{t-k} + \sigma_t e_t \quad (2)$$

$$e_t = \sigma_t z_t \quad (3)$$

Sendo que,  $R_t$  simboliza os retornos do Ibovespa, enquanto  $e_t$  refere-se ao termo de erro.  $X_{t-k}$  abrange as variáveis exógenas, que podem incluir elementos como o superávit nos resultados primários do governo. Na Equação (3)  $e_t$  é o termo de erro,  $\sigma_t$  é a volatilidade

condicional, e  $z_t$  é um termo de ruído branco, geralmente assumido como uma variável aleatória com média zero e variância constante. Assim,  $e_t$  é decomposto em uma parte que captura a volatilidade que varia ao longo do tempo ( $\sigma_t$ ) e um componente aleatório ( $z_t$ ).

Por outro lado,  $\sigma_t$  é definida como a volatilidade condicional, cuja modelagem é especificada pelas seguintes equações:

$$\sigma_t^2 = \omega_0 + \sum_{i=1}^p \alpha_i e_{t-i}^2 + \sum_{j=1}^q \beta_j \sigma_{t-j}^2 + \rho X_{t-k} \quad (4)$$

$$\ln(\sigma_t^2) = \omega_0 + \sum_{i=1}^p \alpha_i \left| \frac{e_{t-i}}{\sigma_{t-i}} \right| + \sum_{i=1}^p \gamma_i \frac{e_{t-i}}{\sigma_{t-i}} + \sum_{j=1}^q \beta_j \ln(\sigma_{t-j}^2) + \rho X_{t-k} \quad (5)$$

$$\sigma_t^2 = \omega_0 + \sum_{i=1}^p \alpha_i e_{t-i}^2 + \sum_{j=1}^q \beta_j \sigma_{t-j}^2 + \sum_{i=1}^q \gamma_i e_{t-i}^2 d_{t-1} + \rho X_{t-k} \quad (6)$$

As variantes do modelo GARCH detalhadas nas Equações (3), (4) e (5) se adaptam para integrar variáveis exógenas, capturando assim o efeito de fatores externos na volatilidade dos retornos do Ibovespa. A estrutura desses modelos é ajustada para refletir distintas variações da volatilidade de mercado.

Especificamente, o modelo S-GARCH (Equação 4) considera não apenas os efeitos de retornos passados e volatilidade anterior, mas também o impacto de variáveis exógenas na volatilidade condicional.

O modelo E-GARCH (Equação 5) oferece uma abordagem logarítmica que permite capturar assimetrias na volatilidade, ou seja, ele considera que choques positivos e negativos podem ter impactos diferentes na volatilidade. Esse modelo utiliza o logaritmo da volatilidade condicional, o que garante que a volatilidade estimada seja sempre positiva e permite modelar efeitos assimétricos de maneira mais direta.

Por outro lado, a Equação 6, correspondente ao GJR-GARCH, expande esta análise ao incorporar um mecanismo para reconhecer efeitos assimétricos na volatilidade, introduzindo o termo  $D_{t-i}$  que diferencia entre retornos positivos e negativos.

Para captar a dependência temporal e o efeito das variáveis exógenas, as defasagens ( $p$  e  $q$ ) são definidas tanto para a média condicional quanto para a volatilidade condicional. A escolha destas defasagens é orientada por critérios de informação, como AIC ou BIC, com o objetivo de aprimorar o ajuste do modelo.

### 3.3 ANÁLISE DESCRITIVA

A tabela 2 fornece um panorama detalhado das finanças públicas brasileiras e do comportamento do Ibovespa, refletindo aspectos fundamentais da economia do país em milhões de reais (R\$). Importante destacar que os dados foram cuidadosamente ajustados para refletir valores reais, sendo deflacionados pelo Índice Nacional de Preços ao Consumidor Amplo (IPCA) e dessazonalizados para remover efeitos sazonais, garantindo assim uma análise mais precisa e comparável ao longo do tempo. A distribuição dos dados para cada variável, representada pelas observações, mediana, média, e os quartis, além dos valores mínimos e máximos, sugere informações econômicas significativas.

**Tabela 2** – Sumário de dados do Ibovespa, Receitas, Despesas e Transferências do Governo Federal do Brasil em Milhões de Reais (R\$).

Sumário	Arrecadação Líquida	Incentivos Fiscais	Rec. Não Adm. Rec. Federal	Rec. Adm. Receita Federal	Transferências
Observações	263	263	263	263	263

<b>Mínimo</b>	-4.015	-478,685	-2103	54034	-89174
<b>25%</b>	53.128	-25,253	27038	149420	-48658
<b>Mediana</b>	69557	-7,082	31255	169289	-46066
<b>Média</b>	61299	-22,396	31808	164109	-44011
<b>75%</b>	72614	-3,899	36367	184033	-37920
<b>Máximo</b>	89384	29,703	80327	247794	-7391

Sumário	Benefícios Previdenciários	Despesas do Poder Executivo	Outras Despesas Obrigatórias	Despesas com Pessoal	Ibovespa
<b>Observações</b>	263	263	263	263	263
<b>Mínimo</b>	-154452,1	-86572	-210896	-61062	8623
<b>25%</b>	-102223,2	-50612	-41194	-52827	42363
<b>Mediana</b>	-81650,2	-42889	-31120	-50995	57475
<b>Média</b>	-84760,6	-42865	-33699	-47829	61795
<b>75%</b>	-67312	-34925	-19989	-46221	79281
<b>Máximo</b>	571,3	-1344	8541	-16686	127331

Fonte: Autoria própria.

Para melhor visualizar tais informações, o Gráfico 1 exibe a evolução do Ibovespa em conjunto com as variáveis-chave das finanças públicas brasileiras ao longo do tempo. As linhas representam as trajetórias das receitas, despesas e transferências governamentais, todas ajustadas pelo IPCA para contabilizar a inflação, e dessazonalizadas para remover as flutuações regulares que ocorrem em padrões sazonais. A série temporal mensal vai de janeiro de 2002 até dezembro de 2023.

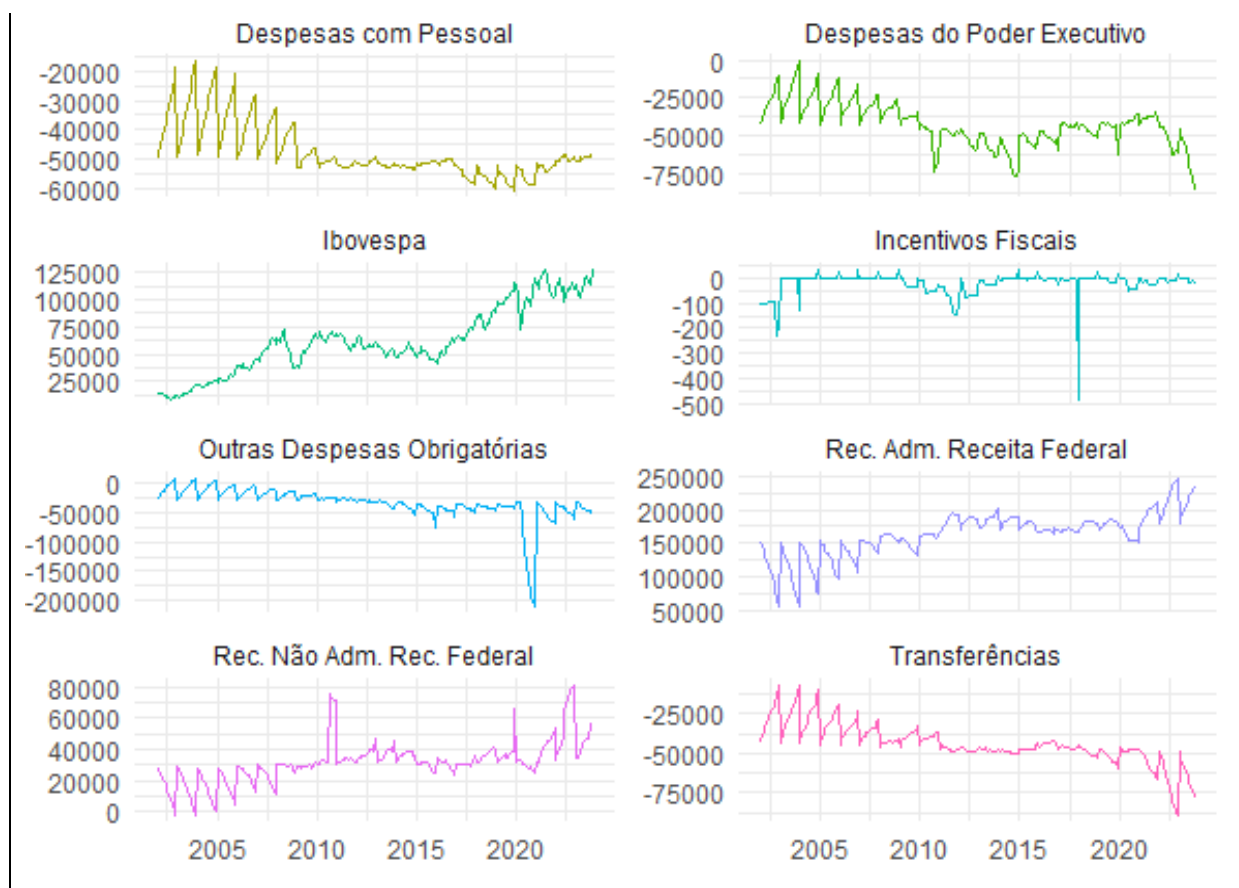
A análise das finanças públicas e do mercado de ações do Brasil revela uma arrecadação líquida com crescimento estável, porém volátil, refletindo ciclos econômicos e políticas fiscais. Os benefícios previdenciários evidenciam um aumento contínuo, desafiando a sustentabilidade fiscal diante do envelhecimento populacional.

As despesas com pessoal e do Poder Executivo mostram estabilidade, contrastando com a alta significativa e as correções do Ibovespa, que refletem o otimismo e as incertezas econômicas. Incentivos fiscais e outras despesas obrigatórias indicam estabilidade e ajustes fiscais, respectivamente, enquanto as receitas, tanto administradas quanto não administradas pela Receita Federal, demonstram crescimento com variações que acompanham a atividade econômica. As transferências em declínio sinalizam esforços de consolidação fiscal. Esse panorama integrado destaca a interação entre a performance do mercado acionário e as dinâmicas fiscais do governo.

**Gráfico 1** – Gráficos do Ibovespa, Receitas, Despesas e Transferências do Governo Federal do Brasil em milhões de reais (R\$) com dados mensais para o período de janeiro de 2002 até dezembro de 2023.







Fonte: Autoria própria utilizando 'R'.

A matriz de correlação apresentada no Gráfico 2 exibe as inter-relações entre o Ibovespa e diversas variáveis de receitas, despesas e transferências do Governo Federal do Brasil. A matriz utiliza um gradiente de cores para representar a intensidade e a direção das correlações, onde tons de azul indicam correlações positivas, e tons de vermelho, correlações negativas. Valores próximos a 1 ou -1 indicam fortes correlações positivas ou negativas, respectivamente, enquanto valores próximos a zero sugerem pouca ou nenhuma correlação. Entre os resultados mais notáveis, observa-se uma forte correlação positiva entre "Arrecadação Líquida" e "Receitas Administrativas da Receita Federal" (0,92), sugerindo que aumentos nas receitas federais administradas estão fortemente associados a aumentos na arrecadação líquida. Por outro lado, a "Arrecadação Líquida" também apresenta uma forte correlação negativa com "Transferências" (-0,96), indicando que aumentos nas transferências estão inversamente relacionados ao montante líquido arrecadado.


No que tange ao Ibovespa, as correlações individuais são em sua maioria fracas, com o coeficiente mais alto sendo 0,14 em relação às "Despesas com Pessoal". Este resultado indica que as variações no mercado acionário brasileiro têm uma relação limitada com as variáveis fiscais do governo federal incluídas nesta análise. Outras correlações do Ibovespa, como com "Outras Despesas Obrigatórias" (0,11) e "Receitas Administrativas da Receita Federal" (-0,18), reforçam a percepção de que não há uma forte dependência entre o desempenho do mercado acionário e as variáveis fiscais analisadas. Essa observação pode sugerir que outros fatores, talvez econômicos ou internacionais, tenham um impacto mais significativo no desempenho do Ibovespa do que as movimentações financeiras internas do governo.

Ademais, a ausência de correlações fortes entre o Ibovespa e as variáveis fiscais do governo enfatiza a complexidade e a multiplicidade de fatores que influenciam o mercado de ações, indicando que políticas fiscais, embora importantes, são apenas uma peça do quebra-



cabeça no entendimento do comportamento do mercado financeiro brasileiro. Dado que as correlações individuais entre as variáveis fiscais e o Ibovespa são fracas, a aplicação da Análise de Componentes Principais (PCA) pode ser útil para identificar impactos conjuntos e sintetizar a variabilidade das múltiplas variáveis em componentes principais, proporcionando uma compreensão mais profunda dos fatores que afetam o Ibovespa.

**Gráfico 2** – Matriz de Correlação do Ibovespa, Receitas, Despesas e Transferências do Governo Federal do Brasil.



Fonte: Autoria própria utilizando ‘R’.

#### 4.1 RESULTADOS DA ANÁLISE DO COMPONENTE PRINCIPAL (PCA)

Os resultados obtidos através da Análise de Componentes Principais fornecem uma visão abrangente sobre a estrutura subjacente das variáveis fiscais analisadas. A Tabela 3 oferece uma análise integrada da distribuição da variância e da contribuição de cada variável nas dimensões identificadas por uma Análise de Componentes Principais (PCA) aplicada às finanças públicas do Governo Federal do Brasil. Esta abordagem permite uma avaliação compreensiva de como as diferentes categorias financeiras impactam a variância total dos dados, identificando as principais dimensões que explicam a variabilidade observada.


A primeira dimensão (Dim.1) emerge como a mais significativa, com uma variância de 6,17, representando 68,55% da variância total, sugerindo que uma grande parte da variabilidade dos dados é capturada por esta dimensão. A segunda dimensão (Dim.2) contribui com 11,27%

para a variância total, e, juntamente com a primeira, essas dimensões acumulam quase 80% da variância total (79,82%). A terceira dimensão (Dim.3) acrescenta 9,68% à variância explicada, alcançando um acumulado de 89,51%, com as dimensões subsequentes contribuindo de forma decrescente.

**Tabela 3** – Distribuição, componentes de cada dimensão e gráfico da variância dos componentes principais (PCA) dos gastos, transferências e receitas do Governo Federal do Brasil.

	Dim.1	Dim.2	Dim.3	Dim.4	Dim.5	Dim.6	Dim.7	Dim.8	Dim.9
<b>Variância</b>	6,17	1,014	0,871	0,402	0,259	0,158	0,086	0,024	0,017
<b>% da Variância</b>	68,55%	11,27%	9,68%	4,46%	2,88%	1,75%	0,95%	0,26%	0,18%
<b>% Acum. da Variância</b>	68,55%	79,82%	89,51%	93,96%	96,84%	98,61%	99,55%	99,81%	100%

	Dim.1		Dim.2		Dim.3	
	ctr	cos2	ctr	cos2	ctr	cos2
<b>Arrecadação Líquida</b>	-0,952	14,688	0,029	0,083	0,05	0,287
<b>Incentivos Fiscais</b>	-0,078	0,098	0,975	93,63	-0,2	4,609
<b>Rec. Não Adm. Rec. Federal</b>	-0,85	11,721	0,04	0,158	0,308	10,917
<b>Rec. Adm. Receita Federal</b>	-0,953	14,719	0,067	0,443	0,186	3,953
<b>Transferências</b>	0,946	14,493	-0,071	0,494	-0,088	0,882
<b>Benefícios Previdenciários</b>	0,919	13,693	0,037	0,136	0,241	6,661
<b>Despesas do Poder Executivo</b>	0,858	11,945	0,016	0,024	-0,277	8,83
<b>Outras Despesas Obrigatórias</b>	0,608	5,987	0,193	3,689	0,732	61,541
<b>Despesas com Pessoal</b>	0,884	12,657	0,117	1,344	0,142	2,321



Fonte: Autoria própria utilizando 'R'.

Os componentes das três primeiras dimensões revelam a importância variável das categorias financeiras. Na Dim.1, Arrecadação Líquida e Receita Administrada pela Receita Federal apresentam as maiores contribuições e qualidades de representação (cos2), evidenciando uma correlação forte com a dimensão. Incentivos Fiscais dominam a Dim.2 com

uma contribuição e qualidade de representação notáveis ( $\cos^2$  de 93.63%), refletindo a influência predominante dessa variável nesta dimensão. Na Dim.3, Outras Despesas Obrigatórias são proeminentes, indicando a relevância dessa categoria na explicação da variância.

Esta análise detalhada, agora consolidada na Tabela 3, não só fornece informações sobre a distribuição da variância e a contribuição das variáveis nas dimensões principais, mas também ilustra a complexidade da estrutura fiscal do governo, destacando as inter-relações e o impacto significativo de certas categorias sobre as finanças públicas brasileiras. Ao incluir tanto a distribuição da variância quanto as especificidades dos componentes em uma tabela unificada, ganhamos uma visão clara e concisa de quais aspectos das finanças públicas são mais influentes e como eles se interconectam dentro do contexto econômico brasileiro.

Ao analisar os resultados de uma Análise de Componentes Principais (PCA), é crucial proceder com cautela e atenção a detalhes específicos. Primeiramente, deve-se considerar cuidadosamente o número de componentes a serem retidos, o que pode ser informado pelo gráfico de percentual de variância, mas também deve ser guiado pelo contexto e pela interpretabilidade.

A seleção de muitas dimensões pode incluir ruído e complexidade desnecessária, enquanto poucas dimensões podem deixar de capturar aspectos importantes dos dados. É importante também lembrar que a PCA é uma técnica de redução de dimensionalidade que se baseia em correlações lineares. Portanto, ela pode não capturar relações não lineares complexas entre as variáveis. Além disso, embora a PCA reduza a dimensionalidade, isso não significa que as dimensões retidas sejam necessariamente independentes de considerações externas, como implicações econômicas ou políticas.

Outro ponto a considerar é a interpretação das cargas das componentes. Enquanto altos valores absolutos indicam variáveis que têm forte influência nas componentes, eles não revelam a direção dessa influência ou a causalidade subjacente. Além disso, a variância explicada pelas componentes pode refletir a influência de outliers ou de padrões específicos de variação que não são generalizáveis para outras situações ou conjuntos de dados.

Por último, a normalização dos dados antes da aplicação da PCA é uma prática padrão, porém deve-se estar ciente de que isso pode afetar a interpretação dos componentes principais. A padronização presume que todas as variáveis têm igual importância a priori, o que pode não ser o caso em todos os contextos. Portanto, a seleção de variáveis e o entendimento de sua relevância no estudo são fundamentais para uma análise robusta e significativa.

## **4.2 RESULTADOS ARMAX-GARCHX COM DIMENSÕES PCA**

Para identificar os modelos ARMAX-GARCHX com os menores valores do Critério de Informação Akaike (AIC), foram estimadas 243 combinações<sup>4</sup> de ordens (n, o, p, q), utilizando como variáveis exógenas as três primeiras dimensões da Análise de Componentes Principais (PCA). Contudo, antes de avançar, é essencial verificar a estacionariedade das séries. A Tabela 4 apresenta os resultados do Teste de Dickey-Fuller Aumentado, aplicado aos retornos do Ibovespa e às três principais componentes da PCA das Contas Públicas Federais do Brasil, com o intuito de avaliar essa característica nas séries analisadas.

---

<sup>4</sup> Ver Anexo “A” – Modelos ARMAX-GARCHX para o Ibovespa e Política Fiscal.

**Tabela 4** – Teste de estacionariedade para os retornos do Ibovespa (log-retorno) e as 3 primeiras dimensões da Análise de Componentes Principais (PCA) das Contas Públicas Federais do Brasil.

Variável	Dickey-Fuller-Aumentado	P-valor	Hipótese Alternativa
<b>Ibovespa (log-retorno)</b>	-6,5103	0,01	Estacionária
<b>Dimensão 1</b>	-5,4785	0,01	Estacionária
<b>Dimensão 2</b>	-4,326	0,01	Estacionária
<b>Dimensão 3</b>	-3,799	0,01952	Estacionária

Nota: De acordo com Dickey e Fuller (1979), o teste de raiz unitária tem como hipótese nula que a série não é estacionária.

Fonte: Autoria própria.

Todos os valores obtidos, incluindo o Ibovespa (-6,5103), a Dimensão 1 (-5,4785), a Dimensão 2 (-4,326), e a Dimensão 3 (-3,799), demonstram estatísticas de teste suficientemente negativas para rejeitar a hipótese nula de não estacionariedade ao nível de significância de 0,01 para as três primeiras e 0,01952 para a última, indicando que todas as séries são estacionárias. Isso sugere uma estabilidade de longo prazo tanto nos retornos do Ibovespa quanto nas características fiscais do governo brasileiro representadas pelas dimensões da PCA, permitindo análises mais aprofundadas sobre suas dinâmicas temporais.

Na sequência, a Tabela 5 apresenta os resultados dos modelos ARX-S-GARCHX, ARMAX-E-GARCHX e ARX-GJR-GARCHX para a equação do Ibovespa (log-retorno) e as 3 primeiras dimensões do PCA como variável exógena. A análise dos coeficientes significativos para as variáveis exógenas (MXREG) nos modelos oferece informações importantes sobre a interação entre condições econômicas ou políticas e o mercado financeiro. Estas dimensões encapsulam aspectos cruciais das finanças públicas, incluindo arrecadação líquida, incentivos fiscais, receitas não administradas e administradas pela Receita Federal, transferências, benefícios previdenciários, despesas do poder executivo, outras despesas obrigatórias e despesas com pessoal.

Na primeira dimensão, que se refere predominantemente à arrecadação líquida e às despesas do governo, observa-se que os coeficientes MXREG (1) são altamente significativos em todos os modelos analisados. No modelo S-GARCH, o coeficiente MXREG (1) é 0,00290\*\*\*, no E-GARCH é 0,00294\*\*\*, e no GJR-GARCH é 0,00325\*\*\*. Esses valores sugerem que grande parte dos retornos do mercado de ações pode ser atribuída a variações na capacidade do governo de gerar receitas e administrar seus gastos. A significância desses coeficientes indica que mudanças nas condições fiscais gerais do governo têm um impacto direto e notável na média condicional dos retornos do Ibovespa. Além disso, o coeficiente VXREG (1), que captura o impacto sobre a volatilidade condicional, também é significativo no E-GARCH 0,01530\*, e no GJR-GARCH 0,00001\*\*\*, indicando que essa dimensão afeta não só os retornos, mas também a incerteza no mercado.

**Tabela 5** – Resultados dos modelos ARMAX-S-GARCHX, ARMAX-E-GARCHX e ARX-GJR-GARCHX para a equação do Ibovespa (log-retorno) e as 3 primeiras dimensões do PCA como variável exógena.

Modelo	S-GARCH	E-GARCH	GJR-GARCH
<b>Ordem ARMA</b>	(3,3)	(3,3)	(3,3)
<b>Ordem GARCH</b>	(2,3)	(3,1)	(1,1)

Equação da Média Condicional			
<b>Mu</b>	0,00738***	0,00779***	0,00732***
	(0,00001)	(0,00001)	(0,00001)
<b>AR (1)</b>	-0,40384***	-0,61844***	-0,48620***
	(0,00014)	(0,00036)	(0,00005)
<b>AR (2)</b>	0,84494***	0,77328***	0,85505***
	(0,00019)	(0,00046)	(0,00004)
<b>AR (3)</b>	0,27865***	0,41826***	0,36596***
	(0,00010)	(0,00024)	(0,00006)
<b>MA (1)</b>	0,50713***	0,66728***	0,58666***
	(0,00013)	(0,00001)	(0,00010)
<b>MA (2)</b>	-1,04728***	-1,03302***	-1,04111***
	(0,00033)	(0,00030)	(0,00014)
<b>MA (3)</b>	-0,53035***	-0,68265***	-0,60288***
	(0,00013)	(0,00001)	(0,00005)
<b>MXREG (1)</b>	0,00290***	0,00294***	0,00325***
	(0,00001)	(0,00001)	(0,00001)
<b>MXREG (2)</b>	0,00256***	0,00263***	0,00412***
	(0,00006)	(0,00003)	(0,00002)
<b>MXREG (3)</b>	-0,00732***	-0,00787***	-0,00882***
	(0,00010)	(0,00016)	(0,00011)

Equação da Volatilidade Condicional:			
<b>Omega</b>	0,00001*	-0,90149***	0,00002***
	(0,00001)	(0,03068)	(0,00001)
<b>Alpha (1)</b>	0,00103	-0,38777***	0,00001
	(0,02809)	(0,00694)	(0,00007)
<b>Alpha (2)</b>	0,00020	0,16371*	-
	(0,00114)	(0,08998)	-
<b>Alpha (3)</b>	-	0,18843*	-
	-	(0,10258)	-
<b>Beta (1)</b>	0,04752	0,84145***	0,99998***
	(0,05597)	(0,00457)	(0,00003)
<b>Beta (2)</b>	0,27082***	-	-
	(0,08257)	-	-
<b>Beta (3)</b>	0,67620***	-	-
	(0,02655)	-	-
<b>VXREG (1)</b>	0,00001	0,01530*	0,00001***
	(0,00001)	(0,00863)	(0,00001)
<b>VXREG (2)</b>	0,00001	0,00339	0,00001
	(0,00011)	(0,02654)	(0,00001)
<b>VXREG (3)</b>	0,00001	-0,00876	0,00001
	(0,00007)	(0,02403)	(0,00001)
<b>Gamma (1)</b>	-	-0,32029***	-0,01070***
	-	(0,05620)	(0,00013)
<b>Gamma (2)</b>	-	-0,09618***	-

	-	(0,02589)	-
	-	0,45446***	-
<b>Gamma (3)</b>	-	(0,11114)	-
<hr/>			
<b>Log-Lik.</b>	6149,685	6158,031	6150,471
<b>AIC</b>	-2,59523	-2,65248	-2,61545
<b>BIC</b>	-2,32358	-2,35366	-2,37096
<b>LM (Het.)</b>	0,334	0,512	0,295
<b>Ljung-Box</b>	0,40159	0,87333	0,48629

Nota: i) Os asteriscos denotam o nível de significância estatística dos coeficientes: \*\*\*  $p < 0.01$  (significância a 1%); \*\*  $p < 0.05$  (significância a 5%); \*  $p < 0.1$  (significância a 10%).

ii) Os números entre parênteses são os erros padrões associados a cada estimador de coeficiente.

iii) Log-Lik. (Logaritmo da verossimilhança) - Indica o quão bem o modelo se ajusta aos dados.

iv) AIC (Critério de Informação de Akaike) e BIC (Critério de Informação Bayesiano) - Critérios para seleção de modelo; menores valores indicam um ajuste superior.

v) LM (Lagrange Multiplier) em p-valor com  $h_0$ : Hipótese de homocedasticidade.

vi) Ljung-Box em p-valor com  $h_0$ : Dados não autocorrelacionados.

Fonte: Autoria própria utilizando 'R'.

A segunda dimensão está associada principalmente a incentivos fiscais, refletindo como políticas específicas para estimular a economia através de benefícios fiscais influenciam o mercado de ações. Novamente, os coeficientes MXREG (2) mostram significância em todos os modelos: 0,00256\*\*\* no modelo S-GARCH, 0,00263\*\*\* no E-GARCH e 0,00412\*\*\* no GJR-GARCH. Esses coeficientes sugerem que os investidores reagem positivamente a medidas que podem impulsionar a atividade econômica, influenciando diretamente os retornos do Ibovespa. Em termos de volatilidade condicional, o VXREG (2) é positivo nos três modelos, com valores de 0,00001 no S-GARCH, 0,00339 no E-GARCH, e 0,00001 no GJR-GARCH, sugerindo que essa dimensão também pode aumentar a incerteza nos mercados (especialmente em momentos de política fiscal expansionista) porém não houve significância estatística.

Na terceira dimensão, que destaca outras despesas obrigatórias do governo, os coeficientes MXREG (3) são altamente significativos e negativos: -0,00732\*\*\* no modelo S-GARCH, -0,00787\*\*\* no E-GARCH e -0,00882\*\*\* no GJR-GARCH. Esses resultados apontam para a sensibilidade do mercado em relação às obrigações financeiras do governo, refletindo preocupações sobre a sustentabilidade fiscal de longo prazo e seu impacto nos retornos do Ibovespa. No que se refere à volatilidade condicional, o coeficiente VXREG (3) mostra um impacto mais modesto, com valores de 0,00001 no S-GARCH, -0,00876 no E-GARCH e 0,00001 no GJR-GARCH, sugerindo que essa dimensão pode ter um papel limitado na incerteza do mercado, mas ainda é relevante para a dinâmica da volatilidade.

Em suma, a análise dos modelos ARMAX-S-GARCHX, ARMAX-E-GARCHX e ARMAX-GJR-GARCHX, utilizando as três primeiras dimensões do PCA, revela uma relação dinâmica e complexa entre a política fiscal do governo e o mercado de ações brasileiro. Mudanças nas arrecadações e despesas, políticas de incentivo fiscal e obrigações financeiras governamentais afetam diretamente a média dos retornos do Ibovespa, enquanto também influenciam a volatilidade condicional do mercado, destacando o papel crítico das finanças públicas na estabilidade e crescimento do mercado financeiro.

## 5 CONSIDERAÇÕES FINAIS

A análise econômica abrangente conduzida neste estudo, baseada tanto na Análise de Componentes Principais (PCA) quanto nos modelos ARMAX-GARCHX, ARMAX-E-



GARCHX e ARMAX-GJR-GARCHX, permite-nos concluir que há uma interação significativa e complexa entre as políticas fiscais do governo brasileiro e a performance do mercado de ações, representada pelo Ibovespa. Os resultados obtidos oferecem informações importantes sobre como as variações nas políticas fiscais influenciam a estabilidade financeira e os retornos no mercado de ações, sobretudo em uma economia emergente e volátil como a do Brasil.

A aplicação da Análise de Componentes Principais (PCA) nas finanças públicas do Brasil destaca a predominância da primeira dimensão, que explica 68,55% da variância total, sugerindo a centralidade da arrecadação líquida e despesas governamentais nas variações dos dados fiscais. Esta dimensão enfatiza a relação entre as práticas fiscais e a percepção de estabilidade econômica, que pode influenciar indiretamente as expectativas dos investidores e, por extensão, o comportamento do mercado de ações. As segunda e terceira dimensões, que destacam a importância dos incentivos fiscais e outras despesas obrigatórias, indicam áreas adicionais que potencialmente afetam a confiança do investidor.

Os modelos ARMAX-S-GARCHX, ARMAX-E-GARCHX e ARMAX-GJR-GARCHX permitiram uma análise detalhada dos retornos condicionais e dos efeitos assimétricos das variáveis fiscais sobre o Ibovespa. Os coeficientes MXREG, que representam o impacto direto das variáveis fiscais sobre a média condicional dos retornos, foram altamente significativos para as três primeiras dimensões do PCA. A primeira dimensão, relacionada à arrecadação líquida e às despesas do governo, mostrou-se especialmente influente, indicando que a capacidade do governo de gerar receitas e controlar gastos afeta diretamente os retornos do mercado de ações. A segunda dimensão, associada a incentivos fiscais, também foi significativa, sugerindo que políticas de estímulo fiscal influenciam positivamente as expectativas dos investidores e a performance do Ibovespa. Já a terceira dimensão, ligada a outras despesas obrigatórias, apresentou coeficientes MXREG negativos e significativos, destacando o impacto das obrigações financeiras do governo na confiança dos investidores e a preocupação com a sustentabilidade fiscal.

Além disso, os coeficientes VXREG, que medem o impacto dessas mesmas variáveis fiscais sobre a volatilidade condicional dos retornos, revelaram que, embora a primeira dimensão também afete a incerteza do mercado, especialmente nos modelos E-GARCH e GJR-GARCH, os efeitos da segunda e terceira dimensões na volatilidade são mais modestos, com significância estatística limitada. Isso sugere que, embora as políticas fiscais influenciem os retornos, seu impacto no risco, medido pela volatilidade, é menos evidente. Isso pode indicar que as informações fiscais estão sendo absorvidas de maneira eficiente pelo mercado, sem aumentar a percepção de risco das empresas brasileiras. Conclui-se, portanto, que as políticas fiscais desempenham um papel fundamental na determinação dos retornos do mercado de ações no Brasil. O estudo reforça a necessidade de uma gestão fiscal prudente e de políticas que promovam a estabilidade econômica e financeira. A compreensão detalhada das dinâmicas entre as finanças públicas e o mercado de ações é vital para investidores, formuladores de políticas e economistas, especialmente em contextos de incerteza econômica global. Este trabalho não apenas avança no conhecimento acadêmico sobre a relação entre política fiscal e mercado de ações brasileiro, mas também busca oferecer implicações práticas para a formulação de políticas econômicas e estratégias de investimento no país.



## REFERÊNCIAS

AKAIKE, H. A new look at the statistical model identification. **IEEE Transactions on Automatic Control**, 1974.

APERGIS, N.; REZITIS, A. N. Food Price Volatility and Macroeconomic Factors: Evidence from GARCH and GARCH-X Estimates. **Journal of Agricultural and Applied Economics**, v. 43, n. 1, 2011.

BOLLERSLEV, T. Generalized Autoregressive Conditional Heteroskedasticity. **Journal of Econometrics**, v. 31, n. 3, p. 307-327, abr. 1986.

CHATZIANTONIOU, I.; DUFFY, D.; FILIS, G. Stock market response to monetary and fiscal policy shocks: Multi-country evidence. **Journal of Economic Studies**, v. 39, n. 6, p. 602-621, 2013.

DICKEY, D. A.; FULLER, W. A. Distribution of the Estimators for Autoregressive Time Series with a Unit Root. **Journal of the American Statistical Association**, v. 74, n. 366, p. 427-431, jun. 1979.

ENGLE, R.F. Autoregressive Conditional Heteroskedasticity with Estimates of the Variance of United Kingdom Inflation. **Econometrica**, v. 50, n. 4, p. 987-1007, jul. 1982.

FAMA, E. F. Efficient capital markets: A review of theory and empirical work. **Journal of Finance**, v. 25, n. 2, p. 383-417, maio 1970.

FORESTI, P.; NAPOLITANO, O. On the stock market reactions to fiscal policies. **International Journal of Finance & Economics**, v. 22, n. 3, p. 244-258, 2017.

HAN, H.; KRISTENSEN, D. Asymptotic Theory for the QMLE in GARCH-X Models With Stationary and Nonstationary Covariates. **Journal of Business & Economic Statistics**, p. 416-429, 2014.

HOTELLING, H. Analysis of a complex of statistical variables into principal components. **Journal of Educational Psychology**, v. 24, n. 6, p. 417-441, 1933.

HSING, Y. Effects of Fiscal Policy and Monetary Policy on the Stock Market in Poland. **Economies**, v. 1, n. 3, p. 19-25, 2013.

HU, L.; HAN, J.; ZHANG, Q. The Impact of Monetary and Fiscal Policy Shocks on Stock Markets: Evidence from China. **Asian Economic and Financial Review**, v. 3, n. 11, p. 1463-1471, 2018.

JOLLIFFE, I. T. **Principal Component Analysis**. 2. ed. New York: Springer, 2002.

LAOPODIS, N. T. Fiscal policy and stock market efficiency: Evidence for the United States. **Review of Financial Economics**, v. 17, n. 1, p. 1-19, 2009.

PEARSON, K. On lines and planes of closest fit to systems of points in space. **The London, Edinburgh, and Dublin Philosophical Magazine and Journal of Science**, v. 2, n. 11, p. 559-572, 1901.

SUHARTONO; LEE, M. H.; PRASTYO, D. D. Two levels ARIMAX and regression models for forecasting time series data with calendar variation effects. **AIP Conference Proceedings**, v. 1691, 050026, 2015.

TESOURO NACIONAL. **Séries Temporais do Tesouro Nacional (Tesouro Transparente)**. Disponível em: <https://www.tesourotransparente.gov.br/visualizacao/series-temporais-do-tesouro-nacional>. Acesso em: 2024.

YAHOO FINANCE. **Yahoo Finance API**. Disponível em: <https://finance.yahoo.com/>. Acesso em: 2024.

## ANEXO A – MODELOS ARMAX-GARCHX DO IBOVESPA E POLÍTICA FISCAL

Modelo	p	q	n	o	AIC	Modelo	p	q	n	o	AIC	Modelo	p	q	n	o	AIC
S-GARCH	1	1	1	1	-2,48173	E-GARCH	1	1	1	1	-2,54993	GJR-GARCH	1	1	1	1	-2,47867
S-GARCH	1	1	1	2	-2,47285	E-GARCH	1	1	1	2	-2,53396	GJR-GARCH	1	1	1	2	-2,47074
S-GARCH	1	1	1	3	-2,47398	E-GARCH	1	1	1	3	-2,55313	GJR-GARCH	1	1	1	3	-2,47067
S-GARCH	1	1	2	1	-2,54456	E-GARCH	1	1	2	1	-2,57086	GJR-GARCH	1	1	2	1	-2,55197
S-GARCH	1	1	2	2	-2,52188	E-GARCH	1	1	2	2	-2,57951	GJR-GARCH	1	1	2	2	-2,58218
S-GARCH	1	1	2	3	-2,56651	E-GARCH	1	1	2	3	-2,56634	GJR-GARCH	1	1	2	3	-2,57386
S-GARCH	1	1	3	1	-2,54041	E-GARCH	1	1	3	1	-2,56506	GJR-GARCH	1	1	3	1	-2,5468
S-GARCH	1	1	3	2	-2,56923	E-GARCH	1	1	3	2	-2,56412	GJR-GARCH	1	1	3	2	-2,56546
S-GARCH	1	1	3	3	-2,56675	E-GARCH	1	1	3	3	-2,62415	GJR-GARCH	1	1	3	3	-2,61545
S-GARCH	1	2	1	1	-2,47416	E-GARCH	1	2	1	1	-2,51458	GJR-GARCH	1	2	1	1	-2,47664
S-GARCH	1	2	1	2	-2,46524	E-GARCH	1	2	1	2	-2,52436	GJR-GARCH	1	2	1	2	-2,46854
S-GARCH	1	2	1	3	-2,46637	E-GARCH	1	2	1	3	-2,53706	GJR-GARCH	1	2	1	3	-2,46793
S-GARCH	1	2	2	1	-	E-GARCH	1	2	2	1	-2,57965	GJR-GARCH	1	2	2	1	-2,55057
S-GARCH	1	2	2	2	-2,51427	E-GARCH	1	2	2	2	-2,57025	GJR-GARCH	1	2	2	2	-2,51586
S-GARCH	1	2	2	3	-2,55662	E-GARCH	1	2	2	3	-2,55759	GJR-GARCH	1	2	2	3	-2,56364
S-GARCH	1	2	3	1	-2,53261	E-GARCH	1	2	3	1	-2,56985	GJR-GARCH	1	2	3	1	-2,54567
S-GARCH	1	2	3	2	-2,56588	E-GARCH	1	2	3	2	-2,56154	GJR-GARCH	1	2	3	2	-2,56928
S-GARCH	1	2	3	3	-2,56111	E-GARCH	1	2	3	3	-2,61512	GJR-GARCH	1	2	3	3	-2,56211
S-GARCH	1	3	1	1	-2,46652	E-GARCH	1	3	1	1	-2,5561	GJR-GARCH	1	3	1	1	-2,46825
S-GARCH	1	3	1	2	-2,45768	E-GARCH	1	3	1	2	-2,54232	GJR-GARCH	1	3	1	2	-2,46055
S-GARCH	1	3	1	3	-2,45876	E-GARCH	1	3	1	3	-2,54739	GJR-GARCH	1	3	1	3	-2,46034
S-GARCH	1	3	2	1	-2,5292	E-GARCH	1	3	2	1	-2,55601	GJR-GARCH	1	3	2	1	-2,54-5
S-GARCH	1	3	2	2	-2,50669	E-GARCH	1	3	2	2	-2,60269	GJR-GARCH	1	3	2	2	-2,59904
S-GARCH	1	3	2	3	-2,55359	E-GARCH	1	3	2	3	-2,57752	GJR-GARCH	1	3	2	3	-2,55596
S-GARCH	1	3	3	1	-2,52485	E-GARCH	1	3	3	1	-2,58956	GJR-GARCH	1	3	3	1	-2,53804
S-GARCH	1	3	3	2	-2,58555	E-GARCH	1	3	3	2	-2,57191	GJR-GARCH	1	3	3	2	-2,56289
S-GARCH	1	3	3	3	-2,55129	E-GARCH	1	3	3	3	-2,57271	GJR-GARCH	1	3	3	3	-2,5477
S-GARCH	2	1	1	1	-2,47419	E-GARCH	2	1	1	1	-2,54094	GJR-GARCH	2	1	1	1	-2,49506
S-GARCH	2	1	1	2	-2,46518	E-GARCH	2	1	1	2	-2,57114	GJR-GARCH	2	1	1	2	-2,58654
S-GARCH	2	1	1	3	-2,56651	E-GARCH	2	1	1	3	-2,54374	GJR-GARCH	2	1	1	3	-2,49804
S-GARCH	2	1	2	1	-2,5371	E-GARCH	2	1	2	1	-2,56915	GJR-GARCH	2	1	2	1	-2,55092
S-GARCH	2	1	2	2	-2,51428	E-GARCH	2	1	2	2	-2,60633	GJR-GARCH	2	1	2	2	-2,5162
S-GARCH	2	1	2	3	-2,53616	E-GARCH	2	1	2	3	-2,59717	GJR-GARCH	2	1	2	3	-2,30297
S-GARCH	2	1	3	1	-2,53284	E-GARCH	2	1	3	1	-2,56645	GJR-GARCH	2	1	3	1	-2,55431
S-GARCH	2	1	3	2	-2,57054	E-GARCH	2	1	3	2	-2,5973	GJR-GARCH	2	1	3	2	-2,57452
S-GARCH	2	1	3	3	-2,51954	E-GARCH	2	1	3	3	-2,56612	GJR-GARCH	2	1	3	3	-2,55732
S-GARCH	2	2	1	1	-2,46656	E-GARCH	2	2	1	1	-2,54447	GJR-GARCH	2	2	1	1	-2,51533
S-GARCH	2	2	1	2	-2,45764	E-GARCH	2	2	1	2	-2,57545	GJR-GARCH	2	2	1	2	-2,47897
S-GARCH	2	2	1	3	-2,45877	E-GARCH	2	2	1	3	-2,53521	GJR-GARCH	2	2	1	3	-2,49669
S-GARCH	2	2	2	1	-2,52946	E-GARCH	2	2	2	1	-2,57831	GJR-GARCH	2	2	2	1	-2,48465
S-GARCH	2	2	2	2	-2,50645	E-GARCH	2	2	2	2	-2,57972	GJR-GARCH	2	2	2	2	-2,50766
S-GARCH	2	2	2	3	-2,55872	E-GARCH	2	2	2	3	-2,55871	GJR-GARCH	2	2	2	3	-2,56921
S-GARCH	2	2	3	1	-2,52485	E-GARCH	2	2	3	1	-2,58784	GJR-GARCH	2	2	3	1	-2,51734
S-GARCH	2	2	3	2	-2,5669	E-GARCH	2	2	3	2	-2,60272	GJR-GARCH	2	2	3	2	-2,57322

S-GARCH	2	2	3	3	-2,54504	E-GARCH	2	2	3	3	-2,56946	GJR-GARCH	2	2	3	3	-2,56228
S-GARCH	2	3	1	1	-2,459	E-GARCH	2	3	1	1	-2,54-5	GJR-GARCH	2	3	1	1	-2,50194
S-GARCH	2	3	1	2	-2,44975	E-GARCH	2	3	1	2	-2,55459	GJR-GARCH	2	3	1	2	-2,48994
S-GARCH	2	3	1	3	-2,45114	E-GARCH	2	3	1	3	-2,56235	GJR-GARCH	2	3	1	3	-2,46057
S-GARCH	2	3	2	1	-2,52183	E-GARCH	2	3	2	1	-2,56597	GJR-GARCH	2	3	2	1	-2,47575
S-GARCH	2	3	2	2	-2,49892	E-GARCH	2	3	2	2	-2,5862	GJR-GARCH	2	3	2	2	-2,48301
S-GARCH	2	3	2	3	-2,53895	E-GARCH	2	3	2	3	-2,5734	GJR-GARCH	2	3	2	3	-2,5563
S-GARCH	2	3	3	1	-2,51731	E-GARCH	2	3	3	1	-2,62431	GJR-GARCH	2	3	3	1	-2,54733
S-GARCH	2	3	3	2	-2,55537	E-GARCH	2	3	3	2	-2,57181	GJR-GARCH	2	3	3	2	-2,55889
S-GARCH	2	3	3	3	-2,59523	E-GARCH	2	3	3	3	-2,57719	GJR-GARCH	2	3	3	3	-2,55115
S-GARCH	3	1	1	1	-2,4666	E-GARCH	3	1	1	1	-2,51965	GJR-GARCH	3	1	1	1	-2,49501
S-GARCH	3	1	1	2	-2,45772	E-GARCH	3	1	1	2	-2,58703	GJR-GARCH	3	1	1	2	-2,48722
S-GARCH	3	1	1	3	-2,4588	E-GARCH	3	1	1	3	-2,51888	GJR-GARCH	3	1	1	3	-2,48231
S-GARCH	3	1	2	1	-2,52954	E-GARCH	3	1	2	1	-2,56865	GJR-GARCH	3	1	2	1	-2,54692
S-GARCH	3	1	2	2	-2,50671	E-GARCH	3	1	2	2	-2,58676	GJR-GARCH	3	1	2	2	-2,58697
S-GARCH	3	1	2	3	-2,54817	E-GARCH	3	1	2	3	-2,58731	GJR-GARCH	3	1	2	3	-2,54951
S-GARCH	3	1	3	1	-2,52529	E-GARCH	3	1	3	1	-2,56407	GJR-GARCH	3	1	3	1	-2,54371
S-GARCH	3	1	3	2	-2,55045	E-GARCH	3	1	3	2	-2,57595	GJR-GARCH	3	1	3	2	-2,55463
S-GARCH	3	1	3	3	-2,08653	E-GARCH	3	1	3	3	-2,65248	GJR-GARCH	3	1	3	3	-2,59276
S-GARCH	3	2	1	1	-2,45902	E-GARCH	3	2	1	1	-2,54701	GJR-GARCH	3	2	1	1	-2,48946
S-GARCH	3	2	1	2	-2,45008	E-GARCH	3	2	1	2	-2,58958	GJR-GARCH	3	2	1	2	-2,48344
S-GARCH	3	2	1	3	-2,45117	E-GARCH	3	2	1	3	-2,53817	GJR-GARCH	3	2	1	3	-2,47993
S-GARCH	3	2	2	1	-2,52185	E-GARCH	3	2	2	1	-2,57212	GJR-GARCH	3	2	2	1	-2,48115
S-GARCH	3	2	2	2	-2,49909	E-GARCH	3	2	2	2	-2,58352	GJR-GARCH	3	2	2	2	-2,50567
S-GARCH	3	2	2	3	-2,5453	E-GARCH	3	2	2	3	-2,64199	GJR-GARCH	3	2	2	3	-2,54452
S-GARCH	3	2	3	1	-2,51736	E-GARCH	3	2	3	1	-2,56842	GJR-GARCH	3	2	3	1	-2,54336
S-GARCH	3	2	3	2	-2,54719	E-GARCH	3	2	3	2	-2,57991	GJR-GARCH	3	2	3	2	-2,55257
S-GARCH	3	2	3	3	-2,57792	E-GARCH	3	2	3	3	-2,57565	GJR-GARCH	3	2	3	3	-2,5445
S-GARCH	3	3	1	1	-2,4514	E-GARCH	3	3	1	1	-2,54854	GJR-GARCH	3	3	1	1	-2,48023
S-GARCH	3	3	1	2	-2,44246	E-GARCH	3	3	1	2	-2,56182	GJR-GARCH	3	3	1	2	-2,48295
S-GARCH	3	3	1	3	-2,44355	E-GARCH	3	3	1	3	-2,54804	GJR-GARCH	3	3	1	3	-2,48656
S-GARCH	3	3	2	1	-2,51424	E-GARCH	3	3	2	1	-2,58277	GJR-GARCH	3	3	2	1	-2,47823
S-GARCH	3	3	2	2	-2,49148	E-GARCH	3	3	2	2	-2,56541	GJR-GARCH	3	3	2	2	-2,47961
S-GARCH	3	3	2	3	-2,54111	E-GARCH	3	3	2	3	-2,5665	GJR-GARCH	3	3	2	3	-2,54777
S-GARCH	3	3	3	1	-2,50982	E-GARCH	3	3	3	1	-2,56082	GJR-GARCH	3	3	3	1	-2,53454
S-GARCH	3	3	3	2	-2,54014	E-GARCH	3	3	3	2	-2,57551	GJR-GARCH	3	3	3	2	-2,5483
S-GARCH	3	3	3	3	-2,58562	E-GARCH	3	3	3	3	-2,56533	GJR-GARCH	3	3	3	3	-2,52801

Nota: i) Sinais (-) representam valores nulos onde não foi possível estimar a equação por falta de convergência;  
ii) Variações de ordens ( $p, q, n, o$ ) com os menores valores do Critério Akaike (AIC) estão assinalados em linha tracejada.

Fonte: Autoria própria.



ISBN nº 978-65-01-11585-6

## RISCO SOBERANO E O MERCADO FINANCEIRO BRASILEIRO: ANÁLISE VIA ARMAX-GARCHX

Adilson Padovan Junior <sup>1</sup>  
Joilson Giorno <sup>2</sup>

### Área 3 – Macroeconomia, Economia Monetária, Finanças e Economia Internacional

**RESUMO:** Este estudo investiga a relação entre o risco soberano e o mercado financeiro brasileiro utilizando a modelagem ARMAX-GARCHX, com foco no Ibovespa e no Risco Brasil. A análise, baseada em séries temporais diárias de 2015 a 2023, utiliza modelos de volatilidade como GARCH, E-GARCH e GJR-GARCH - total de 243 combinações de ordens (n, o, p, q) - para capturar a dinâmica de retorno e volatilidade do índice de mercado. Os testes de causalidade de Granger mostram que o Risco Brasil Granger-cause o Ibovespa, mas o contrário não ocorre. Os resultados revelam uma relação inversa entre o Risco Brasil e os retornos do Ibovespa, sugerindo que o aumento de 1% no risco soberano está associado a uma redução de 0,28% nos retornos médios de mercado para o período seguinte (*ceteris paribus*). Além disso, aumentos no risco estão fortemente relacionados a maior volatilidade no Ibovespa refletindo a aversão dos investidores. A análise também destaca a persistência da volatilidade e assimetrias nos choques de mercado, especialmente em períodos de instabilidade, reforçando a importância de entender o impacto do risco soberano sobre o mercado acionário.

**Palavras-chave:** Risco Soberano; Ibovespa; Volatilidade.

**ABSTRACT:** This study investigates the relationship between sovereign risk and the Brazilian financial market using ARMAX-GARCHX modeling, focusing on the Ibovespa and Brazil Risk. The analysis, based on daily time series from 2015 to 2023, utilizes volatility models such as GARCH, E-GARCH, and GJR-GARCH—a total of 243 combinations of orders (n, o, p, q)—to capture the return and volatility dynamics of the market index. Granger causality tests show that Brazil Risk Granger-causes the Ibovespa, but the reverse does not occur. The results reveal an inverse relationship between Brazil Risk and Ibovespa returns, suggesting that a 1% increase in sovereign risk is associated with a 0.28% reduction in average market returns for the subsequent period (*ceteris paribus*). Moreover, increases in risk are strongly related to higher volatility in the Ibovespa, reflecting investor aversion. The analysis also highlights the persistence of volatility and asymmetries in market shocks, especially in periods of instability, reinforcing the importance of understanding the impact of sovereign risk on the stock market.

**Keywords:** Sovereign Risk; Ibovespa; Volatility.

**Classificação JEL:** C58; G15; E44.

<sup>1</sup> Doutorando em Economia pelo Programa de Pós-Graduação em Ciências Econômicas da Universidade Estadual de Maringá (PCE/UEM), Maringá, Paraná, Brasil e Bolsista CAPES (Coordenação de Aperfeiçoamento de Pessoal de Nível Superior). E-mail: padovanjr@gmail.com

<sup>2</sup> Ph.D. in Economics at the University of South Carolina, USC, USA e Professor na Universidade Estadual de Maringá (PCE/UEM), Maringá, Paraná, Brasil. E-mail: jgiorno@uem.com

# **1 INTRODUÇÃO**

No ambiente dinâmico das finanças, a interação entre risco e retorno emerge como uma dualidade fundamental, guiando as decisões dos investidores e a gestão de portfólios. Central para esse debate é a teoria da aversão ao risco, introduzida por Pratt (1964), que postula que os indivíduos possuem uma tendência inerente a evitar riscos, optando por investimentos que, embora possam oferecer retornos mais modestos, são percebidos como menos arriscados. Esta inclinação para a segurança é particularmente relevante no mercado de ações, onde a volatilidade é uma característica intrínseca, e a habilidade de prever e mitigar riscos torna-se um determinante chave do sucesso financeiro.

No contexto específico do mercado financeiro brasileiro, estas dinâmicas podem se manifestar de maneira única, influenciadas por uma combinação de fatores econômicos, políticos e sociais que moldam a percepção e a gestão do risco. A volatilidade do Ibovespa, índice de referência da Bolsa de Valores de São Paulo, reflete não apenas as condições econômicas internas, mas também eventos globais que impactam os mercados emergentes de maneira significativa.

Sendo assim, este estudo visa explorar a relação entre risco e retorno no mercado financeiro brasileiro através da análise ARMAX-GARCHX. Os objetivos gerais incluem investigar como a aversão ao risco influencia as decisões de investimento no contexto do Ibovespa, assim como identificar padrões de volatilidade e suas causas subjacentes. Especificamente, pretende-se modelar a volatilidade condicional do Ibovespa utilizando técnicas avançadas de séries temporais, oferecendo informações sobre a dinâmica do mercado de ações brasileiro e fornecendo uma base analítica para a gestão de riscos e a tomada de decisões estratégicas por parte dos investidores e gestores de fundos.

Além da presente introdução, o estudo está organizado nas seguintes seções. A seção 2 aborda o risco soberano e os retornos de mercado, contextualizando a importância do estudo e seus objetivos. A seção 3 detalha os dados utilizados e a metodologia aplicada, com destaque para o método ARMAX-GARCHX e sua extensão GJR-GARCHX, além de incluir uma análise descritiva dos dados. Os resultados obtidos são discutidos na seção 4, onde se exploram as implicações dos achados e se identificam padrões de volatilidade. Por fim, a seção 5 traz as considerações finais, resumindo as principais conclusões do estudo e oferecendo recomendações para futuras pesquisas e práticas de gestão de riscos no mercado financeiro brasileiro.

## **2 RISCO SOBERANO E OS RETORNOS DE MERCADO**

Enquanto a teoria de Pratt (1964) oferece uma base para entender como os investidores avaliam o risco, o estudo do risco soberano e seu impacto sobre os retornos dos mercados financeiros expande esse entendimento para o âmbito macroeconômico. Nas últimas décadas, a investigação sobre como as variáveis macroeconômicas e políticas econômicas influenciam o risco dos países e, por sua vez, o desempenho dos mercados de ações, tem se intensificado.

A pesquisa de Montes e Tiberto (2012) ilustra claramente esse fenômeno, ressaltando o papel crucial da política monetária e da gestão da dívida pública na modulação do risco. Essa análise não apenas sublinha a importância da credibilidade e da reputação das instituições financeiras na mitigação do risco país, mas também destaca como esses elementos influenciam diretamente a performance do mercado acionário brasileiro, fornecendo uma ponte entre as decisões macroeconômicas e a psicologia dos investidores individuais em face ao risco.

Por outro lado, a abordagem de redes complexas, proposta por Pontes e Rêgo (2022), oferece uma nova perspectiva sobre como as oscilações macroeconômicas afetam a estrutura topológica do mercado de ações. Os autores utilizaram essa metodologia para demonstrar que variáveis como o Produto Interno Bruto (PIB), o Risco-Brasil, os pontos do Ibovespa e a taxa de juros influenciam diretamente as métricas globais da rede de ativos do mercado brasileiro. Essas descobertas sublinham o poder explanatório das variáveis macroeconômicas sobre a volatilidade e o risco no mercado de ações.

Além disso, Whitelaw (2000) investigou a relação intrincada e variável ao longo do tempo entre o risco de mercado e os retornos esperados das ações norte-americanas, sugerindo que a intuição de uma relação positiva direta entre risco e retorno pode não se manter em um ambiente econômico dinâmico caracterizado por mudanças de regime de consumo. Esta análise ressalta a necessidade de considerar as oportunidades de investimento variáveis ao longo do tempo ao avaliar a *trade-off* entre risco e retorno.

Aprofundando tais compreensões, Hammoudeh et al. (2013) investigam as relações entre os ratings de risco dos países BRICS (Brasil, Rússia, Índia, China e África do Sul) e os desempenhos de seus mercados de ações, bem como a sensibilidade destes ao mercado acionário dos EUA e ao preço do petróleo. Seus resultados indicam uma predominância da influência dos ratings de risco financeiro sobre os ratings de risco econômico e político, ilustrando como as avaliações de risco financeiro são mais impactantes na performance dos mercados de ações dos BRICS.

Finalmente, a instabilidade dos mercados emergentes, frequentemente exacerbada por mudanças nas classificações de dívida soberana, demonstra o impacto direto e o contágio entre países que as alterações nos ratings de crédito podem causar nos mercados financeiros. Kaminsky e Schmukler (2002) observam que tais mudanças afetam não apenas os instrumentos avaliados, como os títulos, mas também as ações, destacando o papel das agências de classificação de crédito na amplificação da instabilidade financeira.

Em conjunto, esses estudos fornecem uma visão abrangente de como o risco soberano está fortemente ligado aos retornos do mercado, oferecendo dados valiosos para investidores, analistas financeiros e formuladores de políticas. Sendo assim, as próximas seções se dedicam a apresentação dos dados, metodologia, resultados e discussões do presente estudo proposto.

### **3 DADOS E METODOLOGIA**

Nesta seção, são apresentados os dados e a metodologia que envolvem a relação do Ibovespa, que representa o desempenho das ações mais negociadas na Bolsa de Valores de São Paulo, e do Risco-Brasil, indicador do risco soberano medido pelo EMBI+ da *JP Morgan*. As amostras são diárias, abrangendo o período de 1º de janeiro de 2015 a 1º de junho de 2023. O Ibovespa foi escolhido por ser o principal índice do mercado de ações brasileiro, enquanto o Risco-Brasil oferece uma medida do risco soberano relevante para investidores locais e internacionais. Os dados para o Ibovespa foram obtidos do *Yahoo Finance* (2023), e os dados do Risco-Brasil (EBMI+), do IPEA-DATA, com informações do *JP Morgan* (2023).

Vale observar que, a metodologia do EMBI+ (*Emerging Markets Bond Index Plus*) é desenhada para calcular os retornos financeiros diários de uma carteira selecionada de títulos de dívida de países emergentes, medindo a diferença entre a taxa de retorno desses títulos e a taxa de retorno dos títulos do Tesouro dos Estados Unidos. Essa diferença, conhecida como spread soberano, é expressa em pontos-base, onde dez pontos-base equivalem a um décimo de 1%.

Primeiramente foram realizados testes de causalidade de Granger para as variáveis, verificando se uma variável é estatisticamente preditora da outra. Esta etapa é fundamental para



estabelecer a existência e direção da causalidade de Granger entre o Ibovespa e o Risco-Brasil. Por fim, foram estimadas 243 variações de ordens (n, o, p, q) dos modelos ARMAX-GARCHX (Ver Anexo “A” – Modelos ARMAX-GARCHX do Ibovespa e Risco País), com extensões E-GARCHX e GJR-GARCHX que são particularmente adequados para analisar séries temporais financeiras. Esses modelos permitem modelar não apenas a média condicional dos retornos (por meio do componente ARMAX), mas também a volatilidade condicional dos retornos, um aspecto crucial para entender a dinâmica do risco no mercado financeiro.

### 3.1 MÉTODO ARMAX-GARCHX COM EXTENSÃO (GJR-GARCHX)

O desenvolvimento de modelos que capturam a volatilidade dos retornos de ativos financeiros tem sido um tópico importante na econometria financeira, com contribuições significativas de Engle (1982) e Bollerslev (1986). Engle introduziu o modelo ARCH (*Autoregressive Conditional Heteroskedasticity*) para modelar a variação no tempo da volatilidade dos retornos de ativos, uma abordagem que foi posteriormente expandida por Bollerslev com o modelo GARCH (*Generalized Autoregressive Conditional Heteroskedasticity*). Esses modelos são essenciais para entender a natureza dinâmica da volatilidade e são amplamente utilizados em análises financeiras.

Sendo assim, a abordagem adotada no presente estudo é quantitativa, focando na análise de séries temporais desses dois indicadores financeiros (Ibovespa e Risco-Brasil). As observações são feitas em intervalos de tempo discretos, representados por  $P_t$  nos momentos  $t = 0, 1, \dots, T$ . A análise começa com o cálculo do retorno logarítmico para as variáveis de interesse. Este cálculo é crucial para entender as variações nos valores desses índices entre períodos consecutivos, sendo o retorno logarítmico em um tempo específico  $t$  dado pela Equação (1).

$$R_t = \ln \left( \frac{P_t}{P_{t-1}} \right) \quad (1)$$

Para investigar as variações nos log-retornos do Ibovespa e do Risco-Brasil, foram utilizadas modelagens ARMAX-GARCHX. Neste contexto, o log-retorno  $R_t$  é considerado como a variável dependente e modelado em um processo autorregressivo de ordem “n” e “o”. A Equação (2) descreve essa modelagem:

$$R_t = \mu_0 + \sum_{i=1}^n \phi_i R_{t-i} + \sum_{j=1}^o \theta_j e_{t-j} + \rho X_{t-k} + e_t \quad (2)$$

$$e_t = \sigma_t z_t \quad (3)$$

Aqui,  $R_t$  representa o log-retorno do Ibovespa no tempo  $t$ , enquanto  $\mu_0$  é o termo constante do modelo. Os coeficientes  $\phi_i$  estão associados aos termos autorregressivos  $R_{t-i}$ , que capturam a influência dos log-retornos passados sobre o retorno atual. Já os coeficientes  $\theta_j$  estão relacionados aos termos de média móvel  $e_{t-j}$ , que refletem o impacto dos choques passados no retorno atual. O coeficiente  $\rho$  está ligado às variáveis exógenas  $X_{t-k}$ , que representam fatores externos que podem influenciar os retornos.

O termo de erro (Equação 3) é modelado como um processo GARCH, captando as variações inesperadas ou “choques” nos retornos dos ativos não explicados pelo componente autorregressivo com ordens “p” e “q”. Sendo a equação da volatilidade condicional  $\sigma_t^2$  descrita pela Equação (4).

$$\sigma_t^2 = \omega_0 + \sum_{i=1}^p \alpha_i e_{t-i}^2 + \sum_{j=1}^q \beta_j \sigma_{t-j}^2 + \rho X_{t-k} \quad (4)$$

Aqui,  $\sigma_t^2$  representa a volatilidade condicional, ou seja, a variância condicional dos retornos. No modelo GARCH (*Generalized Autoregressive Conditional Heteroskedasticity*), a variância condicional  $\sigma_t^2$  é influenciada por choques passados ( $e_{t-i}^2$ ) e pela variância condicional passada ( $\sigma_{t-j}^2$ ).

O termo  $\omega_0$  é uma constante,  $\alpha_i$  são os coeficientes que capturam o impacto dos choques passados e  $\beta_j$  são os coeficientes que refletem a persistência da volatilidade ao longo do tempo. O termo  $\rho X_{t-k}$  inclui o impacto das variáveis exógenas na variância condicional. Para uma modelagem ainda mais precisa, consideramos a extensão E-GARCHX (*Exponential GARCH*), que captura assimetrias na volatilidade. A Equação (5) descreve esta abordagem:

$$\ln(\sigma_t^2) = \omega_0 + \sum_{i=1}^p \alpha_i \left| \frac{e_{t-i}}{\sigma_{t-i}} \right| + \sum_{i=1}^p \gamma_i \frac{e_{t-i}}{\sigma_{t-i}} + \sum_{j=1}^q \beta_j \ln(\sigma_{t-j}^2) + \rho X_{t-k} \quad (5)$$

No modelo E-GARCH (*Exponential GARCH*), o logaritmo da variância condicional é modelado, o que permite capturar de maneira mais eficaz os efeitos assimétricos na volatilidade. Aqui, os coeficientes  $\alpha_i$  medem o impacto dos choques passados em termos absolutos, enquanto os coeficientes  $\gamma_i$  capturam a direção dos choques (positivos ou negativos). Os coeficientes  $\beta_j$  refletem a persistência da volatilidade condicional.

Além disso, para uma análise mais abrangente, consideramos também a extensão GJR-GARCH, que captura características específicas como efeitos assimétricos e persistência de longo prazo na volatilidade dos log-retornos do Ibovespa e do Risco-Brasil. A Equação (6) descreve esta abordagem:

$$\sigma_t^2 = \omega_0 + \sum_{i=1}^p \alpha_i e_{t-i}^2 + \sum_{j=1}^q \beta_j \sigma_{t-j}^2 + \sum_{i=1}^q \gamma_i e_{t-i}^2 d_{t-1} + \rho X_{t-k} \quad (6)$$

No modelo GJR-GARCH (*Glosten-Jagannathan-Runkle GARCH*), a variância condicional incorpora um termo adicional  $d_{t-1}$ , que é uma variável indicadora que assume valor 1 se  $e_{t-i}^2$  for negativo, e 0 caso contrário. Este termo captura a assimetria nos choques, onde choques negativos têm um impacto diferente (geralmente maior) na variância condicional do que choques positivos. Os coeficientes  $\alpha_i$  e  $\beta_j$  têm interpretações similares ao modelo GARCH, enquanto os coeficientes  $\gamma_i$  medem o efeito adicional dos choques negativos.

Essa metodologia visa oferecer uma visão detalhada sobre a dinâmica do Ibovespa e do Risco-Brasil, destacando a importância de técnicas avançadas na análise de séries temporais no contexto do mercado financeiro brasileiro. O uso combinado de modelos ARMAX com GARCH, E-GARCHX e GJR-GARCH permite uma captura robusta das características complexas das séries temporais financeiras, contribuindo para uma compreensão aprofundada dos fatores que influenciam a volatilidade e os retornos do mercado.

### 3.2 ANÁLISE DESCRITIVA

Nesta seção, é apresentado um sumário estatístico dos retornos logarítmicos (log-retorno) para o Ibovespa e o Risco-Brasil. A Tabela 1 fornece uma visão detalhada das características estatísticas desses dois conjuntos de dados.

A análise revela que ambos os conjuntos de dados, Ibovespa e Risco-Brasil, apresentam um padrão de variação considerável. O Ibovespa possui uma média de 0,0004 e um desvio padrão de 0,0162, indicando uma variabilidade moderada. Por outro lado, o Risco-Brasil tem uma média ligeiramente negativa (-0,0001) e um desvio padrão maior (0,0243), o que sugere uma maior incerteza associada a esse indicador.

Os resultados dos testes ADF para ambos os conjuntos de dados mostram valores de -11,9062 para o Ibovespa e -12,2597 para o Risco-Brasil, com um p-valor de 0,0001 em ambos os casos. Esses resultados sugerem a rejeição da hipótese nula de não estacionaridade, indicando que ambas as séries são estacionárias.

**Tabela 1** – Sumário de dados do Ibovespa e Risco-Brasil em log-retorno.


Sumário	Ibovespa (log-retorno)	Risco-Brasil (log-retorno)
Observações	2.070	2.070
Média	0,0004	-0,0001
Desvio Padrão	0,0162	0,0243
Mínimo	-0,1599	-0,1433
25%	-0,0078	-0,0125
50%	0,0007	0,0001
75%	0,0092	0,0113
Máximo	0,1302	0,1949
Teste ADF	-11,9062	-12,2597
P-Valor (Teste ADF)	0,0001	0,0001

Nota: Teste ADF entende-se como o teste “*Augmented Dickey-Fuller*” que, de acordo com Dickey e Fuller (1979), representa o teste de raiz unitária com hipótese nula de que as séries não são estacionárias.

Fonte: Autoria própria.

O Quadro 1, por sua vez, exibe a série temporal dos log-retorno para o Ibovespa e o Risco-Brasil, respectivamente, cobrindo o período de janeiro de 2015 a junho de 2023. Através dele é possível visualizar a flutuação dos retornos ao longo do tempo e identificar padrões ou eventos significativos que possam ter influenciado o mercado financeiro brasileiro.

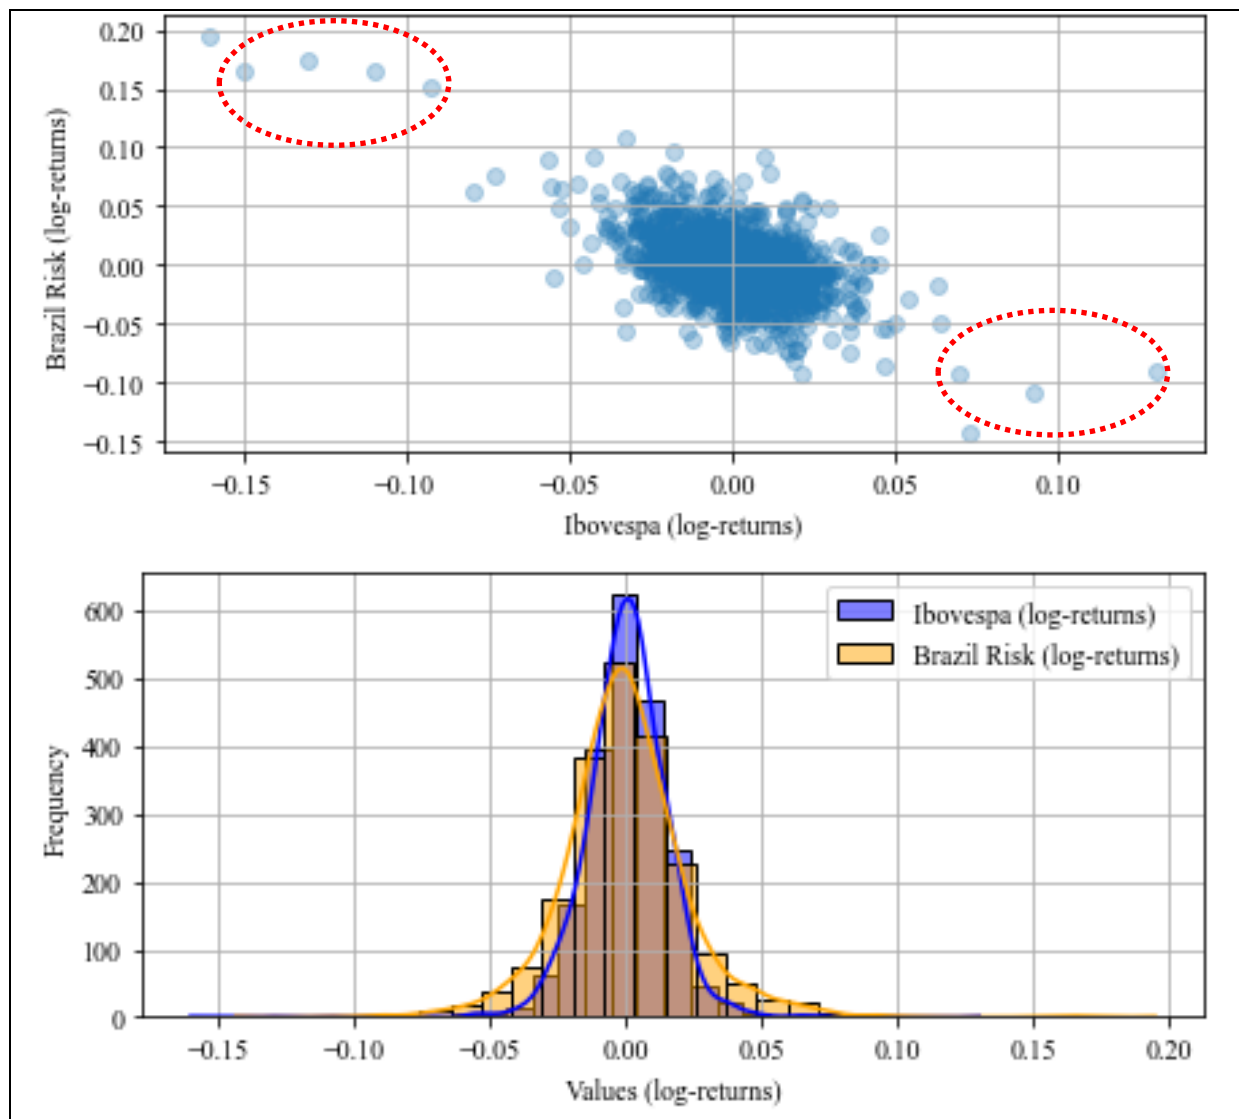
**Quadro 1** – Gráficos do Ibovespa e Risco-Brasil em log-retorno.



Fonte: Autoria própria utilizando Python versão 3.10.9.

Comparando ambos os gráficos presentes no quadro, é possível notar que as séries de log-retorno de ambos os indicadores compartilham algumas características, como a presença de *outliers* e uma tendência central próxima a zero. Entretanto, o Risco-Brasil parece ter uma faixa de variação mais ampla, indicando uma maior volatilidade em comparação com o Ibovespa.

**Quadro 2** – Gráfico de dispersão e distribuição do Ibovespa e Risco-Brasil em log-retorno.



Fonte: Autoria própria utilizando Python versão 3.10.9.

O Quadro 2 fornece uma representação visual da relação entre os log-retorno do Ibovespa e do Risco-Brasil. Destaca-se aqui a presença de *outliers* nas extremidades com relações inversas, o que informa a existência de episódios específicos onde os movimentos do Ibovespa e do Risco-Brasil não seguem a tendência geral (valores próximos a zero) além de que, quando há um forte aumento nos retornos do risco-país há uma queda quase proporcional nos retornos do Ibovespa e vice-versa, refletindo a aversão ao risco dos investidos no mercado financeiro brasileiro.

Em relação ao gráfico de distribuição vale observar que eventos de calda (extremos) são mais frequentes no Risco-Brasil que no Ibovespa (calda mais “pesada” para o risco soberano além da maior concentração de valores próximo a zero do índice de mercado brasileiro).

Continuando, para averiguar melhor essa relação a próxima seção se dedica a apresentação dos resultados dos testes de causalidade de Granger e modelos GARCHs com menores valores AIC estimados.

## 4 RESULTADOS E DISCUSSÕES

No contexto da análise financeira, é importante entender as interrelações dinâmicas entre diferentes indicadores econômicos e financeiros antes de se iniciar uma análise econométrica e estatística mais aprofundada. Sendo assim, primeiramente, foi realizada a análise de causalidade de Granger para verificar se uma variável pode ser utilizada para prever outra, considerando diferentes defasagens temporais.

Os resultados apresentados na Tabela 2 detalham dos P-valores das análises de causalidade de Granger. A análise demonstra que, para todas as defasagens consideradas, os P-valores são maiores que 0,05 quando o Ibovespa é a variável causadora do Risco Brasil. Isso indica que, sob essas condições, não podemos rejeitar a hipótese nula de que o Ibovespa não Granger-causa o Risco Brasil, sugerindo que o Ibovespa não é um preditor significativo para o Risco Brasil.

**Tabela 2** – Resultados dos testes de Causalidade de Granger para o Ibovespa com o Risco Brasil (log-retorno).

Variável Causa (Granger)	Variável Efeito (Granger)	Defasagens	P-Valor
Ibovespa	Risco Brasil	1	0,19785
Ibovespa	Risco Brasil	2	0,58814
Ibovespa	Risco Brasil	3	0,07577
Ibovespa	Risco Brasil	4	0,13047
Ibovespa	Risco Brasil	5	0,10505
Ibovespa	Risco Brasil	6	0,14268
Ibovespa	Risco Brasil	7	0,0904
Ibovespa	Risco Brasil	8	0,12819
Ibovespa	Risco Brasil	9	0,10451
Ibovespa	Risco Brasil	10	0,20927
Risco Brasil	Ibovespa	1	0,00124
Risco Brasil	Ibovespa	2	0,00034
Risco Brasil	Ibovespa	3	0,00001
Risco Brasil	Ibovespa	4	0,00004
Risco Brasil	Ibovespa	5	0,00001
Risco Brasil	Ibovespa	6	0,00001
Risco Brasil	Ibovespa	7	0,00001
Risco Brasil	Ibovespa	8	0,00001
Risco Brasil	Ibovespa	9	0,00001
Risco Brasil	Ibovespa	10	0,00001

Fonte: Autoria própria utilizando ‘R’.

Por outro lado, quando o Risco Brasil é a variável causadora do Ibovespa, os valores de P são extremamente baixos (próximos de zero) para todas as defasagens analisadas. Isso permite rejeitar a hipótese nula de que o Risco Brasil não Granger-causa o Ibovespa, indicando uma forte evidência de que o Risco Brasil é um preditor significativo do comportamento do

índice. Esses achados sugerem que alterações no Risco Brasil têm um impacto direto e significativo sobre o desempenho do mercado de ações brasileiro.

Na sequência, como dito anteriormente, foram estimados 243 variações de ordens (n, o, p, q) dos modelos ARMAX-S-GARCHX, ARMAX-E-GARCHX e ARMAX-GJR-GARCHX (Ver Anexo “A” – Modelos ARMAX-GARCHX do Ibovespa e Risco País). A Tabela 3 apresenta os resultados dos modelos com os menores critérios AIC de cada extensão, mostrando a influência da variável exógena sobre a dinâmica do Ibovespa.

Destaca-se que, os indicadores de ajuste, como o Logaritmo da verossimilhança (Log-Lik.), o Critério de Informação de Akaike (AIC) e o Critério de Informação Bayesiano (BIC), apontaram para um ajuste muito próximo entre os três modelos. Testes adicionais, como o teste de heterocedasticidade de LM e o teste de autocorrelação de Ljung-Box, não indicaram a presença de heterocedasticidade condicional ou autocorrelação nos resíduos, o que valida a adequação dos modelos escolhidos.

**Tabela 3** – Resultados dos modelos ARMAX-S-GARCHX, ARMAX-E-GARCHX e ARMAX-GJR-GARCHX para a equação do Ibovespa com o Risco Brasil de variável exógena (log-retorno).

Modelo	S-GARCH	E-GARCH	GJR-GARCH
<b>Ordem ARMA</b>	(2,3)	(3,2)	(2,3)
<b>Ordem GARCH</b>	(3,1)	(2,3)	(1,2)

Equação da Média Condicional:			
<b>Mu</b>	0,00076*** (0,00001)	0,00057*** (0,00001)	0,00048*** (0,00001)
<b>AR (1)</b>	-0,94915*** (0,00006)	1,44570*** (0,00008)	-0,92509*** (0,00006)
<b>AR (2)</b>	-0,99648*** (0,00006)	-0,77071*** (0,00005)	-0,99246*** (0,00007)
<b>AR (3)</b>	- (0,00001)	-0,13979*** (0,00001)	- (0,00001)
<b>MA (1)</b>	0,82828*** (0,00006)	-1,60008*** (0,00008)	0,81139*** (0,00006)
<b>MA (2)</b>	0,88100*** (0,00004)	1,00717*** (0,00001)	0,89468*** (0,00005)
<b>MA (3)</b>	-0,13366*** (0,00002)	- (0,00002)	-0,12236*** (0,00002)
<b>MXREG (1)</b>	-0,28163*** (0,00026)	-0,28511*** (0,00031)	-0,28764*** (0,00012)

Equação da Volatilidade Condicional:			
<b>Omega</b>	0,00001*** (0,00001)	-0,45329*** (0,08173)	0,00001*** (0,00001)
<b>Alpha (1)</b>	0,00801 (0,01849)	-0,04656* (0,02494)	0,02701** (0,01148)
<b>Alpha (2)</b>	0,05284* (0,02817)	-0,00250 (0,02434)	- (0,02434)

<b>Alpha (3)</b>	0,00006 (0,02582)	- -	- -
<b>Beta (1)</b>	0,90430*** (0,01238)	0,21570*** (0,07944)	0,92081*** (0,01600)
<b>Beta (2)</b>	- -	0,75501*** (0,02220)	0,00001 (0,01865)
<b>Beta (3)</b>	- -	-0,02222 (0,04127)	- -
<b>VXREG (1)</b>	0,00035*** (0,00006)	4,22793*** (0,78315)	0,00024*** (0,00007)
<b>Gamma (1)</b>	- -	0,08045*** (0,02869)	0,04116** (0,01691)
<b>Gamma (2)</b>	- -	0,07570*** (0,02596)	- -
<b>Log-Lik.</b>	6.149,685	6.158,031	6.150,471
<b>AIC</b>	-5,93393	-5,93910	-5,93469
<b>BIC</b>	-5,89579	-5,89279	-5,89655
<b>LM (Het.)</b>	0,6916	0,4757	0,9267
<b>Ljung-Box</b>	0,44544	0,23426	0,67696

Nota: i) Os asteriscos denotam o nível de significância estatística dos coeficientes: \*\*\* p<0.01 (significância a 1%); \*\* p<0.05 (significância a 5%); \* p<0.1 (significância a 10%).

ii) Os números entre parênteses são os erros padrões associados a cada estimador de coeficiente.

iii) Log-Lik. (Logaritmo da verossimilhança) - Indica o quão bem o modelo se ajusta aos dados.

iv) AIC (Critério de Informação de Akaike) e BIC (Critério de Informação Bayesiano) - Critérios para seleção de modelo; menores valores indicam um ajuste superior.

v) LM (Lagrange Multiplier) em p-valor com  $H_0$ : Hipótese de homocedasticidade.

vi) Ljung-Box em p-valor com  $H_0$ : Dados não autocorrelacionados.

Fonte: Autoria própria utilizando 'R'.

Observa-se também aspectos fundamentais da relação entre o Ibovespa e a exposição a riscos e volatilidade, com especial atenção ao papel desempenhado pelo Risco Brasil como variável exógena. Primeiramente, a presença de uma constante positiva ( $\mu$ ) nos modelos sugere um cenário onde, mesmo na ausência de eventos de mercado imediatos ou volatilidade condicional explícita, espera-se que o Ibovespa apresente um retorno médio positivo. Nos três modelos analisados, o parâmetro ( $\mu$ ) é positivo e significativo, com valores de 0,00076\*\*\* no S-GARCH, 0,00057\*\*\* no E-GARCH e 0,00048\*\*\* no GJR-GARCH, o que é coerente com a tendência de longo prazo do mercado acionário de refletir o crescimento econômico subjacente, apesar das flutuações de curto prazo.

Mais significativamente, a variável MXREG (1), que quantifica o impacto do Risco Brasil sobre os retornos do Ibovespa, mostra-se negativamente significativa em todos os modelos examinados. Os coeficientes são -0,28163\*\*\* no S-GARCH, -0,28511\*\*\* no E-GARCH e -0,28764\*\*\* no GJR-GARCH, denotando uma relação inversa entre o Risco Brasil e os retornos do Ibovespa. Isso implica que melhorias na percepção de risco do Brasil (i.e., uma redução no Risco Brasil) estão correlacionadas com um aumento nos retornos do Ibovespa. Especificamente, uma redução de 1% no Risco Brasil está associada a um aumento subsequente de aproximadamente 0,28% nos retornos do Ibovespa, mantendo tudo o mais constante (*ceteris paribus*). Essa relação sublinha a sensibilidade do mercado acionário brasileiro às mudanças na confiança dos investidores e nas condições macroeconômicas, afetando diretamente as



expectativas de investimento, os fluxos de capital estrangeiro e a percepção de estabilidade econômica e política.

Por sua vez, o coeficiente VXREG (1), significativamente positivo em todos os modelos, indica uma correlação direta entre a volatilidade do Ibovespa e o Risco Brasil. Nos modelos S-GARCH, E-GARCH e GJR-GARCH, os coeficientes VXREG (1) são 0,00035\*\*\*, 4,22793\*\*\* e 0,00024\*\*\*, respectivamente, sugerindo que um aumento no Risco Brasil está associado a um aumento na volatilidade dos retornos do Ibovespa. Esse efeito pode ser interpretado como uma manifestação da aversão ao risco dos investidores: à medida que a percepção de risco econômico e político no Brasil se eleva, a incerteza no mercado acionário aumenta, refletida em maior volatilidade dos preços das ações.

Ao detalhar a volatilidade condicional, os parâmetros Omega, Alpha (1), Beta (1), e, especificamente nos modelos E-GARCH e GJR-GARCH, o Gamma, desvelam a natureza persistente e complexa da volatilidade nos retornos do Ibovespa. O parâmetro Omega, que representa o nível constante da volatilidade, é positivo e significativo no S-GARCH e no GJR-GARCH (0,00001\*\*\* em ambos), enquanto o E-GARCH apresenta um valor negativo de -0,45329\*\*\*, sugerindo diferentes dinâmicas da volatilidade entre os modelos. A significância dos coeficientes Alpha (1) e Beta (1) em todos os modelos reforça a ideia de que choques anteriores, tanto nos retornos quanto na volatilidade, exercem uma influência prolongada sobre a volatilidade futura. No S-GARCH, Alpha (1) é 0,00801, enquanto Beta (1) é 0,90430\*\*\*, destacando a persistência da volatilidade.

O modelo E-GARCH evidencia um efeito de alavancagem, indicado pelo coeficiente Gamma positivo (0,08045\*\*\*), sugerindo que choques negativos nos retornos têm um impacto desproporcional na amplificação da volatilidade futura comparado a choques positivos de magnitude equivalente. Este fenômeno, conhecido como efeito de alavancagem, pode ser atribuído à reação assimétrica dos investidores a notícias negativas, refletindo aversão ao risco e ajustes de portfólio em resposta a incertezas.

Em suma, essa análise detalhada não apenas sublinha a complexa interação entre o Ibovespa e o Risco Brasil, mas também enfatiza a importância de considerar o contexto econômico mais amplo. Mudanças no Risco Brasil afetam diretamente os retornos e a volatilidade do Ibovespa, refletindo a confiança dos investidores e as condições macroeconômicas. Políticas econômicas, estabilidade política e outros fatores externos desempenham um papel crucial na compreensão dos mecanismos que dirigem os retornos e a volatilidade no mercado acionário brasileiro.

## **5 CONSIDERAÇÕES FINAIS**

A teoria da aversão ao risco, meticulosamente proposta por Pratt (1964) em sua análise da reação dos investidores diante de incertezas, oferece um alicerce para a compreensão da interação entre risco e retorno, um dos pilares fundamentais das finanças. Esta teoria avança a ideia de que os indivíduos, de forma inerente, preferem evitar o risco, demandando prêmios de risco mais elevados para compensar a tomada de investimentos percebidos como arriscados. Essa preferência é evidenciada na forma como investidores e gestores de portfólio moldam suas estratégias, enfatizando tanto a mitigação de riscos quanto a busca por retornos adequados.

Ao aplicar modelos ARMAX-S-GARCH, ARMAX-E-GARCH e ARMAX-GJR-GARCH na análise dos retornos do Ibovespa, considerando o Risco-Brasil como uma variável exógena, a importância da aversão ao risco no mercado acionário brasileiro se torna evidente. Notadamente, um aumento no Risco-Brasil correlaciona-se significativamente com a redução dos retornos esperados (ou a média dos retornos – via MXREG) do Ibovespa. Esse efeito sublinha como o risco percebido influencia diretamente as expectativas de retorno dos

investidores, reforçando que a aversão ao risco desempenha um papel crucial na avaliação de investimentos.

Ademais, o aumento no Risco-Brasil associa-se também a um incremento na volatilidade dos retornos do Ibovespa, como indicam os coeficientes positivamente significativos para VXREG. Essa relação sugere que períodos de maior incerteza, simbolizados pelo aumento do Risco-Brasil, resultam em uma volatilidade ampliada no mercado. Esse padrão destaca como a aversão ao risco dos investidores se manifesta perante incertezas elevadas, afetando diretamente a volatilidade do mercado.

Portanto, a interconexão entre o aumento do Risco-Brasil e a redução dos retornos esperados do Ibovespa, bem como a associação desse aumento com a elevada volatilidade dos retornos, ilustra claramente a influência do risco percebido sobre o comportamento do mercado de ações brasileiro. Este cenário ressalta um ambiente de investimento marcado pela prudência e adaptação a um nível elevado de incerteza, demonstrando vividamente a importância da aversão ao risco nas decisões de investimento.

Essas considerações sublinham a necessidade de gestão de riscos nas decisões de investimento, especialmente em mercados emergentes como o Brasil, onde variáveis políticas e econômicas podem impactar significativamente tanto os retornos quanto a volatilidade. A análise destaca o Risco-Brasil como um fator primordial para investidores e gestores de portfólio ao avaliarem oportunidades no mercado acionário brasileiro, enfatizando a complexa interação entre risco e retorno.

## REFERÊNCIAS

AKAIKE, H. A new look at the statistical model identification. **IEEE Transactions on Automatic Control**, 1974.

BOLLERSLEV, T. Generalized autoregressive conditional heteroskedasticity. **Journal of Econometrics**, 1986.

DICKEY, D. A.; FULLER, W. A. Distribution of the Estimators for Autoregressive Time Series With a Unit Root. **Journal of the American Statistical Association**, 1979.

ENGLE, R. F. Autoregressive Conditional Heteroscedasticity with Estimates of the Variance of United Kingdom Inflation. **Econometrica**, 1982.

HAMMOUDEH, S.; SARI, R.; UZUNKAYA, M.; LIU, T. The dynamics of BRICS's country risk ratings and domestic stock markets, U.S. stock market and oil price. **Mathematics and Computers in Simulation**, 94, 277-294, 2013.

JP MORGAN. EMBI+ Risco-Brasil. **IPEADATA**. Disponível em: <http://www.ipeadata.gov.br/ExibeSerie.aspx?serid=40940&module=M>. Acesso em: 10 jun. 2023.

KAMINSKY, G.; SCHMUKLER, S. L. Emerging Market Instability: Do Sovereign Ratings Affect Country Risk and Stock Returns? **The World Bank Economic Review**, 16(2), 171–195, 2002.

MONTES, G. C.; TIBERTO, B. P. Macroeconomic environment, country risk and stock market performance: Evidence for Brazil. **Economic Modelling**, 29(5), 1666-1678, 2012.

PRATT, J. W. Risk aversion in the small and in the large. **Econometrica**, 32(1-2), 122-136, 1964.

PONTES, L. S.; RÊGO, L. C. Impact of macroeconomic variables on the topological structure of the Brazilian stock market: A complex network approach. **Physica A: Statistical Mechanics and its Applications**, 2022.

WHITELAW, R. F. Stock Market Risk and Return: An Equilibrium Approach. **The Review of Financial Studies**, 13(3), 521–547, 2000.

YAHOO INC. **Yahoo Finance API**. Disponível em: <https://finance.yahoo.com/quote/API/>. Acesso em: 10 jun. 2023.

## ANEXO A – MODELOS ARMAX-GARCHX DO IBOVESPA E RISCO PAÍS

Modelo	p	q	n	o	AIC	Modelo	p	q	n	o	AIC	Modelo	p	q	n	o	AIC
S-GARCH	1	1	1	1	-5.92126	E-GARCH	1	1	1	1	-5.92706	GJR-GARCH	1	1	1	1	-5.92303
S-GARCH	1	1	1	2	-5.92052	E-GARCH	1	1	1	2	-5.92635	GJR-GARCH	1	1	1	2	-5.92229
S-GARCH	1	1	1	3	-5.91963	E-GARCH	1	1	1	3	-5.92545	GJR-GARCH	1	1	1	3	-5.9214
S-GARCH	1	1	2	1	-5.92048	E-GARCH	1	1	2	1	-5.92605	GJR-GARCH	1	1	2	1	-5.92222
S-GARCH	1	1	2	2	-5.91999	E-GARCH	1	1	2	2	-5.92582	GJR-GARCH	1	1	2	2	-5.92174
S-GARCH	1	1	2	3	-5.91911	E-GARCH	1	1	2	3	-5.92497	GJR-GARCH	1	1	2	3	-5.93224
S-GARCH	1	1	3	1	-5.91959	E-GARCH	1	1	3	1	-5.9254	GJR-GARCH	1	1	3	1	-5.92136
S-GARCH	1	1	3	2	-5.9187	E-GARCH	1	1	3	2	-5.92447	GJR-GARCH	1	1	3	2	-5.92051
S-GARCH	1	1	3	3	-5.92209	E-GARCH	1	1	3	3	-5.92784	GJR-GARCH	1	1	3	3	-5.92393
S-GARCH	1	2	1	1	-5.92032	E-GARCH	1	2	1	1	-5.92624	GJR-GARCH	1	2	1	1	-5.92206
S-GARCH	1	2	1	2	-5.91938	E-GARCH	1	2	1	2	-5.92554	GJR-GARCH	1	2	1	2	-5.92133
S-GARCH	1	2	1	3	-5.91866	E-GARCH	1	2	1	3	-5.92464	GJR-GARCH	1	2	1	3	-5.92043
S-GARCH	1	2	2	1	-5.91951	E-GARCH	1	2	2	1	-5.92522	GJR-GARCH	1	2	2	1	-5.92125
S-GARCH	1	2	2	2	-5.91903	E-GARCH	1	2	2	2	-5.92505	GJR-GARCH	1	2	2	2	-5.92077
S-GARCH	1	2	2	3	-5.91967	E-GARCH	1	2	2	3	-5.93798	GJR-GARCH	1	2	2	3	-5.93469
S-GARCH	1	2	3	1	-5.91862	E-GARCH	1	2	3	1	-5.92458	GJR-GARCH	1	2	3	1	-5.92039
S-GARCH	1	2	3	2	-5.91773	E-GARCH	1	2	3	2	-5.92369	GJR-GARCH	1	2	3	2	-5.91954
S-GARCH	1	2	3	3	-5.92112	E-GARCH	1	2	3	3	-5.9269	GJR-GARCH	1	2	3	3	-5.92296
S-GARCH	1	3	1	1	-5.91934	E-GARCH	1	3	1	1	-5.92558	GJR-GARCH	1	3	1	1	-5.92111
S-GARCH	1	3	1	2	-5.91862	E-GARCH	1	3	1	2	-5.92487	GJR-GARCH	1	3	1	2	-5.92019
S-GARCH	1	3	1	3	-5.91769	E-GARCH	1	3	1	3	-5.92397	GJR-GARCH	1	3	1	3	-5.91946
S-GARCH	1	3	2	1	-5.91857	E-GARCH	1	3	2	1	-5.92457	GJR-GARCH	1	3	2	1	-5.9203
S-GARCH	1	3	2	2	-5.91811	E-GARCH	1	3	2	2	-5.92436	GJR-GARCH	1	3	2	2	-5.91982
S-GARCH	1	3	2	3	-5.92044	E-GARCH	1	3	2	3	-5.92353	GJR-GARCH	1	3	2	3	-5.93242
S-GARCH	1	3	3	1	-5.91768	E-GARCH	1	3	3	1	-5.92392	GJR-GARCH	1	3	3	1	-5.91943
S-GARCH	1	3	3	2	-5.91678	E-GARCH	1	3	3	2	-5.93712	GJR-GARCH	1	3	3	2	-5.91857
S-GARCH	1	3	3	3	-5.92018	E-GARCH	1	3	3	3	-5.92622	GJR-GARCH	1	3	3	3	-5.92235
S-GARCH	2	1	1	1	-5.92188	E-GARCH	2	1	1	1	-5.92706	GJR-GARCH	2	1	1	1	-5.91901
S-GARCH	2	1	1	2	-5.91441	E-GARCH	2	1	1	2	-5.9264	GJR-GARCH	2	1	1	2	-5.91836
S-GARCH	2	1	1	3	-5.9202	E-GARCH	2	1	1	3	-5.92552	GJR-GARCH	2	1	1	3	-5.92152
S-GARCH	2	1	2	1	-5.91457	E-GARCH	2	1	2	1	-5.92601	GJR-GARCH	2	1	2	1	-5.91834
S-GARCH	2	1	2	2	-5.9205	E-GARCH	2	1	2	2	-5.92574	GJR-GARCH	2	1	2	2	-5.92172
S-GARCH	2	1	2	3	-5.92289	E-GARCH	2	1	2	3	-5.92498	GJR-GARCH	2	1	2	3	-5.92092
S-GARCH	2	1	3	1	-5.92017	E-GARCH	2	1	3	1	-5.92547	GJR-GARCH	2	1	3	1	-5.92148
S-GARCH	2	1	3	2	-5.91932	E-GARCH	2	1	3	2	-5.92452	GJR-GARCH	2	1	3	2	-5.92067
S-GARCH	2	1	3	3	-5.92273	E-GARCH	2	1	3	3	-5.92817	GJR-GARCH	2	1	3	3	-5.92424
S-GARCH	2	2	1	1	-5.91421	E-GARCH	2	2	1	1	-5.9283	GJR-GARCH	2	2	1	1	-5.91807
S-GARCH	2	2	1	2	-5.91352	E-GARCH	2	2	1	2	-5.9276	GJR-GARCH	2	2	1	2	-5.91743
S-GARCH	2	2	1	3	-	E-GARCH	2	2	1	3	-5.92664	GJR-GARCH	2	2	1	3	-5.91654
S-GARCH	2	2	2	1	-5.91361	E-GARCH	2	2	2	1	-5.92751	GJR-GARCH	2	2	2	1	-5.9174
S-GARCH	2	2	2	2	-5.91279	E-GARCH	2	2	2	2	-5.92704	GJR-GARCH	2	2	2	2	-5.91664
S-GARCH	2	2	2	3	-5.91533	E-GARCH	2	2	2	3	-5.92622	GJR-GARCH	2	2	2	3	-5.91938
S-GARCH	2	2	3	1	-5.91253	E-GARCH	2	2	3	1	-5.92659	GJR-GARCH	2	2	3	1	-5.9165
S-GARCH	2	2	3	2	-5.91928	E-GARCH	2	2	3	2	-5.92569	GJR-GARCH	2	2	3	2	-5.91579

S-GARCH	2	2	3	3	-5.92261	E-GARCH	2	2	3	3	-5.92896	GJR-GARCH	2	2	3	3	-5.91934
S-GARCH	2	3	1	1	-5.921	E-GARCH	2	3	1	1	-5.92736	GJR-GARCH	2	3	1	1	-5.92403
S-GARCH	2	3	1	2	-5.9201	E-GARCH	2	3	1	2	-5.92665	GJR-GARCH	2	3	1	2	-5.92343
S-GARCH	2	3	1	3	-5.91937	E-GARCH	2	3	1	3	-5.92572	GJR-GARCH	2	3	1	3	-5.92256
S-GARCH	2	3	2	1	-5.92017	E-GARCH	2	3	2	1	-5.92655	GJR-GARCH	2	3	2	1	-5.92292
S-GARCH	2	3	2	2	-5.91974	E-GARCH	2	3	2	2	-5.92611	GJR-GARCH	2	3	2	2	-5.92266
S-GARCH	2	3	2	3	-5.91888	E-GARCH	2	3	2	3	-5.92529	GJR-GARCH	2	3	2	3	-5.92197
S-GARCH	2	3	3	1	-5.91914	E-GARCH	2	3	3	1	-5.92567	GJR-GARCH	2	3	3	1	-5.92251
S-GARCH	2	3	3	2	-5.91946	E-GARCH	2	3	3	2	-5.9391	GJR-GARCH	2	3	3	2	-5.92155
S-GARCH	2	3	3	3	-5.92069	E-GARCH	2	3	3	3	-5.92808	GJR-GARCH	2	3	3	3	-5.92378
S-GARCH	3	1	1	1	-5.92088	E-GARCH	3	1	1	1	-5.92538	GJR-GARCH	3	1	1	1	-5.92169
S-GARCH	3	1	1	2	-5.91997	E-GARCH	3	1	1	2	-5.92473	GJR-GARCH	3	1	1	2	-5.92101
S-GARCH	3	1	1	3	-5.91923	E-GARCH	3	1	1	3	-5.92384	GJR-GARCH	3	1	1	3	-5.92009
S-GARCH	3	1	2	1	-5.92009	E-GARCH	3	1	2	1	-5.92434	GJR-GARCH	3	1	2	1	-5.92084
S-GARCH	3	1	2	2	-5.91951	E-GARCH	3	1	2	2	-5.92404	GJR-GARCH	3	1	2	2	-5.92019
S-GARCH	3	1	2	3	-5.93393	E-GARCH	3	1	2	3	-5.92326	GJR-GARCH	3	1	2	3	-5.91862
S-GARCH	3	1	3	1	-5.9192	E-GARCH	3	1	3	1	-5.92379	GJR-GARCH	3	1	3	1	-5.92004
S-GARCH	3	1	3	2	-5.91836	E-GARCH	3	1	3	2	-5.92285	GJR-GARCH	3	1	3	2	-5.91926
S-GARCH	3	1	3	3	-5.92176	E-GARCH	3	1	3	3	-5.92632	GJR-GARCH	3	1	3	3	-5.9228
S-GARCH	3	2	1	1	-5.92128	E-GARCH	3	2	1	1	-5.92751	GJR-GARCH	3	2	1	1	-5.92178
S-GARCH	3	2	1	2	-5.91244	E-GARCH	3	2	1	2	-5.92683	GJR-GARCH	3	2	1	2	-5.92104
S-GARCH	3	2	1	3	-	E-GARCH	3	2	1	3	-5.92592	GJR-GARCH	3	2	1	3	-5.91912
S-GARCH	3	2	2	1	-5.9205	E-GARCH	3	2	2	1	-5.92674	GJR-GARCH	3	2	2	1	-5.91987
S-GARCH	3	2	2	2	-5.91991	E-GARCH	3	2	2	2	-5.92622	GJR-GARCH	3	2	2	2	-5.91922
S-GARCH	3	2	2	3	-5.91904	E-GARCH	3	2	2	3	-5.92542	GJR-GARCH	3	2	2	3	-5.92297
S-GARCH	3	2	3	1	-5.91958	E-GARCH	3	2	3	1	-5.92587	GJR-GARCH	3	2	3	1	-5.91908
S-GARCH	3	2	3	2	-5.91877	E-GARCH	3	2	3	2	-5.92516	GJR-GARCH	3	2	3	2	-5.9183
S-GARCH	3	2	3	3	-	E-GARCH	3	2	3	3	-5.92838	GJR-GARCH	3	2	3	3	-5.92184
S-GARCH	3	3	1	1	-5.92263	E-GARCH	3	3	1	1	-5.92664	GJR-GARCH	3	3	1	1	-5.92562
S-GARCH	3	3	1	2	-5.92194	E-GARCH	3	3	1	2	-5.92598	GJR-GARCH	3	3	1	2	-5.92454
S-GARCH	3	3	1	3	-5.92104	E-GARCH	3	3	1	3	-5.92507	GJR-GARCH	3	3	1	3	-5.92401
S-GARCH	3	3	2	1	-5.92178	E-GARCH	3	3	2	1	-5.92588	GJR-GARCH	3	3	2	1	-5.92485
S-GARCH	3	3	2	2	-5.92144	E-GARCH	3	3	2	2	-5.92534	GJR-GARCH	3	3	2	2	-5.92425
S-GARCH	3	3	2	3	-5.92499	E-GARCH	3	3	2	3	-5.92456	GJR-GARCH	3	3	2	3	-5.92344
S-GARCH	3	3	3	1	-5.921	E-GARCH	3	3	3	1	-5.92501	GJR-GARCH	3	3	3	1	-5.92399
S-GARCH	3	3	3	2	-5.92128	E-GARCH	3	3	3	2	-5.92408	GJR-GARCH	3	3	3	2	-5.92311
S-GARCH	3	3	3	3	-5.91927	E-GARCH	3	3	3	3	-5.92753	GJR-GARCH	3	3	3	3	-5.92662

Nota: i) Sinais (-) representam valores nulos onde não foi possível estimar a equação por falta de convergência;  
ii) Variações de ordens (n, o, p, q) com os menores valores do Critério Akaike (AIC) estão assinalados em linha tracejada.

Fonte: Autoria própria.



ISBN nº 978-65-01-11585-6

# **AValiação DAS EXPECTATIVAS INFLACIONÁRIAS NO BRASIL**

JOÃO PEDRO CATAPAN MONTANHER<sup>1</sup>  
ELAINE CRISTINA DE PIZA<sup>2</sup>

## **ÁREA 3**

### **RESUMO**

O objetivo deste trabalho é analisar o desempenho das expectativas inflacionárias coletadas pelo Banco Central do Brasil no período de 2003 a 2022. As expectativas inflacionárias são importantes para a política monetária, dessa forma, também é importante a análise do desempenho destas expectativas, e para que esta ocorra, deve ser considerado na análise o contexto econômico da época analisada. Para atingir o objetivo foram utilizados os seguintes critérios de avaliação: Erros de Previsão, Performance e eficiência. Os resultados indicam que na maior parte do período, a mediana das expectativas consegue acompanhar a inflação efetiva, de modo que o erro de previsão é próximo de zero, com exceção dos períodos de instabilidade econômica, em que a inflação se afasta da expectativa e aumenta de forma absoluta.

**Palavras-chave:** Inflação, Expectativas, Banco Central do Brasil.

### **ABSTRACT**

Inflationary expectations are important for monetary policy, so it is also important to analyze the performance of these expectations, and for this to occur, the economic context of the time analyzed must be considered in the analysis. For this reason, this study analyzes the performance of the median inflation expectations collected by the BCB for the years 2003 and 2022 during the presidential terms at the time, following evaluation criteria such as: Forecast Errors, Performance and Efficiency. As a result, it was concluded that, in most cases, the median of expectations does manage to keep up with actual inflation, so that the forecast error is close to zero, with the exception of periods of economic "turbulence", when inflation deviates from expectations and increases absolutely.

**Key-words:** Inflation, Expectations, Central Bank of Brazil.

**Classificação JEL:** E58, E50, E52,

---

<sup>1</sup> Aluno do Programa de Pós-graduação em Bioestatística – UEM

<sup>2</sup> Docente do Departamento de Economia da UEM

## 1 INTRODUÇÃO

As expectativas inflacionárias desempenham um papel importante para a condução da política monetária, uma vez que, parte da inflação efetiva depende da inflação esperada (LEE, POWEL e WESSEL, 2020). Em um regime de metas de inflação, como o vivenciado pelo Brasil, o Banco Central monitora as expectativas de inflação do mercado, além das suas próprias expectativas, para verificar se elas estão ancoradas com a meta de inflação e se há riscos de que a meta não seja cumprida, e a partir disso, subsidiando suas decisões de política monetária. Nesse sentido, é fundamental avaliar os desvios entre as expectativas de inflação e a inflação observada, de modo a mensurar a performance das expectativas inflacionárias.

Diversos trabalhos já foram publicados, dissertando sobre o quão próximo da realidade se encontram as expectativas de inflação, como os trabalhos de Rocha (2010) e Gestsson (2018). Esses trabalhos, em sua maioria, utilizam períodos menores de 10 anos, sem distinguir períodos de “rompimento” da inflação sobre as expectativas e o contexto econômico da época.

Neste trabalho o objetivo é distinguir o desempenho das expectativas durante os diversos mandatos presidenciais que ocorreram nos últimos 20 anos, sendo estes: os dois primeiros mandatos de Lula (2003-2006) e (2007-2010), o primeiro de Dilma (2011-2014), o segundo de Dilma-Temer (2015-2018) e de Bolsonaro (2019-2022). Para atingir esse objetivo foram realizadas comparações entre as previsões para a inflação divulgadas pelo Banco Central no Boletim Focus e a inflação efetiva de cada de cada período medida pelo IPCA, em que a diferença entre ambos resulta nos erros de previsão. E nestes erros serão aplicados métodos estatísticos para fins de análise e comparação como a Média e Desvio Padrão dos erros de Previsão. Para a avaliação da performance das previsões foram utilizados o Erro Médio Absoluto (MAE) e Raiz do Erro Quadrático Médio (RMSE), indicadores mais robustos que a média capazes de reduzir o impacto de outliers.

Este artigo está organizado da seguinte forma: a sessão 2 apresenta uma breve revisão de estudos empíricos correlatos. A sessão 3 descreve a metodologia do artigo, a sessão 4 analisa os erros de previsão dos períodos estudados e a sessão 5 utiliza-se de métodos estatísticos para comparar os erros de previsão. Por fim, serão apresentadas as considerações finais.

## 2 REVISÃO DOS ESTUDOS EMPÍRICOS

Os trabalhos focados no desempenho das expectativas inflacionárias, principalmente referenciando o Boletim Focus, utilizam de metodologias e períodos distintos.

Lima e Céspedes (2003) utilizaram diferentes modelos lineares para prever a taxa de inflação entre 2000 até 2002, reestimaram esses modelos de forma recursiva e compararam suas habilidades preditivas com base nas previsões do boletim Focus e do BCB, usando critérios estatísticos provenientes de pacotes como X12-Arima e Eviews. Entretanto, concluiu-se que não há evidências de que o mercado (Focus) ou o Banco Central (Bacen), em seus relatórios, prevejam a inflação com precisão suficiente em horizontes temporais longos para orientar efetivamente a política monetária.

No que diz respeito às previsões do mercado, Lima e Céspedes (2003) observaram que os modelos lineares superam o mercado em termos de habilidade preditiva, especialmente para previsões que ultrapassam três meses no futuro. Esse resultado é ainda mais significativo ao considerar apenas as “Top 5” (as cinco instituições que possuem os melhores índices de acerto em previsões) em diferentes prazos (curto, médio e longo prazos). Os resultados



indicaram que as previsões do mercado, em horizontes temporais superiores a três meses, não refletiram adequadamente as verdadeiras expectativas do mercado. Portanto, sugeriram que tais previsões não deveriam exercer influência na formulação da política monetária do país.

O trabalho de Veras (2015) focou nas “Top 5”, de forma a mensurar e comparar as performances do Boletim Focus e das Top 5 entre 2004 e 2014, através do Erro Quadrático Médio (EQM), similar a Raiz do Erro Quadrático Médio (RMSE) utilizado no presente trabalho. A conclusão de Veras (2015) foi que o Boletim Focus e as Top 5 não possuem diferenças significativas em termos de precisão.

Do ponto de vista prático, o estudo de Zanettini (2019) buscou examinar as três das principais variáveis macroeconômicas: a Taxa de Câmbio, a Taxa de Crescimento do PIB e a Taxa de Inflação, seguem a hipótese de expectativas racionais, tanto na sua forma forte quanto na fraca. As análises foram conduzidas considerando o período entre 2014 e 2018. Os resultados indicam que a hipótese de expectativas racionais pode ser aceita de maneira parcial.

O Estudo de Rocha (2010) examinou as discrepâncias entre as taxas anuais de inflação efetivamente ocorridas e as previsões feitas pelos agentes econômicos do mercado para o ano consecutivo. Os índices considerados incluíram IPCA, IPA-M, IGP-M e IGP-DI. Para avaliar as previsões dos agentes, foram realizadas análises estatísticas e de séries temporais usando o modelo ARIMA. Este último método explicou os erros nas previsões dos agentes econômicos com base em valores passados desses erros, bem como termos estocásticos. Na análise estatística, observou-se que em períodos sem turbulência, como em 2002, os agentes tendem a prever valores de inflação ligeiramente acima da inflação real observada um ano depois.

Por fim, Gestsson, (2018) analisou as expectativas inflacionárias trimestrais da Islândia entre 2001 e 2017, publicadas pelo CBI (Central Bank of Iceland). O autor utilizou-se de três critérios, cada um com sua respectiva metodologia estatística: Precisão, Enviesamento e Eficiência. Três afirmações foram feitas em sua conclusão: Primeiro, as previsões do CBI são mais precisas que modelos simples de previsão. Segundo, os dados indicaram que as previsões para zero e um trimestre à frente feitas pelo CBI têm um viés positivo, o que sugere que o CBI prevê uma inflação muito alta em suas previsões para os períodos atual e seguinte. E por último, as previsões para três a oito trimestres à frente não são eficientes, indicando que o CBI não utiliza todas as informações disponíveis ao fazer previsões.

### 3 METODOLOGIA

Realizou-se um comparativo entre o histórico das expectativas inflacionárias do Boletim Focus<sup>3</sup> e o histórico inflacionário real, de forma a buscar qual padrão de previsão foi o mais próximo da realidade, buscando margens de erro, intervalos de previsão, regressões e indicadores estatísticos.

O principal dado utilizado nesta pesquisa foi a mediana das expectativas de inflação acumuladas em 12 meses, sendo as coletas feitas no último dia útil de cada mês, formadas por todas as instituições integrantes do Boletim Focus, com datas de referência entre janeiro de 2003 e dezembro de 2022. Vale ressaltar que estas previsões são “suavizadas”, ou seja, não consideram o mês atual na previsão, mas sim os 12 meses seguintes.

---

<sup>3</sup> O Relatório Focus é divulgado toda segunda-feira pelo Banco Central e resume as expectativas de mercado coletadas até a sexta-feira anterior à sua divulgação. O relatório traz a evolução gráfica e o comportamento semanal das projeções para índices de preços, atividade econômica, câmbio, taxa Selic, entre outros indicadores. As projeções são do mercado, não do BCB.

A análise comparativa entre as expectativas inflacionárias do Brasil e sua inflação efetiva seguirá uma metodologia similar ao artigo de Gestsson (2018) citado anteriormente, porém, com a diferença de que ao invés de avaliar o desempenho das expectativas trimestrais, serão utilizadas expectativas acumuladas em 12 meses.

O primeiro fator a ser definido e calculado é o erro de previsão, cuja fórmula é:

$$E_{t-12}^t = \pi_{t-12}^{et} - \pi_{t-12}^t \quad (1)$$

Podendo t ser um mês entre janeiro de 2003 e dezembro de 2022,  $E_{t-12}^t$  representa o erro de previsão da inflação acumulada em 12 meses a partir do período t-12,  $\pi_{t-12}^{et}$  representa a inflação acumulada em 12 meses esperada para o período t, e  $\pi_{t-12}^t$  a inflação efetiva acumulada em 12 meses até o período t. A partir desta equação, serão mensuradas as médias, desvios padrão, p-valores e números de observações dos erros de previsão dentro de cada intervalo entre a data na qual foi feita a previsão e a data referência. Vale salientar que os p-valores serão mensurados utilizando o teste de Shapiro-Walk, devido sua simplicidade e pelo fato de que este trabalho não aborda análises multivariadas.

Também é possível substituir  $\pi_{t-12}^t$  pelo centro da meta de inflação estabelecida para o ano referência, resultando em um desvio da Expectativa sobre a meta, no qual é capaz de determinar quão ancorada a expectativa se encontra sobre a meta de inflação. Além disso, esta variável será comparada com o erro de previsão no decorrer do trabalho.

A performance das previsões será medida através de dois parâmetros, os quais serão medidos por métodos econométricos: precisão e eficiência.

Para calcular a precisão da expectativa, utilizaremos o número de observações “n” aplicado no Erro Médio Absoluto da Previsão (MAE) e na Raiz do Erro Quadrático Médio da Previsão (RMSE), resultando nas seguintes fórmulas:

$$MAE_t = \frac{1}{n} \sum_{t=1}^n |E_{t-12}^t| \quad (2)$$

$$RMSE_t = \sqrt{\frac{1}{n} \sum_{t=1}^n E_{t-12}^{t^2}} \quad (3)$$

Como o nome já diz, o MAE<sub>t</sub> representa a média absoluta do erro de previsão para a inflação acumulada em 12 meses até o período t, enquanto a RMSE<sub>t</sub> representa a raiz quadrada da média do erro da previsão para a inflação acumulada em 12 meses até o período t. No final, quanto maiores forem o MAE e o RMSE, menos precisas serão consideradas as previsões.

De acordo com Gestsson (2018), para que uma previsão seja eficiente, ela não deve estar correlacionada com a informação disponível no momento da previsão, representada neste trabalho pela inflação passada, acumulada em 12 meses, até um período antes da data em que a previsão foi executada ( $\pi_{t-25}^{t-13}$ ).

Para mensurarmos a eficiência, estimamos uma equação através dos MQO (Mínimos Quadrados Ordinários), considerando o erro de previsão  $E_{t-12}^t$  como a variável dependente e  $\pi_{t-25}^{t-13}$  citada anteriormente como variável independente, resultando na equação abaixo:


$$E_{t-12}^t = \alpha + \beta \pi_{t-25}^{t-13} + \mu_{t-12}^t \quad (5)$$

Em que  $\alpha$  representa o intercepto da regressão para determinado intervalo de previsão,  $\beta$  é o coeficiente da variável independente  $\pi_{t-13}^t$  e  $\mu_{t-12}^t$  é um erro residual de média zero e variância constante. Dentro desta equação, se  $\beta \neq 0$  significa que o erro de previsão está correlacionado com a inflação passada.

#### 4 ANÁLISE DOS ERROS DE PREVISÃO ENTRE 2003 E 2022 NO BRASIL

Entre 2003 e 2022 a taxa de inflação IPCA teve fortes variações durante todos os períodos, enquanto suas devidas expectativas oscilaram em menor grau, como se pode observar no Gráfico 1. Dessa forma, encontram-se momentos em que a inflação supera significativamente não apenas as expectativas, mas também a banda superior da meta de inflação.

Vale reforçar que as datas referência para a Expectativa e a inflação efetiva são as mesmas. Exemplo: O IPCA de janeiro de 2010 é comparado com as expectativas para a inflação de janeiro de 2010, sendo estas previsões realizadas 12 meses antes, ou seja, em janeiro de 2009.




Fontes: BCB e IPEADATA (2023).

Também se pode notar que as expectativas se mantiveram na grande maioria dos períodos dentro dos limites superior e inferior das metas, porém, relativamente distante do centro da meta, seja acima ou abaixo desta.

Através da equação número (1) citada anteriormente, pode ser realizado a análise mais detalhada sobre os dados, em que os erros de previsão equivalem a subtração entre a inflação prevista e a inflação efetiva, o mesmo pode ser feito para o desvio da previsão sobre a meta (Previsão – Meta do ano Referência). Com ambos os indicadores definidos, pode-se obter duas séries temporais abrangendo todos os períodos estudados neste trabalho e compará-las.

Observando o Gráfico 2, há momentos em que as expectativas erram negativamente e outros momentos em que os erros se aproximam de zero



Fontes: BCB e IPEADATA (2023).

Por outro lado, o desvio da previsão sobre a meta indica que, no geral, há um grau de ancoragem maior entre a expectativa e a meta do que a expectativa e inflação efetiva.

Análises mais precisas serão feitas a seguir analisando períodos de quatro em quatro anos, divididos por mandatos presidenciais (em que o segundo governo Dilma e Temer foram unificados para manter a divisão temporal uniforme).

O primeiro governo Lula começou em 2003, com a expectativa de inflação acima de 10%, e IPCA efetivo acumulado em 12 meses próximo de 15% como demonstra o Gráfico 3. Além disso, as expectativas se encontravam completamente desancoradas da meta de inflação, porém em níveis menores que a dispersão da inflação em relação a meta. Por outro lado, no ano seguinte e adiante, as expectativas e a inflação efetiva começaram a progredir de maneira similar e próximas.

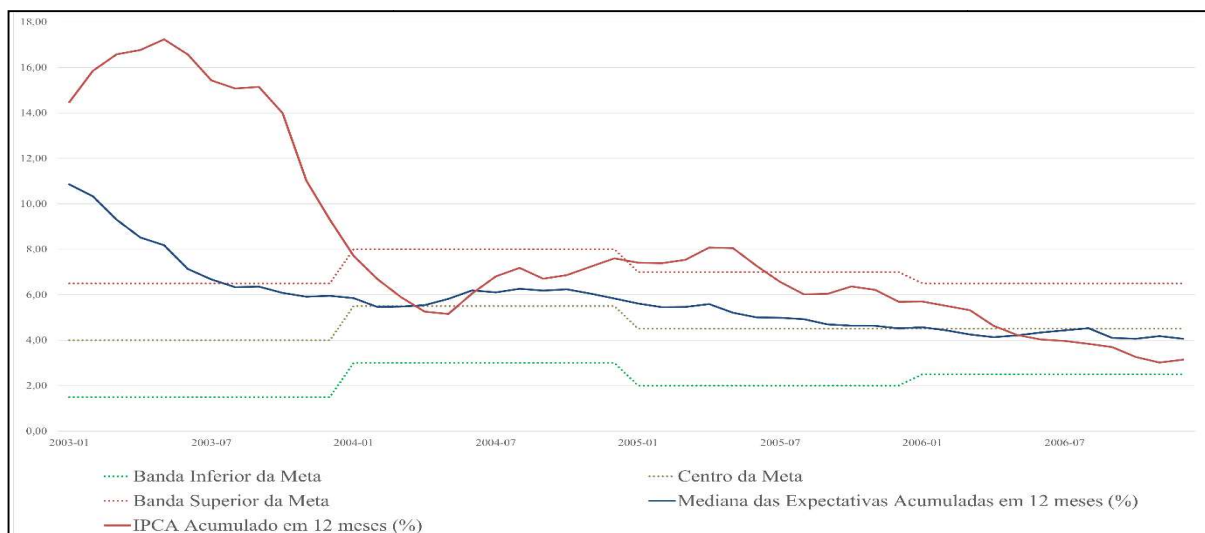


Gráfico 3 - IPCA e Mediana das Expectativas acumuladas em 12 meses (%) entre 2003 e 2006

Fontes: BCB e IPEADATA (2023).

Analisando os erros de previsão em p.p., conforme o Gráfico 4, em determinado ponto do ano de 2003 o erro de previsão chegou próximo aos 10 p.p., enquanto o desvio das expectativas em relação a meta foram diminuindo gradualmente ao longo do tempo, aproximando-se de zero e os erros de previsão se tornaram menos extremos.




Gráfico 4 - Erros de Previsão e Desvios da Previsão Sobre a Meta Entre 2003 e 2006 (p.p.)

Fontes: BCB e IPEADATA (2023).

As razões para o desequilíbrio inflacionário de 2003, de acordo com Silva (2017), começou no ano anterior, em que havia preocupações nos mercados financeiros interno e externo em relação à possível eleição de Luís Inácio Lula da Silva como presidente. A incerteza sobre a futura política econômica do Brasil persistia, mesmo após Lula ter incluído o senador e empresário José Alencar em sua chapa e ter se comprometido formalmente com a estabilidade econômica, controle da inflação e respeito aos contratos com investidores nacionais e estrangeiros. Além disso, não apenas havia expectativas de aumento da inflação para o ano de 2003, como esta também se efetivou em grau elevado.

Há um padrão repetitivo em que, nos anos em que as metas de inflação não são cumpridas, a inflação encontra-se desancorada das expectativas. E em 2003 não foi diferente, a inflação do ano atingiu 9,3%, superando a banda superior de 6,5%.

As causas para o não cumprimento da meta encontram-se não apenas na carta aberta do BCB ao CMN referente ao ano de 2003, mas também na carta referente ao ano anterior, de acordo com a primeira carta do BCB (2003d), o ano de 2002 foi caracterizado por uma grave crise de confiança sobre a economia junto de um aumento significativo da aversão ao risco sobre os mercados internacionais, prejudicando assim, a estabilidade da inflação.

Enquanto o ano de 2003, de acordo com o BCB (2004e), o maior grau de inflação ficou concentrado nos primeiros meses do ano, refletindo as mesmas causas da inflação para o ano anterior: uma deterioração das expectativas sobre o futuro da economia.

O segundo sub-período analisado abrange os anos de 2007 a 2010, durante o segundo governo Lula. Mesmo que o período de Lula II tenha abrangido a crise de 2008, os efeitos desta sobre as expectativas e o IPCA efetivo foram mínimos, como demonstra o Gráfico 5, gerando apenas um leve desvio da inflação e das expectativas em relação ao centro da meta, porém, sem ultrapassar o limite superior. Vale ressaltar também que em todos os anos deste governo a meta de inflação foi cumprida.

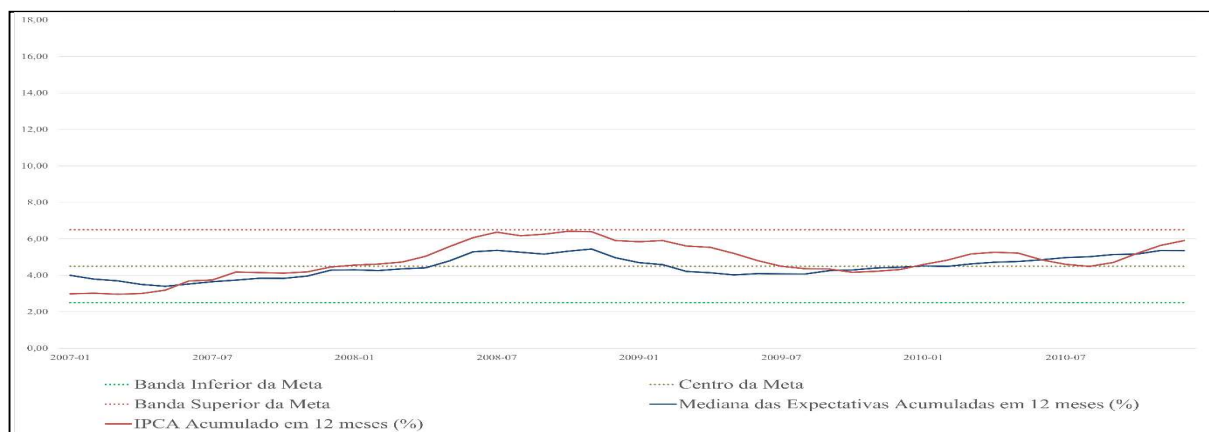


Gráfico 5 - IPCA e Mediana das Expectativas acumuladas em 12 meses entre 2007 e 2010 (%)

Fontes: BCB e IPEADATA (2023).

Consequentemente os erros de previsão e o desvio da meta do segundo governo Lula foram próximos de zero, como demonstra a Gráfico 6.




Gráfico 6 - Erros de Previsão e Desvios da Previsão Sobre a Meta Entre 2007 e 2010 (p.p.)

Fontes: BCB e IPEADATA (2023).

Assim como o segundo governo Lula, as expectativas e o IPCA no primeiro governo Dilma (2011 – 2014) estiveram bem ancorados um com o outro durante todo o período, como demonstra o Gráfico 7. Porém, tanto a inflação quanto suas expectativas caminharam entre o centro da meta durante todo o período e em alguns pontos, ficou acima da meta superior (apesar de não finalizar o ano descumprindo a meta em nenhum momento).

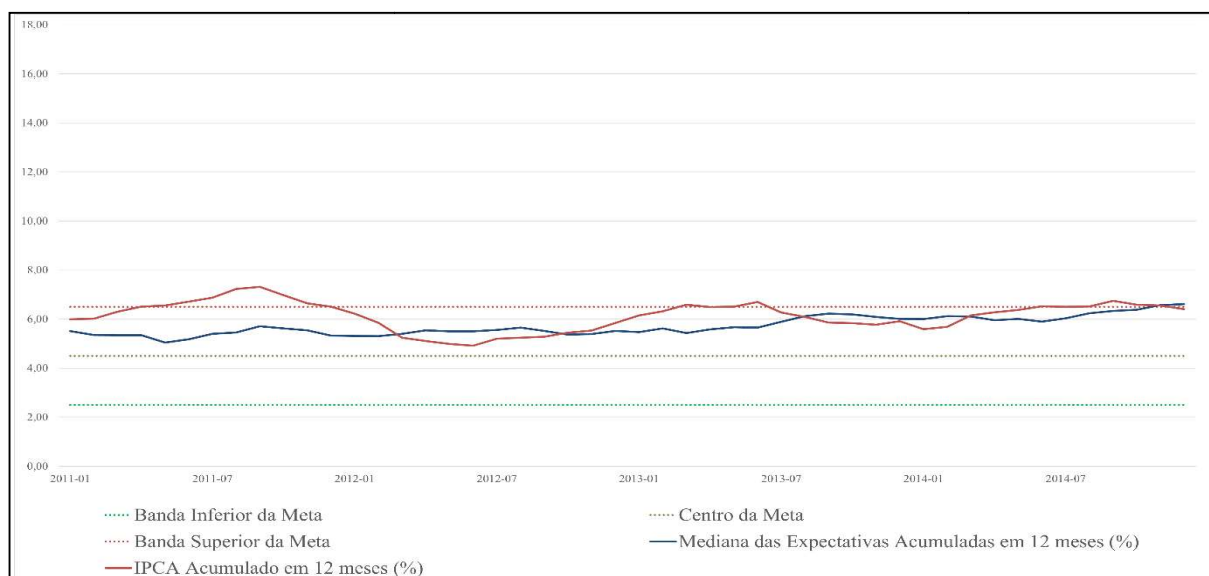


Gráfico 7 - IPCA e Mediana das Expectativas acumuladas em 12 meses entre 2011 e 2014 (%)

Fontes: BCB e IPEADATA (2023).

Consequentemente, os erros de previsão e os desvios da meta estiveram bem próximos de zero durante todo o período, como demonstra o Gráfico 8.




Gráfico 8 - Erros de Previsão e Desvios da Previsão Sobre a Meta Entre 2011 e 2014 (p.p.)

Fontes: BCB e IPEADATA (2023).



No segundo Governo Dilma a inflação se desancorou de suas expectativas e da meta de inflação desde o começo do mandato, excedendo-a significativamente, como demonstra o Gráfico 9. Entretanto, no início de 2017, o IPCA continuou desancorado, porém, mantendo-se abaixo da expectativa. E no final da primeira metade de 2018, tanto o IPCA quanto as expectativas voltaram a progredir similarmente. Por outro lado, o desvio da expectativa em relação a meta foi menor em 2015, e praticamente se igualou a meta em 2017, momento único da história do RMI no Brasil onde a inflação alcançou um valor inferior à meta.




Gráfico 9 - IPCA e Mediana das Expectativas acumuladas em 12 meses (%) entre 2015 e 2018

Fontes: BCB e IPEADATA (2023).

Os erros de previsão aumentaram significativamente para baixo no começo de 2015, como demonstra o Gráfico 10, aumentaram para cima em 2017 e se estabilizaram próximo de zero no fim da primeira metade de 2018.




Gráfico 10 - Erros de Previsão e Desvios da Previsão Sobre a Meta Entre 2015 e 2018 (p.p)

Fontes: BCB e IPEADATA (2023).

As razões para a alta de inflação de 2015, ano em que a inflação finalizou em 10,67%, superando o limite superior da meta de 6,5%, podem ser explicadas pela carta aberta do BCB (2016f) ao CMN, que cita o realinhamento dos “Preços Administrados” em relação aos preços livres. Além disso, as taxas de câmbio dispararam na época para um valor acima do esperado, em que a expectativa era de R\$2,75/US\$ e o valor concretizado foi de R\$3,90/US\$.

Por outro lado, 2017 foi um ano atípico, a inflação finalizou-se abaixo da meta, atingindo 2,95% enquanto o limite mínimo era de 3%. Mesmo assim, a inflação estava desancorada das expectativas e uma carta aberta teve de ser escrita pelo BCB (2018g) para o CMN. De acordo com esta carta, o ano de 2017 foi caracterizado por uma recuperação da atividade econômica melhor do que o esperado, e um aumento na oferta de alimentos, que inclusive gerou deflação nos seus preços.


Até o final de 2020, mesmo após o início da Crise do Covid-19, o IPCA e suas expectativas se mantiveram no mesmo nível em termos de acúmulo em 12 meses, como demonstra o Gráfico 11.

Historicamente, no começo de 2021, a lei complementar 179 entrou em vigor estabelecendo a autonomia do Brasil, de forma a classificar o mesmo como uma autarquia desvinculada a qualquer ministério, pois antes o BCB era vinculado ao ministério da Fazenda (AGÊNCIA SENADO, 2021).

As mudanças sobre o BCB foram majoritariamente de natureza administrativa, não econômica. Por isso, esta lei não proporcionou soluções imediatas sobre a instabilidade inflacionária da época, que se estendeu até o final do Governo Bolsonaro, tanto que, no mesmo ano, a inflação disparou, de forma a parar mais uma vez de acompanhar as expectativas e a meta.


Em meados de 2022, a inflação efetiva diminuiu, e as expectativas voltam a se aproximar, porém, ambas acima do limite superior da meta. Dessa forma, tanto 2021 quanto 2022 foram anos nos quais as metas de inflação não foram cumpridas. De acordo com o BCB (2022) em sua carta aberta ao CMN, houveram múltiplas causas para o aumento da inflação, como o aumento dos preços das *commodities*, a crise hídrica e desequilíbrios de oferta e demanda de insumos nas cadeias produtivas globais.

Para 2022, segundo o BCB (2023), os motivos para a alta de inflação foram praticamente os mesmos do ano anterior, com a adição da retomada da demanda por empregos e serviços devido à redução de casos de Covid-19.



Fontes: BCB e IPEADATA (2023).

Sobre os erros de previsão, presentes na Gráfico 12, se mantiveram perto de zero até o final de 2020, mas em 2021, o erro se intensifica para baixo, chegando a voltar ao normal apenas no final de 2022. Enquanto os desvios da meta mantiveram-se também próximos de zero até 2020, porém, no ano seguinte, este responde com um leve aumento.



## 5 ANÁLISE COMPARATIVA DOS ERROS DE PREVISÃO

O comparativo intertemporal utilizando indicadores estatísticos é fundamental para distinguir e comparar o desempenho das previsões de cada período distinto, desta forma, este capítulo apresenta os resultados empíricos agrupados para os períodos sob análise.

### 5.1 O COMPARATIVO ENTRE OS ERROS DE PREVISÃO

Ao comparar os erros de previsão de cada governo notamos que, em média, de acordo com o Quadro 1, todas as expectativas erram para baixo. Dessa forma, em termos absolutos, os menores erros de previsão ocorreram no primeiro governo Dilma, representando 0,42 p.p., porém, o menor desvio padrão ocorreu no segundo governo Lula, atingindo os 0,59 p.p. Por outro lado, as maiores imprecisões ocorreram no primeiro governo Lula, com erro médio de 2,39 p.p. e desvio padrão de 3,11 p.p.

Analisando os P valores, que representam o resultado do teste de Shapiro-Wilk, podemos não rejeitar a hipótese nula de que os erros de previsão seguem uma distribuição normal apenas no Segundo Governo Lula e no Primeiro Governo Dilma.

Ao comparar a crise de confiança do mercado que ocorreu na transição entre os governos FHC e Lula com a Crise do Covid-19, pode-se afirmar que a última foi mais a severa, gerando maiores impactos negativos sobre a economia brasileira. Porém, foi a crise de confiança entre 2002 e 2003 que demonstrou maior grau de instabilidade e desancoragem entre a inflação efetiva, a mediana das expectativas e o RMI.

Vale mencionar também que a crise econômica de 2015 também teve um impacto significativo para a imprecisão das previsões da época, de forma a superar 1 p.p. no Erro Médio de previsão da inflação.

Tabela 1 - Médias e Desvios Padrão dos Erros de Previsão (p.p)

Período	Erro Médio (p.p)	Desvio Padrão do Erro (p.p)	P valor (Shapiro-Wilk)
Período Total	-1,25	2,16	0,00
Lula 1	-2,39	3,11	0,00
Lula 2	-0,35	0,59	0,67
Dilma 1	-0,42	0,66	0,05
Dilma2/Temer	-1,16	1,98	0,00
Bolsonaro	-1,93	2,45	0,00

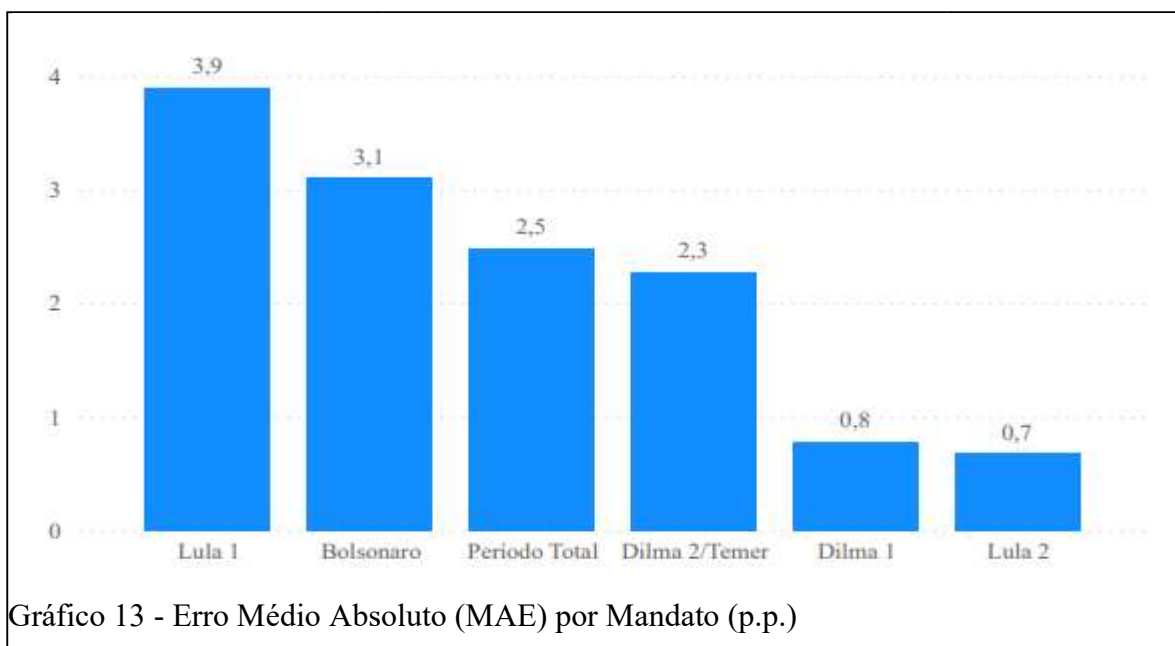
Fontes: BCB e IPEADATA (2023).

### 5.2 DESEMPENHO DAS EXPECTATIVAS


O desempenho das expectativas foi mensurada utilizando dois indicadores estatísticos avançados, considerados mais robustos que a média aritmética. Estes indicadores são: o Erro Médio Absoluto (MAE) e Raiz do Erro Quadrático Médio (RMSE), e quanto menores forem estes indicadores, melhor a performance das expectativas.

Ambos os Indicadores de desempenho das expectativas, representados pelos Gráficos 13 e 14 respectivamente, demonstram que a previsão mais performática ocorreu no segundo governo Lula, onde o primeiro governo Lula obteve um Erro médio Absoluto (MAE) de 0,6

p.p. e uma Raiz do Erro Quadrático Médio (RMSE) de 0,7. Enquanto a previsão menos performática ocorreu no primeiro governo Lula, com MAE de 2,6 p.p. e RMSE de 3,9 p.p.



Fontes: BCB e IPEADATA (2023).



Fontes: BCB e IPEADATA (2023).

### 5.3 EFICIÊNCIA DAS EXPECTATIVAS

Para mensurar a eficiência das expectativas de acordo com Gestsson (2018), é executando uma regressão linear, onde o Erro de previsão é a variável dependente, e a independente é a inflação acumulada em 12 meses até o período anterior a realização da previsão. Dessa forma, se houver correlação entre a informação disponível no momento com a previsão realizada, esta é considerada ineficiente.

Utilizando um nível de confiança de 95%, apenas as previsões no primeiro governo Dilma demonstraram sinais de ineficiência, onde o erro de previsão esteve correlacionado com previsões anteriores, como demonstra o Quadro 2.

Tabela 2 - Resultados da Estimação da Equação (5) (p.p.)

<b>Período</b>	<b>Intercepto</b>	<b>Beta</b>	<b>R<sup>2</sup></b>	<b>P Valor</b>
Período Total	-0,73427	-0,0827	0,01201	0,09026
Lula 1	-3,97877	0,17277	0,04173	0,16373
Lula 2	-0,86361	0,11244	0,04031	0,17122
Dilma 1	-3,82813	0,58497	0,43031	0,00
Dilma 2/Temer	-0,02459	-0,16441	0,04196	0,16253
Bolsonaro	-1,09854	-0,17625	0,03071	0,23353

Fontes: BCB e IPEADATA (2023).

Por fim, comparando todos estes números, nota-se um padrão, onde todos os indicadores demonstram que os piores erros de previsão em todas as medidas ocorreram na crise de confiança do mercado primeiro governo Lula, seguido da crise de Covid-19 no governo Bolsonaro e da crise econômica no segundo governo Dilma/Temer.

## 6 CONCLUSÃO

Em momentos de crise, seja esta de credibilidade no começo do governo Lula, econômica no Governo Dilma-Temer ou Sanitária no Governo Bolsonaro, foram momentos em que a inflação efetiva se desvinculou completamente das expectativas e das metas de inflação, demonstrando nestes momentos falta de previsibilidade sobre a inflação durante crises, enquanto a expectativa se afasta moderadamente dos limites determinados para a inflação pelo Banco Central. Consequentemente, indicadores de desempenho sobre as expectativas para mandatos marcados por crises são fortemente afetados por estas.

Fora destes momentos, o IPCA efetivo e a mediana de suas expectativas mantinham uma proximidade relativa entre si e dentro das bandas limites da meta. Dessa forma, podemos concluir que a mediana das expectativas é relativamente precisa em momentos não turbulentos da economia e assim como o IPCA, mantêm-se dentro dos limites das metas.

## REFERÊNCIAS

- BANCO CENTRAL DO BRASIL. **Controle da Inflação** - Meta Inflação. Disponível em: <https://www.bcb.gov.br/controleinflacao/metainflacao>. Acesso em: 03 set. 2023. (b).
- BANCO CENTRAL DO BRASIL. **Política Monetária** - Expectativas de Mercado - Expectativas - Perguntas Frequentes. Disponível em: <https://www.bcb.gov.br/controleinflacao/faqexpectativa>. Acesso em: 17 nov. 2023. (c).
- BANCO CENTRAL DO BRASIL. **Política monetária** – Metas para a inflação – Histórico das metas para inflação - 2002 – Carta Aberta. Disponível em: [https://www.bcb.gov.br/content/controleinflacao/controleinflacao\\_docs/carta\\_aberta/carta2002.pdf](https://www.bcb.gov.br/content/controleinflacao/controleinflacao_docs/carta_aberta/carta2002.pdf). Acesso em: 16 dez. 2023.
- BANCO CENTRAL DO BRASIL. **Política monetária** – Metas para a inflação – Histórico das metas para inflação - 2004 – Carta Aberta. Disponível em: [https://www.bcb.gov.br/content/controleinflacao/controleinflacao\\_docs/carta\\_aberta/carta2003.pdf](https://www.bcb.gov.br/content/controleinflacao/controleinflacao_docs/carta_aberta/carta2003.pdf). Acesso em: 16 dez. 2023.
- BANCO CENTRAL DO BRASIL. **Política monetária** – Metas para a inflação – Histórico das metas para inflação - 2016 – Carta Aberta. Disponível em: [https://www.bcb.gov.br/content/controleinflacao/controleinflacao\\_docs/carta\\_aberta/carta2015.pdf](https://www.bcb.gov.br/content/controleinflacao/controleinflacao_docs/carta_aberta/carta2015.pdf). Acesso em: 16 dez. 2023.
- BANCO CENTRAL DO BRASIL. **Política monetária** – Metas para a inflação – Histórico das metas para inflação - 2018 – Carta Aberta. Disponível em: [https://www.bcb.gov.br/content/controleinflacao/controleinflacao\\_docs/carta\\_aberta/carta2017.pdf](https://www.bcb.gov.br/content/controleinflacao/controleinflacao_docs/carta_aberta/carta2017.pdf). Acesso em: 16 dez. 2023.
- BANCO CENTRAL DO BRASIL. **Política monetária** – Metas para a inflação – Histórico das metas para inflação - 2022 – Carta Aberta. Disponível em: [https://www.bcb.gov.br/content/controleinflacao/controleinflacao\\_docs/carta\\_aberta/carta2022.pdf](https://www.bcb.gov.br/content/controleinflacao/controleinflacao_docs/carta_aberta/carta2022.pdf). Acesso em: 16 dez. 2023.
- GESTSSON, M. H. **An Analysis of CBI's Inflation Forecast Errors**. Maio 2018. IPEADATA. Disponível em: <http://ipeadata.gov.br/Default.aspx>. Acesso em: 10 set. 2023.
- LEE, J.; POWELL, T.; WESSEL, D. **What are inflation expectations? Why do they matter?**. Washington D.C. 30 nov. 2020. Disponível em: <https://www.brookings.edu/articles/what-are-inflation-expectations-why-do-they-matter/>. Acesso em: 07 out. 2023.
- AGÊNCIA SENADO, Lei da autonomia do Banco Central entra em vigor. **Agência Senado** [online], Brasília, 26 fev. 2021. Economia. Disponível em:



<https://www12.senado.leg.br/noticias/materias/2021/02/25/lei-da-autonomia-do-banco-central-entra-em-vigor> Acesso em: 21 de fev de 2021.

LIMA, Elcyon Caiado Rocha; CÉSPEDES, Brisne J. Vasquez. O Desempenho do Mercado (Focus) e do Bacen na Previsão da Inflação: Comparações com Modelos Lineares Univariados. **Boletim de Conjuntura – IPEA**, 2003.

ROCHA, M. V. B. F. **Previsão da Inflação no Boletim Focus: Uma Avaliação**. 2010. Dissertação (Mestrado em Finanças e Economia Empresarial) - Escola de Pós-Graduação em Economia, Fundação Getúlio Vargas, Rio de Janeiro, 2010.

SILVA, José Alderir da. A política monetária nos governos Lula e Dilma. **Revista de Economia da UEG**. Vol. 13, N.º 1, jan/jun. 2017.

VERAS, Marina Palhano. **Boletim Focus: As “Top 5” Preveem Melhor?**. Monografia (Graduação em Ciências Econômicas) - Faculdade de Economia e Administração, Insper Instituto de Ensino e Pesquisa, São Paulo, 2015.

ZANETTINI, Fernando Lusse Santos. **Existe Formação de Expectativas Racionais no Brasil? uma Avaliação do Boletim Focus para o Período 2014-2018**. Trabalho de Conclusão de Curso (Graduação em Ciências Econômicas) - Faculdade de Ciências Econômicas, Universidade Federal do Rio Grande do Sul, 2019).



ISBN nº 978-65-01-11585-6

# INTERDEPENDÊNCIA FINANCEIRA DO IBOVESPA E OS PRINCIPAIS ÍNDICES GLOBAIS: ABORDAGEM NÃO LINEAR VIA GARCH-CÓPULA

Adilson Padovan Junior <sup>1</sup>

Joilson Giorno <sup>2</sup>

## Área 3 – Macroeconomia, Economia Monetária, Finanças e Economia Internacional

**RESUMO:** Este estudo examina a dependência estrutural entre o Ibovespa e principais índices globais, buscando entender como choques externos em grandes economias, como EUA, Europa e Ásia, impactam o mercado brasileiro. Utilizando modelos GARCH (S-GARCH, E-GARCH, GJR-GARCH, TARCH e APARCH) para modelar a média e volatilidade condicional, foram estimadas 1.100 variações para encontrar as melhores ordens (p, q) com base nos critérios de informação. Funções cópulas (Gaussiana, t-Student, Clayton, Gumbel e Frank) foram usadas para capturar dependências não lineares entre os choques. Os resultados indicam forte correlação do Ibovespa com SP500 e DAX, sugerindo integração com mercados dos EUA e Europa, enquanto a relação com mercados asiáticos é mais fraca, apontando para possíveis oportunidades de diversificação. A cópula t-Student capturou melhor as dependências de cauda pesada, indicando que eventos extremos podem ocorrer simultaneamente entre os mercados.

**Palavras-chave:** Dependência estrutural; Ibovespa; GARCH-Cópula.

**ABSTRACT:** *This study examines the structural dependence between the Ibovespa and major global indices, aiming to understand how external shocks in large economies, such as the US, Europe, and Asia, impact the Brazilian market. Using GARCH models (S-GARCH, E-GARCH, GJR-GARCH, TARCH, and APARCH) to model the conditional mean and volatility, 1,100 variations were estimated to find the best (p, q) orders based on information criteria. Copula functions (Gaussian, t-Student, Clayton, Gumbel, and Frank) were used to capture nonlinear dependencies between the shocks. The results indicate a strong correlation between the Ibovespa and the SP500 and DAX, suggesting integration with US and European markets, while the relationship with Asian markets is weaker, pointing to potential diversification opportunities. The t-Student copula provided the best fit, capturing heavy-tail dependencies, indicating that extreme events may occur simultaneously across the markets.*

**Keywords:** *Structural dependence; Ibovespa; GARCH-Copula.*

**Classificação JEL:** C32; F36; G15.

---

<sup>1</sup> Doutorando em Economia pelo Programa de Pós-Graduação em Ciências Econômicas da Universidade Estadual de Maringá (PCE/UEM), Maringá, Paraná, Brasil e Bolsista CAPES (Coordenação de Aperfeiçoamento de Pessoal de Nível Superior). E-mail: padovanjr@gmail.com

<sup>2</sup> Ph.D. in Economics at the University of South Carolina, USC, USA e Professor na Universidade Estadual de Maringá (PCE/UEM), Maringá, Paraná, Brasil. E-mail: jgiorno@uem.com

# 1 INTRODUÇÃO

A interconexão dos mercados financeiros globais, uma consequência direta da globalização financeira e da integração de mercados, é um fenômeno que tem atraído um interesse significativo tanto de acadêmicos quanto investidores nas últimas décadas. Eichengreen (1996) destaca como o advento da globalização financeira facilitou um ambiente onde investimentos e capital podem fluir com mais liberdade entre fronteiras, resultando em uma integração sem precedentes dos mercados financeiros. Obstfeld e Taylor (2004) complementam essa visão, evidenciando a integração através da crescente correlação entre movimentos dos mercados acionários globais, demonstrando como eventos econômicos em uma região podem ter efeitos reverberantes em todo o mundo, ampliando assim o conceito de interdependência econômica global.

Um aspecto crucial dessa interconexão é o fenômeno do contágio financeiro, que se refere à transmissão de choques de mercado de uma economia para outra, além do que seria esperado com base em fundamentos econômicos compartilhados. De acordo com Kodres e Pritsker (2002), o contágio pode ser precipitado por uma variedade de fatores, incluindo, mas não se limitando a, choques macroeconômicos, mudanças na política monetária e crises financeiras. Os autores sugerem que as crises financeiras podem se espalhar entre países e mercados, independentemente de suas condições econômicas individuais, devido à psicologia dos investidores e a mecanismos de mercado como alavancagem e liquidez. Isso ressalta cada vez mais a necessidade de adoção de políticas macroprudenciais.

Por sua vez, Claudio Borio (2011), destaca que as políticas macroprudenciais são estratégias implementadas por autoridades financeiras com o objetivo de mitigar riscos sistêmicos que podem afetar a estabilidade financeira de uma economia ou, em um contexto mais amplo, do sistema financeiro global. Essas políticas buscam identificar, monitorar e combater riscos que possam acumular-se no sistema financeiro e provocar uma crise ampla. Incluem a adoção de medidas como requisitos de capital mais rigorosos para bancos, limites para a alavancagem financeira, políticas para gerir o fluxo de capitais e a criação de amortecedores de liquidez. Borio (2011) argumenta que, ao exigir que as instituições financeiras mantenham um nível mais elevado de capital de reserva, as autoridades podem reduzir a probabilidade de insolvência bancária e, por conseguinte, diminuir o risco de uma crise financeira generalizada.

A importância de entender a natureza dessas relações torna-se ainda mais crítica em um mundo onde os mercados financeiros estão cada vez mais interligados. A metodologia GARCH-Cópula, mencionada no trabalho em questão, oferece uma abordagem sofisticada para analisar a dependência estrutural multivariada não linear entre os mercados, permitindo uma compreensão mais profunda da dinâmica de contágio e da integração de mercado. Por meio da aplicação de modelos GARCH variados e técnicas de cópula, é possível capturar a essência das relações de dependência entre os retornos dos índices acionários, o que é fundamental para compreender as dinâmicas de mercado e até mesmo integrar estratégias de mitigação de riscos em um cenário financeiro globalizado.

O estudo tem como objetivo central investigar como choques externos em grandes economias, como os Estados Unidos, Europa e Ásia, afetam a volatilidade e o comportamento do mercado brasileiro, avaliando a transmissão de riscos e o fenômeno de contágio financeiro entre regiões. Especificamente, ao utilizar modelos GARCH e cópulas, pretende-se capturar a dependência não linear entre as inovações (resíduos) dos retornos do Ibovespa (log-retorno) e de índices globais (log-retorno), fornecendo uma análise quantitativa robusta que contribua para a formulação de políticas econômicas e estratégias de mitigação de riscos. A pesquisa tem implicações práticas na compreensão das limitações da diversificação de portfólios e na

promoção de uma maior resiliência econômica em face de choques globais, especialmente para mercados emergentes como o Brasil. Esse enfoque reforça a importância de entender as conexões econômicas subjacentes e o impacto de mercados globais sobre o desenvolvimento financeiro local, com um olhar voltado para a estabilidade macroeconômica.

Sendo assim, a seção 2 investiga as relações de dependência entre índices das bolsas de valores globais, destacando a importância dessas interações. A seção 3 explora a conexão entre o Ibovespa e os principais índices globais. Na seção 4, são apresentados os dados e a metodologia, com uma ênfase nos métodos S-GARCH, E-GARCH, GJR-GARCH, TARCH e APARCH, assim como nas cópulas Gaussiana, t de Student, Clayton, Gumbel e Frank. Além disso, essa seção inclui uma análise descritiva dos dados. Por fim, a seção 5 discute os resultados, examinando as descobertas e suas implicações e a seção 6 conclui o estudo.

## **2 DEPENDÊNCIAS DE ÍNDICES DAS BOLSAS DE VALORES GLOBAIS**

Desde o trabalho de Grubel e Fadner (1971) sobre a interdependência dos mercados acionários internacionais, uma série de estudos têm explorado a correlação entre diferentes mercados de ações em todo o mundo. Abhyankar, Copeland e Wong (1997) descobriram estruturas não lineares nos índices do mercado de ações, enquanto estudavam o S&P 500, o DAX, o Nikkei 225 e o FTSE-100.

Os estudos de Leong e Felmingham (2003) destacaram a interdependência dos mercados de ações nas economias desenvolvidas do Leste Asiático. Posteriormente, a pesquisa de Chuang, Lu e Tswei (2007) confirma a interdependência das variações de ações internacionais, novamente se concentrando nos mercados do Leste Asiático. Drożdż, Grümmer, Ruf e Speth (2001) levaram a análise ainda mais longe, identificando as correlações transversais do mercado de ações global, especificamente entre o DAX e o Dow Jones.

Esses estudos ilustram a existência de relações substanciais entre os índices acionários globais. Portanto, compreender a profundidade e a natureza dessas relações é essencial para investidores e formuladores de políticas. Aplicar técnicas avançadas como a GARCH-Cópula na análise dessas relações pode proporcionar informações mais acuradas sobre a dinâmica do mercado acionário global, possibilitando tomadas de decisões mais informadas e estratégicas.

## **3 IBOVESPA E OS ÍNDICES GLOBAIS**

Assim como para outros índices de mercado, a relação entre o Ibovespa e os principais índices globais não tem sido diferente. Vartanian (2012) explorou o impacto do índice Dow Jones, commodities e câmbio sobre o Ibovespa, em um estudo que revelou a importância desses fatores na determinação do comportamento do Ibovespa. O trabalho destacou a interação dinâmica e a interdependência entre esses diferentes mercados.

Além disso, Ferreira e Zachis (2012) realizaram uma análise dos saltos e co-saltos nas séries do IBOVESPA, Dow Jones, taxa de juros, taxa de câmbio e no spread do C-Bond. Esta pesquisa ilustra como as mudanças bruscas em um mercado podem ter um efeito cascata em outros mercados, incluindo o Ibovespa. Por sua vez, Achcar, Cepeda-Cuervo e Barossi-Filho (2012) se concentraram nos modelos de volatilidade multivariada, aplicando-os ao Ibovespa e ao Dow Jones Industrial. Sua pesquisa evidencia como a volatilidade pode afetar a relação entre os índices.

Brondani et al. (2012) teve como objetivo investigar a relação entre o índice Dow Jones Industrial Average e o índice Ibovespa, buscando compreender a influência que o primeiro exerce sobre o segundo. Para isso, eles empregaram técnicas estatísticas, como o coeficiente de correlação linear de Pearson, a Regressão Linear Simples e o Método de Mínimos Quadrados

Ordinários, a fim de analisar a volatilidade desses índices financeiros. Os resultados obtidos indicaram que o desempenho do índice Ibovespa é influenciado, em certa medida, pelas flutuações e movimentos do índice Dow Jones Industrial Average.

Por fim, Lopes e Pessanha (2017) desenvolveram uma análise de dependência entre mercados financeiros utilizando o modelo Cópula-GARCH, mostrando uma correlação positiva entre o Ibovespa e outros índices globais. No entanto, foram utilizados apenas dados do FTSE100 (Inglaterra), S&P500 (Estados Unidos), GDAXHI (Alemanha) e NIKKEI (Japão).

Em suma, a literatura aponta para uma relação complexa e dinâmica entre o índice de mercado brasileiro e os principais índices globais, influenciada por uma variedade de fatores e sujeita a mudanças ao longo do tempo. A fim de alongar o debate e acrescentar mais dados ao assunto, as próximas seções são dedicadas a apresentar a metodologia e os principais resultados e discussões do presente estudo.

## 4 DADOS E METODOLOGIA

Na presente seção são apresentados os métodos GARCH e Cópulas, além dos dados equivalentes aos retornos<sup>3</sup> do Índice Bovespa (Brasil) com 10 importantes índices acionários globais: S&P 500 (Estados Unidos), *Dow Jones Industrial Average* (Estados Unidos), FTSE 100 (Reino Unido), DAX (Alemanha), EURO STOXX 50 (Europa), Nikkei 225 (Japão), Hang Seng (Hong Kong), *Shanghai Composite* (China), *Índice de Precios y Cotizaciones* (México) e KOSPI (Coreia do Sul) com um total de 1.952 amostras<sup>4</sup> dos retornos para cada índice durante o período de 10 anos (01/01/2013 até 01/01/2023) concatenando-as de acordo com a data de fechamento (Ver seção 4.2 – Análise descritiva).

A partir de então, foi utilizada a abordagem GARCH-Cópula com 1.100 variações de ordens (p, q) dos modelos S-GARCH, E-GARCH, GJR-GARCH, TARCH e APARCH (Ver Anexo “A” – Tabela AIC dos Modelos Estimados GARCH) a fim de se encontrar o modelo e ordem com menor Critério de Avaliação Akaike (AIC) - para cada índice - e assim obter os resíduos padronizados. Na sequência, foram aplicadas cinco técnicas de funções cópulas diferentes (Gaussiana, t de Student, Clayton, Gumbel e Frank) para o conjunto de inovações dos índices (Ver seção 6 – Resultados para os modelos cópulas) para finalmente serem realizadas as interpretações dos resultados e relações de dependências pelo Tau de Kendall.

### 4.1 MÉTODO S-GARCH, E-GARCH, GJR-GARCH, TARCH E APARCH

A primeira equação (Média Condicional) da Tabela 1 representa a média condicional da série  $R_t$  (retornos do Ibovespa), sendo a mesma o produto da volatilidade condicional  $\sigma_t$  e o termo de erro  $e_t$ . O Standard GARCH (S-GARCH) demonstra a variância condicional da série  $\sigma_t^2$  como função da constante  $\alpha_0$ , dos retornos quadrados passados  $R_{t-i}^2$  e da volatilidade condicional quadrada passada  $\sigma_{t-j}^2$ . O modelo GARCH Exponencial (E-GARCH), onde é acrescentado o termo  $\frac{|R_{t-i}| + \delta_i R_{t-i}}{\sigma_{t-i}}$  com o objetivo de adicionar a assimetria na volatilidade condicional.

**Tabela 1** – Modelos S-GARCH, E-GARCH, GJR-GARCH, TARCH e APARCH.

Modelos	Equações
<b>Média Condicional</b>	$R_t = \mu + \varepsilon_t$

<sup>3</sup> Cálculo do log-retorno dos valores de fechamento diário de cada índice.

<sup>4</sup> Base de dados retirada por API (via Python) diretamente do Yahoo Finance! (2023).

**S-GARCH**

$$\sigma_t^2 = \omega_0 + \sum_{i=1}^p \alpha_i e_{t-i}^2 + \sum_{j=1}^q \beta_j \sigma_{t-j}^2$$

**E-GARCH**

$$\ln(\sigma_t^2) = \omega_0 + \sum_{i=1}^p \alpha_i \left| \frac{e_{t-i}}{\sigma_{t-i}} \right| + \sum_{i=1}^p \gamma_i \frac{e_{t-i}}{\sigma_{t-i}} + \sum_{j=1}^q \beta_j \ln(\sigma_{t-j}^2)$$

**GJR-GARCH**

$$\sigma_t^2 = \omega_0 + \sum_{i=1}^p \alpha_i e_{t-i}^2 + \sum_{j=1}^q \beta_j \sigma_{t-j}^2 + \sum_{i=1}^q \gamma_i e_{t-i}^2 d_{t-1}$$

**TARCH**

$$\sigma_t = \omega_0 + \sum_{i=1}^p \alpha_i |e_{t-i}| + \sum_{i=1}^p \gamma_i |e_{t-i}| I_{[e_{t-1} < 0]} + \sum_{j=1}^q \beta_j \sigma_{t-j}$$

**APARCH**

$$\sigma_t^\delta = \omega + \sum_{i=1}^p \alpha_i (|e_{t-i}| - \gamma_i I_{[e_{t-1} > 0]} e_{t-i})^\delta + \sum_{k=1}^q \beta_k \sigma_{t-k}^\delta$$

Fonte: Adaptado de Yamaka e Maneejuk (2020).

Por sua vez, a extensão GJR-GARCH modifica o modelo S-GARCH para capturar o efeito de alavancagem, isto é, a observação de que retornos negativos aumentam a volatilidade futura mais do que retornos positivos. Onde,  $(d_{t-1})$  é uma variável dummy que assume o valor de 1 para retornos negativos.

O modelo *Threshold ARCH* (TARCH), também se destina a capturar a assimetria na volatilidade, permitindo que choques positivos e negativos tenham impactos diferentes sobre a volatilidade. Aqui, similar ao GJR-GARCH,  $(I)$  é uma variável dummy para retornos negativos, mas o termo  $|e_{t-1}|$  permite que o modelo capture diretamente o efeito de choques de magnitude negativa sobre a volatilidade, diferente do GJR-GARCH que se concentra nos retornos quadrados.

Por fim, o APARCH (*Asymmetric Power ARCH*) na última equação, amplia a capacidade de capturar a assimetria e a leptocurtose (caudas mais pesadas que a distribuição normal) na volatilidade dos retornos financeiros, indo além das formulações oferecidas pelos modelos GJR-GARCH e TARCH. Este modelo permite que tanto os choques positivos quanto os negativos afetem a volatilidade de maneira distinta, não apenas pela presença de retornos negativos, mas também pela magnitude dos choques, independente da direção.

#### 4.2 CÓPULA GAUSSIANA, T DE STUDENT, CLAYTON, GUMBEL E FRANK

Ausennegg e Cech (2008) introduziram uma maneira de quantificar a interdependência por meio de cópulas. A técnica de cópula oferece uma maneira de entender a dependência entre diferentes distribuições e pode ser particularmente útil para explorar as relações entre índices de ações globais.

**Tabela 2** – Cópulas, fórmulas e seus respectivos parâmetros de dependência.

Cópula	Fórmula	Parâmetros de Dependência
--------	---------	---------------------------

<b>Gaussiana</b>	$C(u, v) = \Phi_2(\Phi^{-1}(u), \Phi^{-1}(v); \rho)$	$\rho = [-1, 1]$
<b>t de Student</b>	$C(u, v; df, \rho) = T_2(T^{-1}(u; df), T^{-1}(v; df); \rho, df)$	$\rho = [-1, 1]$
<b>Clayton</b>	$C(u, v; \theta) = (u^{-\theta} + v^{-\theta} - 1)^{(-1/\theta)}$	$\theta = [1, \infty]$
<b>Gumbel</b>	$C(u, v; \theta) = \exp[-((-\ln(u))^\theta + (-\ln(v))^\theta)^{(1/\theta)}]$	$\theta = [0, \infty]$
<b>Frank</b>	$C(u, v; \theta) = -1/\theta \ln \left[ \frac{1 + (e^{(-\theta u)} - 1)(e^{(-\theta v)} - 1)}{(e^{(-\theta)} - 1)} \right]$	$\theta = [-\infty, \infty]$

Fonte: Adaptado de Yamaka e Maneejuk (2020).

Na Tabela 2, é apresentada a seleção de cópulas que são frequentemente usadas na modelagem de dependência, juntamente com suas respectivas fórmulas e parâmetros de dependência.

Nas fórmulas acima,  $u$  e  $v$  representam as probabilidades empíricas ou os percentis das respectivas variáveis do trabalho, que neste caso são o Ibovespa e outro índice acionário global. Na Cópula Gaussiana,  $\Phi$  e  $\Phi^{-1}$  são, respectivamente, as funções de distribuição cumulativa e a função inversa de distribuição cumulativa de uma distribuição normal padrão. Aqui,  $\rho$  é o coeficiente de dependência (valores próximos a 1 indicam uma forte correlação positiva, valores próximos a -1 indicam uma forte correlação negativa e valores próximos a zero indicam pouca ou nenhuma relação linear) entre  $u$  e  $v$ .

Na cópula t de Student (semelhante à cópula gaussiana, mas é mais flexível ao modelar a dependência das caudas),  $T$  e  $T^{-1}$  são, respectivamente, as funções de distribuição cumulativa e a função inversa de distribuição cumulativa de uma distribuição t de Student, e  $df$  é o grau de liberdade dessa distribuição. O  $\rho$  aqui também é o coeficiente de dependência.

As cópulas Clayton, Gumbel e Frank (arquimedianas) são particularmente úteis para modelar dependências assimétricas e não lineares, sendo por isso frequentemente usadas em contextos onde as cópulas Gaussiana e t de Student podem ser inadequadas. A cópula de Clayton é assimétrica e modela a dependência na cauda esquerda. Para Nelsen (2006) tal função é caracterizada por um único parâmetro de dependência, representado por  $\theta$  (parâmetro que controla o nível de dependência entre  $u$  e  $v$ ). Valores maiores de  $\theta$  indicam uma maior dependência entre as variáveis.

A cópula de Gumbel também é caracterizada por um único parâmetro de dependência,  $\theta$ . Nesse caso,  $\theta$  deve ser maior ou igual a 1, com valores maiores indicando maior dependência (cauda direita). Por último, a cópula de Frank também é definida por um único parâmetro de dependência,  $\theta$ . Essa cópula é simétrica e não modela a dependência da cauda. O parâmetro  $\theta$  varia de  $-\infty$  a  $\infty$ , e valores maiores em magnitude implicam maior dependência.

Vale ressaltar que, ao usar estas cópulas para modelar a dependência entre o Ibovespa e outros índices acionários globais, é possível capturar a estrutura de dependência entre estes índices, com a ideia de fornecer informações que auxiliem análises financeiras e tomada de decisões com base na interconexão global dos negócios financeiros.

#### 4.3 ANÁLISE DESCRITIVA



A compreensão dos índices de ações é importante pois eles representam uma forma concisa de analisar o desempenho geral de um mercado ou um segmento específico dele. Portanto, na Tabela 3, é apresentada a lista de símbolos dos índices de ações utilizados nos modelos e suas respectivas descrições.

**Tabela 3** – Símbolo e descrição das variáveis utilizadas nos modelos.

<b>Símbolo</b>	<b>Descrição</b>
<b>BVSP</b>	É o índice Ibovespa da Bolsa de Valores de São Paulo (B3), Brasil. Ele é uma medida do desempenho das ações mais líquidas e representativas do mercado brasileiro.
<b>SP500</b>	Refere-se ao índice Standard & Poor's 500 (S&P 500), que é um índice ponderado de 500 das maiores empresas listadas nas bolsas de valores dos Estados Unidos.
<b>DJI</b>	Este é o índice Dow Jones Industrial Average, que é uma medida do desempenho de 30 grandes empresas listadas nas bolsas de valores dos Estados Unidos.
<b>FTSE</b>	O índice Financial Times Stock Exchange 100 (FTSE 100) é uma medida do desempenho das 100 empresas com maior capitalização de mercado listadas na Bolsa de Valores de Londres.
<b>DAX</b>	Refere-se ao índice Deutscher Aktienindex (DAX), que é uma medida do desempenho das 30 maiores empresas listadas na bolsa de valores de Frankfurt, Alemanha.
<b>STOXX50</b>	O índice STOXX Europe 50 é uma medida do desempenho das 50 maiores empresas de super-segmentos do setor na Europa.
<b>NIKKEI</b>	Este é o índice Nikkei 225, que é uma medida do desempenho das 225 maiores empresas listadas na Bolsa de Valores de Tóquio, Japão.
<b>HANGS</b>	O índice Hang Seng é uma medida do desempenho das maiores empresas listadas na Bolsa de Valores de Hong Kong.
<b>SHZN</b>	Este é o índice de Componentes de Shenzhen (SZSE), que é uma medida do desempenho das empresas listadas na Bolsa de Valores de Shenzhen, na China.
<b>MXM</b>	O índice IPC é uma medida do desempenho das ações mais líquidas e representativas listadas na Bolsa Mexicana de Valores.
<b>KOSPI</b>	Este é o índice KOSPI da Bolsa de Valores da Coreia do Sul, que é uma medida do desempenho de todas as empresas comuns listadas na bolsa.

Fonte: Autoria própria.

A Tabela 4 apresenta o Sumário de dados do Índice Bovespa e 10 dos principais índices globais (em log-retorno) onde alguns dados se destacam. As médias dos retornos, por exemplo, indicam o retorno médio diário de cada índice durante o período de estudo. Nota-se que todos os índices apresentam médias positivas, com exceção do HANGS (Índice Hang Seng) e SHZN (Índice de Componentes de Shenzhen), o que sugere um crescimento geral ao longo do período, exceto nesses dois casos. O desvio padrão, por sua vez, fornece uma medida da volatilidade de cada índice. Índices com desvios padrão mais altos, como o BVSP (Ibovespa) e SHZN, tiveram retornos mais voláteis durante o período de estudo, o que implica um nível de risco mais alto.

**Tabela 4** – Sumário de dados do log-retorno do Ibovespa e dos 10 maiores índices globais (2013 até 2023).

	<b>BVSP</b>	<b>SP500</b>	<b>DJI</b>	<b>FTSE</b>	<b>DAX</b>	<b>STOXX50</b>
<b>Amostras</b>	1.952	1.952	1.952	1.952	1.952	1.952
<b>Média</b>	7E-05	0,00061	0,00062	9,5E-05	0,00037	0,0003087
<b>Desvio</b>	0,01591	0,01082	0,0107	0,01005	0,01227	0,012297
<b>Mínimo</b>	-0,1478	-0,0951	-0,0999	-0,1087	-0,1224	-0,124014
<b>25%</b>	-0,0083	-0,0035	-0,0035	-0,0046	-0,0053	-0,005353
<b>50%</b>	0,00013	0,00068	0,00072	0,00052	0,00073	0,0005289
<b>75%</b>	0,0089	0,00537	0,00543	0,00515	0,00652	0,0062013
<b>Máximo</b>	0,13908	0,09383	0,11365	0,09053	0,10976	0,0923622
<b>ADF</b>	0,00001	1E-15	3,5E-17	1,9E-16	0,00001	0,0001

	<b>NIKKEI</b>	<b>HANGS</b>	<b>SHZN</b>	<b>MXX</b>	<b>KOSPI</b>
<b>Amostras</b>	1.952	1.952	1.952	1.952	1.952
<b>Média</b>	0,00049	-0,0002	-1E-05	0,0001	6E-05
<b>Desvio</b>	0,01336	0,01251	0,01592	0,00995	0,00983
<b>Mínimo</b>	-0,0792	-0,0636	-0,0824	-0,0642	-0,0839
<b>25%</b>	-0,0059	-0,0065	-0,0073	-0,0053	-0,0045
<b>50%</b>	0,0007	0,00028	0,00013	7,6E-05	0,00046
<b>75%</b>	0,00719	0,00601	0,0081	0,00566	0,00511
<b>Máximo</b>	0,08038	0,09082	0,05688	0,04269	0,08601
<b>ADF</b>	0,000001	0,0001	6,1E-25	0,0001	2E-23

Nota: ADF representa teste de raiz unitária Augmented Dickey-Fuller e seus p-valores. Onde a hipótese nula é de que a série não é estacionária e a alternativa de que a variável é estacionária.

Fonte: Autoria própria.

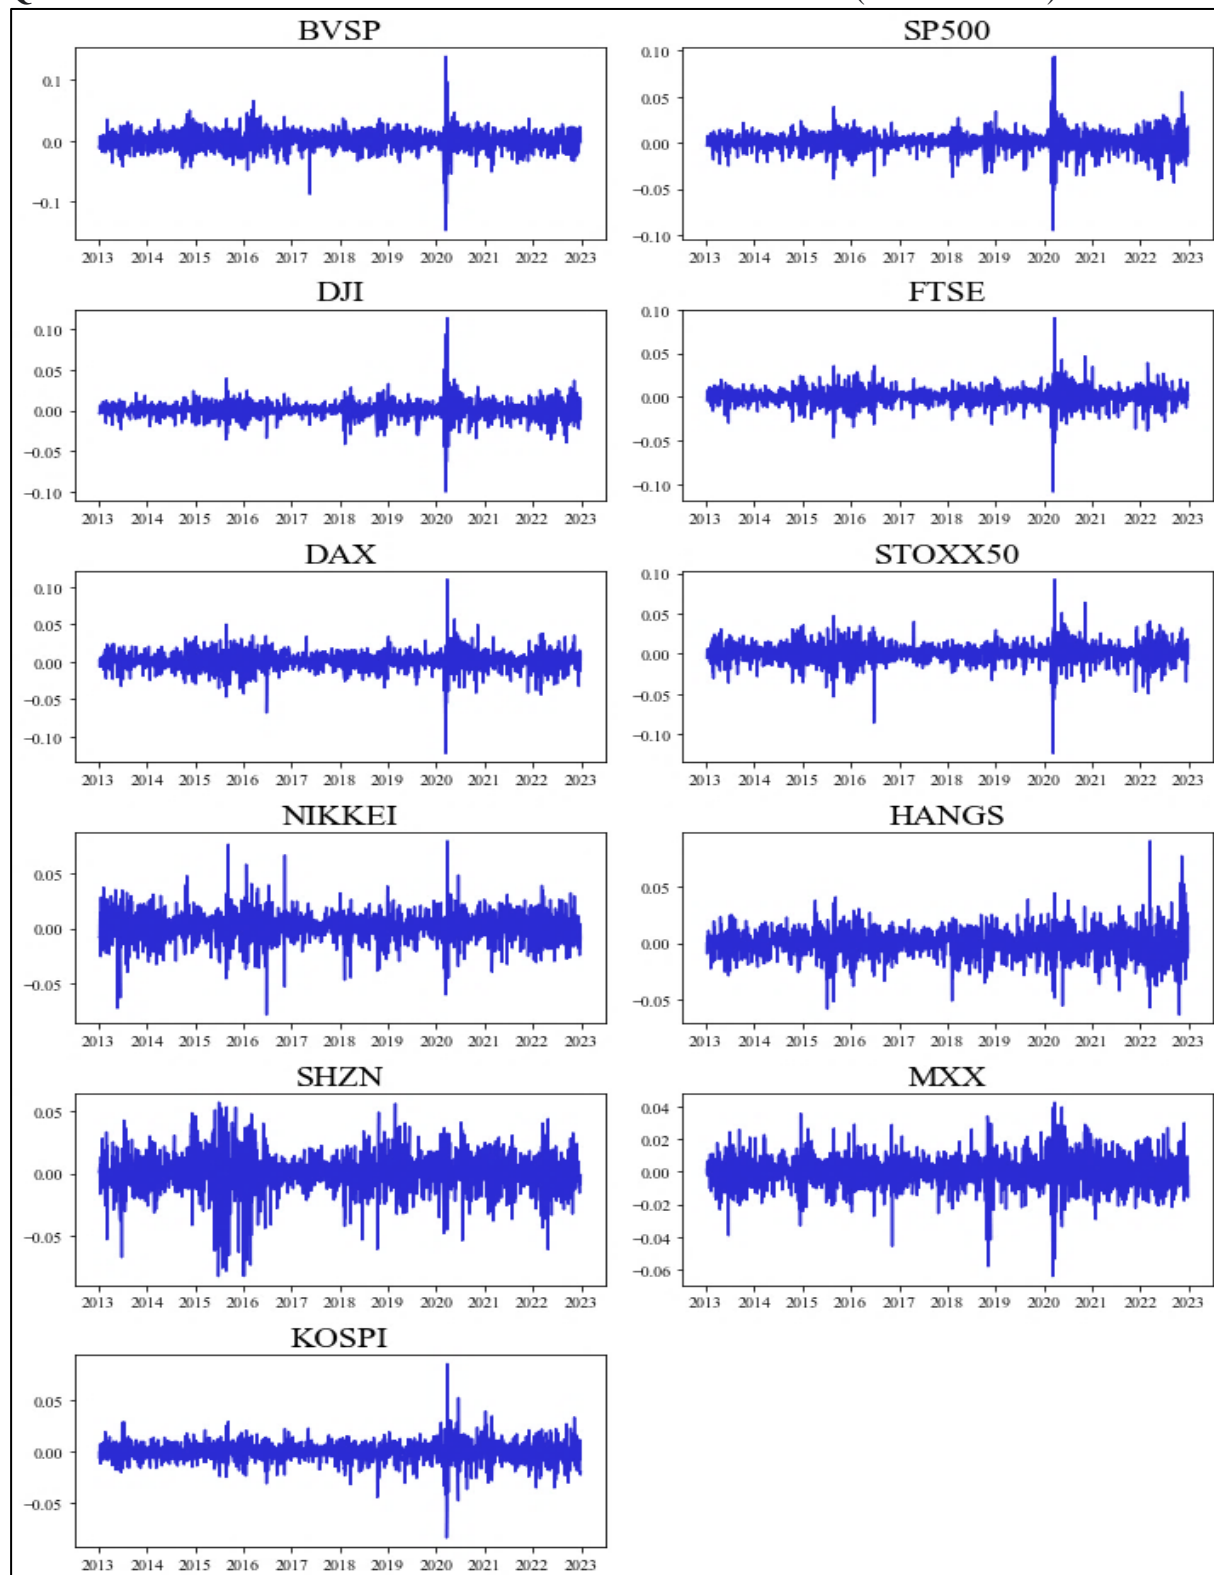
O mínimo e o máximo fornecem informações sobre a variação de retornos durante o período. Por exemplo, o índice FTSE apresentou a maior queda diária (-0,108738) enquanto o índice DJI (Dow Jones) teve a maior subida diária (0,1136504). As quartis de 25%, 50% e 75% nos dão uma ideia da distribuição dos retornos. A mediana (50%) é o valor do meio, com metade dos retornos sendo maiores e metade menores.

Por fim, o Quadro 1 apresenta os gráficos dos retornos diários das variáveis utilizadas no estudo, cobrindo um período de dez anos, de 2013 a 2023. As variáveis representadas incluem índices de mercados desenvolvidos e emergentes, como BVSP (Brasil), SP500 (EUA), DAX (Alemanha), FTSE (Reino Unido), Nikkei (Japão), Hang Seng (Hong Kong), entre outros. Esses gráficos permitem uma análise visual da volatilidade e dos impactos de eventos econômicos globais sobre o comportamento dos mercados. Uma característica comum entre os índices é o aumento acentuado da volatilidade no início de 2020, durante a pandemia de COVID-19, evidenciado por picos negativos e variações mais amplas nos retornos diários. Este aumento da volatilidade reflete o choque global, com mercados como o BVSP, SP500 e DAX apresentando quedas abruptas e recuperações igualmente voláteis, indicando um aumento significativo no risco sistêmico durante o período.

Os índices dos mercados emergentes, como o BVSP e o MXX (México), tendem a exibir oscilações mais pronunciadas, o que é consistente com a maior vulnerabilidade desses mercados a choques externos. Já os índices de mercados mais maduros, como FTSE e SP500, apresentam uma volatilidade relativamente mais controlada após o choque inicial, embora ainda respondam a crises globais de maneira significativa. Esse quadro ressalta a importância de entender as

dinâmicas entre mercados globais, especialmente em momentos de crises, como forma de gestão de risco para investidores e formuladores de políticas econômicas. A interdependência dos mercados globais e a rápida disseminação de choques externos torna imperativo o monitoramento constante dos retornos diários para antecipar possíveis riscos e volatilidades.

**Quadro 1** – Gráficos dos retornos diários das variáveis utilizadas (2013 até 2023).



Fonte: Autoria própria utilizando Python versão 3.10.9.

## 5 RESULTADOS E DISCUSSÕES

Após apresentada a metodologia e a análise descritiva de dados, a presente seção tem o foco nos resultados. Primeiramente dos modelos GARCH (padrão), E-GARCH, GJR-GARCH, TARCH e APARCH (para a extração das inovações ou resíduos das equações estimadas) e na sequência os resultados das funções cópulas estimadas (Gaussiana, t de Student, Clayton, Gumbel e Frank).

### 5.1 RESULTADOS DOS MODELOS GARCH

A Tabela 6 apresenta os melhores modelos GARCHs e seus respectivos resultados. Foram estimados o total de 1.100 modelos<sup>5</sup> GARCHs (Ver “Anexo A” do presente capítulo) a fim de se encontrar o modelo com todos os parâmetros estatisticamente significantes a 10% além do menor valor AIC<sup>6</sup> (critério selecionado) para cada índice. Posterior a isso, foi feita então a extração dos resíduos padronizados das equações selecionadas para se estimar as cópulas (Gaussiana, t-Student, Clayton, Gumbel e Frank).

A análise dos parâmetros estimados para os modelos de volatilidade condicional dos principais índices acionários revela dados significativos sobre a dinâmica dos mercados globais. Utilizando uma abordagem TARCH para o Índice Bovespa (BVSP), SP500, DJI e FTSE, cada um reflete características únicas de volatilidade e tendência dos retornos.

Especificamente, o modelo aplicado ao SP500 e DJI apresenta um retorno médio diário ( $\mu$ ) positivo e estatisticamente significativo, sugerindo uma expectativa de ganhos contínuos nesses mercados. Para o BVSP e o FTSE, esse parâmetro não é aplicável conforme os modelos utilizados. No que tange à volatilidade condicional ( $\omega$ ), todos os índices mostram valores positivos e significativos, exceto para o NIKKEI, que apresenta um valor negativo e significativo. Isso indica uma persistência na volatilidade que varia entre os mercados.

Por outro lado, os Betas demonstram uma relação significativa e duradoura da volatilidade atual com sua própria história, enfatizando a inércia e o efeito de longo prazo dos movimentos passados de mercado na volatilidade futura. Em termos de adequação dos modelos, valores positivos de log-verossimilhança indicam que os modelos TARCH se ajustam bem aos dados de todos os índices. O critério de informação de Akaike (AIC) reforça esse ajuste com valores negativos substanciais. Testes diagnósticos, incluindo Ljung-Box e ARCH-LM, mostram que autocorrelação e heterocedasticidade nos resíduos dos modelos são bem controladas (ausência), o que confirma a robustez dos modelos escolhidos.

Para os demais índices, como DAX, STOXX50, NIKKEI, HANGS, SHZN, MXX e KOSPI, também se observa uma série de comportamentos estatísticos significativos. A constante volatilidade condicional  $\omega$  para o DAX, STOXX50 e NIKKEI ressalta a importância da persistência volátil nesses mercados. Os coeficientes Alpha, embora não uniformemente significativos em todos os índices, em sua maioria indicam a relevância dos choques passados nos retornos futuros. Esses resultados refletem a complexidade e o entrelaçamento dos mercados financeiros internacionais. A volatilidade passada, junto com as respostas a choques anteriores, desempenha um papel crítico no comportamento futuro dos mercados. A aplicação subsequente de funções de cópula nos permitirá desvendar as relações de dependência não linear entre os índices e fornecer uma compreensão mais profunda das

---

<sup>5</sup> Para cada índice foram estimados os modelos GARCHs com combinações de ordem variando de 1 a 3 defasagens temporais.

<sup>6</sup>  $AIC = 2k - 2\ln(L)$ , onde  $k$  é o número de parâmetros e  $L$  é a verossimilhança máxima de acordo com Akaike (1974).

dinâmicas transfronteiriças, essenciais para a gestão de riscos e a formulação de estratégias de investimento.

**Tabela 5** – Resultados dos modelos GARCHs selecionados de acordo com critério AIC para os retornos do Ibovespa e demais índices acionários globais.

Parâmetros	BVSP	SP500	DJI	FTSE	DAX	STOXX50	NIKEI	HANGS	SHZN	MXX	KOSPI
Equação da Média Condicional:											
<b>Mu</b>	-	0.00047*** (0.00017)	0.00031** (0.00015)	-	0.00056** (0.00024)	0.00058** (0.00023)	0.00058** (0.00023)	-	-	-	-
Equação da Volatilidade Condicional:											
<b>Omega</b>	0.00085*** (0.00032)	0.00064*** (0.00016)	0.00055*** (0.00012)	0.00057*** (0.00014)	0.00001*** (0.00001)	0.00003*** (0.00001)	-0.35157** (0.15815)	0.00001*** (0.00001)	0.00001*** (0.00001)	0.00001*** (0.00001)	0.00075** (0.00031)
<b>Alpha (1)</b>	0.04792** (0.02250)	0.08651*** (0.03331)	0.09913*** (0.02627)	0.04344** (0.02035)	0.10000*** (0.00694)	0.15376*** (0.03701)	0.33008*** (0.05903)	0.02101** (0.01017)	0.10000*** (0.00530)	0.05044*** (0.01839)	0.08576*** (0.02245)
<b>Alpha (2)</b>	-	-	-	-	-	-	-0.12058* (0.06781)	-	-	-	-
<b>Beta (1)</b>	0.86610*** (0.03539)	0.79897*** (0.03010)	0.80788*** (0.02394)	0.83536*** (0.02648)	0.88000*** (0.00271)	0.81374*** (0.04662)	0.95867*** (0.01825)	0.90992*** (0.00652)	0.88000*** (0.00691)	0.88006*** (0.00834)	0.81196*** (0.05520)
<b>Gamma (1)</b>	0.09722*** (0.02510)	0.17950*** (0.03931)	0.15360*** (0.03305)	0.17943*** (0.03164)	-	-	-	0.09158*** (0.01101)	-	0.10089*** (0.02067)	0.10596*** (0.03857)
<b>Delta</b>	-	-	-	-	-	1.67539*** (0.08220)	-	-	-	-	-
<b>Modelo</b>	TARCH	TARCH	TARCH	TARCH	GARCH	APGARCH	EGARCH	GJR-GARCH	GARCH	GJR-GARCH	TARCH
<b>Ordem</b>	(1, 1)	(1, 1)	(1, 1)	(1, 1)	(1, 1)	(1, 1)	(2, 1)	(1, 1)	(1, 1)	(1, 1)	(1, 1)
<b>Constante</b>	Não	Sim	Sim	Não	Sim	Sim	Sim	Não	Não	Não	Não
<b>Log-Likelihood</b>	5556.46888	6558.38449	6611.67786	6563.10769	6041.84266	6062.77486	5820.66191	5969.40754	5557.20833	6413.41972	6517.66639
<b>AIC</b>	-11104.93777	-13106.76898	-13213.35572	-13118.21538	-12075.68532	-12115.54972	-11631.32381	-11930.81508	-11108.41665	-12818.83944	-13027.33279
<b>BIC</b>	-11082.63133	-13078.88593	-13185.47267	-13095.90894	-12053.37888	-12087.66667	-11603.44076	-11908.50864	-11091.68682	-12796.53300	-13005.02635
<b>LM (Het.)</b>	0.03754	0.99397	0.94347	0.46240	0.39041	0.58520	0.03703	0.78566	0.91381	0.05747	0.64441
<b>Ljung-Box</b>	0.85248	0.51720	0.46910	0.49843	0.69472	0.84247	0.45115	0.40559	0.46325	0.05886	0.11955

Fonte: Autoria própria utilizando Python versão 3.10.9.



## 5.2 RESULTADOS CÓPULAS

Os resultados da Tabela 6 destacam as diferenças significativas entre os ajustes das cópulas utilizadas para modelar a dependência entre os índices acionários. A cópula t-Student apresenta os menores valores de AIC e BIC, sugerindo que este modelo oferece o melhor ajuste e, conseqüentemente, captura com mais eficácia as caudas pesadas e a dependência de caudas, que são indicativos de um risco de mercado mais pronunciado e a possibilidade de eventos extremos ocorrendo simultaneamente nos índices analisados.

Em contraste, as cópulas Clayton, Gumbel e Frank apresentam valores muito mais altos de AIC e BIC, indicando um ajuste inferior em comparação às cópulas Gaussiana e t-Student. A discrepância sugere que esses modelos são menos apropriados para descrever as complexas estruturas de dependência observadas nos dados.

Em particular, a cópula Gaussiana, embora supere as três últimas em termos de ajuste, ainda é inferior à cópula t-Student, o que pode refletir a inadequação da normalidade para capturar totalmente a dinâmica dos índices acionários, especialmente em condições de mercado extremas. Portanto, com base nos critérios de informação de Akaike e Bayesian, a análise sugere uma preferência clara pela cópula t-Student, que parece ser a mais apropriada para capturar a dependência e o risco sistemático entre os índices acionários no contexto dos modelos GARCH.

**Tabela 6** – Comparação de ajuste das cópulas para a dependências dos índices acionários.

Cópula	AIC	BIC
<i>Gaussiana</i>	-14795,02766	-14488,31412
<i>t-Student</i>	-15061,10755	-14748,81740
<i>Clayton</i>	-5098,01190	-5092,43529
<i>Gumbel</i>	-4418,01055	-4412,43394
<i>Frank</i>	-4470,89301	-4465,31640

Fonte: Autoria própria.

As matrizes apresentadas no Quadro 2 mostram os parâmetros estimados e os valores de Tau de Kendall<sup>7</sup> para a cópula t-Student aplicada aos retornos dos principais índices acionários globais, com ênfase especial na relação do Ibovespa (BVSP) com esses índices. Estes resultados fornecem uma visão quantitativa da dependência entre os índices, permitindo uma análise mais aprofundada sobre como choques de mercado podem ser transmitidos ao Ibovespa devido à sua interconexão com outros mercados.

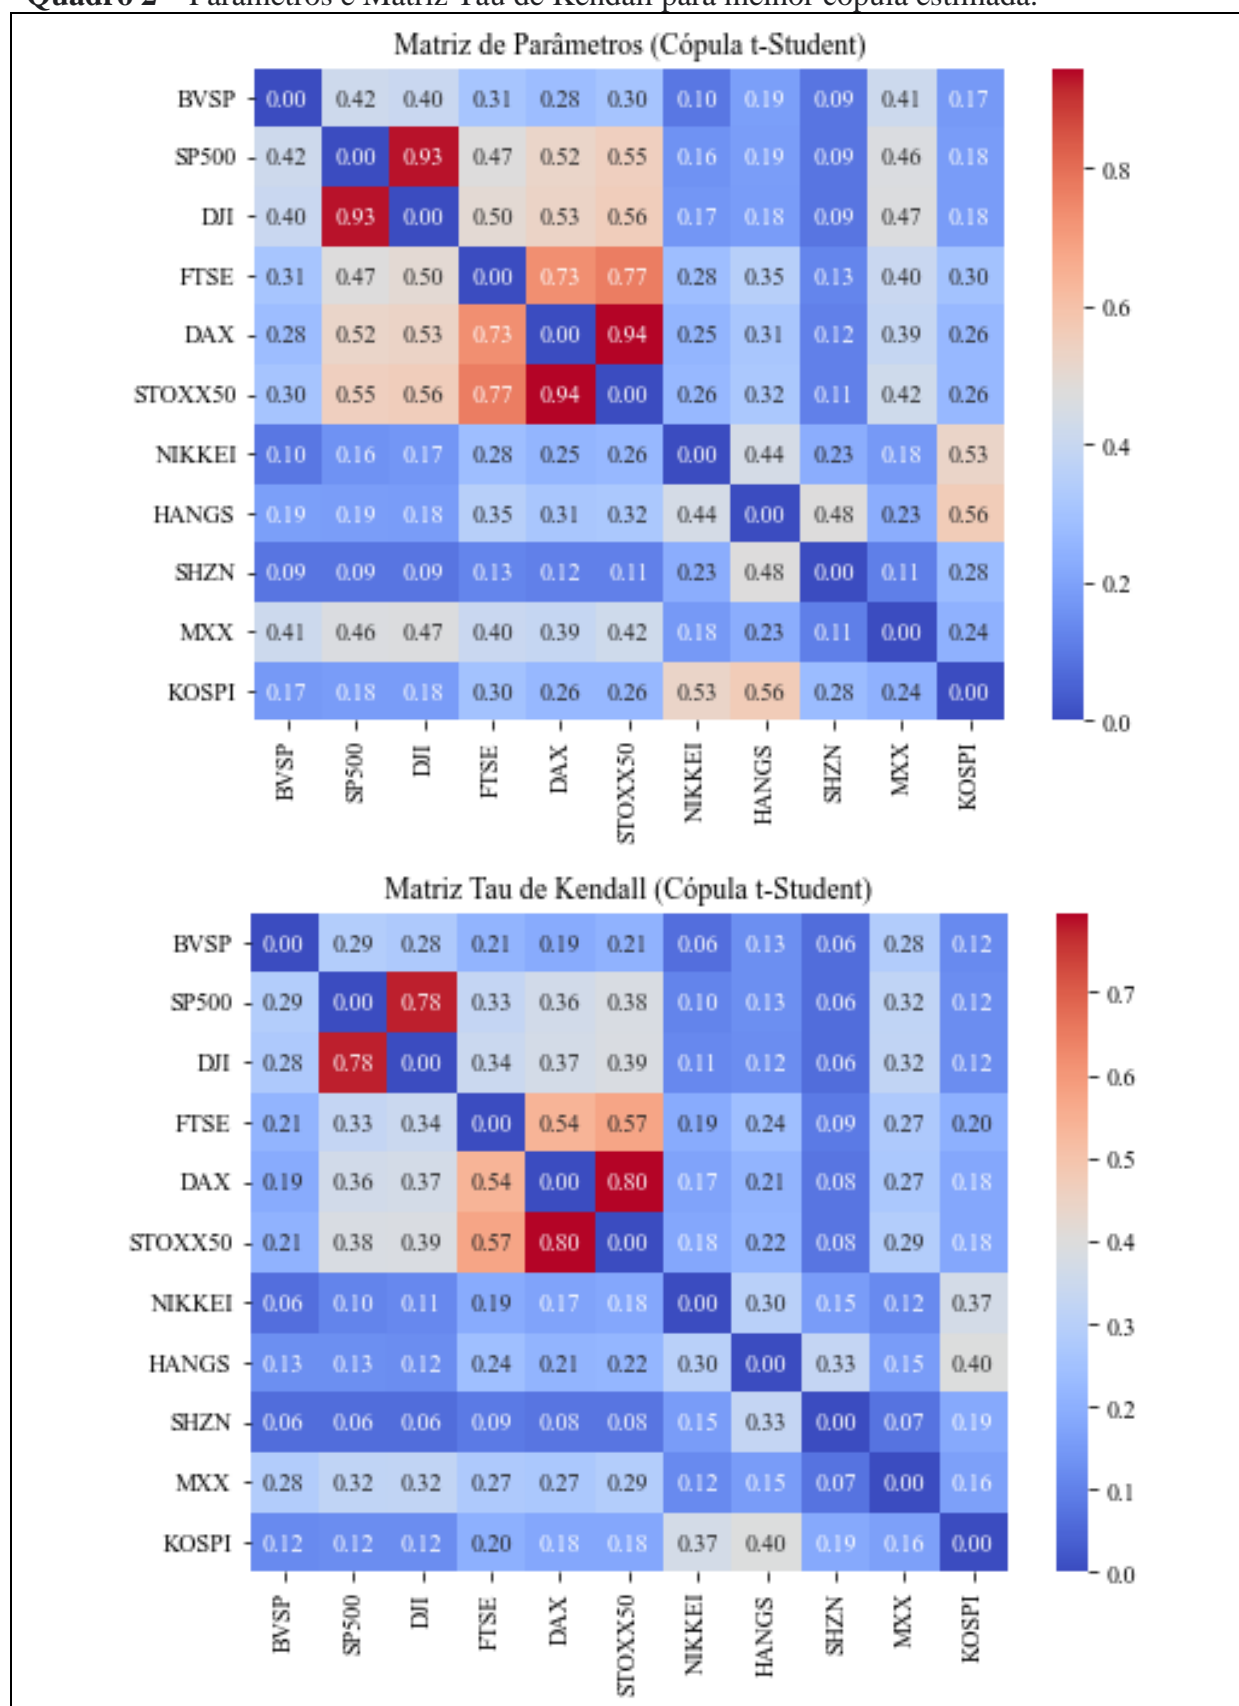
Na primeira matriz, os valores mais elevados na diagonal superior indicam uma forte dependência positiva entre alguns pares de índices, sendo relevante destacar que o Ibovespa tem uma correlação significativa com índices como SP500 (0,42) e DAX (0,28). Isso sugere que eventos nos mercados norte-americanos e europeus podem ter um impacto direto no comportamento do mercado brasileiro, refletindo o nível de integração financeira global que o Brasil compartilha com esses mercados. A segunda matriz, que apresenta o Tau de Kendall, reforça a análise ao medir a força e direção da associação entre os índices (-1 a 1). O Tau de Kendall do Ibovespa com o SP500, por exemplo, é de 0,29, indicando uma correlação positiva

---

<sup>7</sup> De acordo com Yamaka e Maneejuk (2020), o Tau de Kendall é definido pela fórmula:  $\tau = \frac{2}{\pi} \arcsin(\rho)$ , onde  $\rho$  é o coeficiente da cópula t-Student. Esta medida varia entre -1 e 1, onde valores próximos de 1 indicam uma forte associação positiva, valores próximos de -1 indicam uma forte associação negativa, e valores próximos de 0 indicam pouca ou nenhuma associação entre as variáveis.

moderada. Por outro lado, o índice DAX da Alemanha, que também apresenta uma correlação com o Ibovespa, demonstra uma dependência similar (Tau de Kendall de 0,19).

**Quadro 2** – Parâmetros e Matriz Tau de Kendall para melhor cópula estimada.





Os mercados asiáticos, como o NIKKEI, HANGS e SHZN, mostram uma dependência muito baixa em relação ao Ibovespa, sugerindo que esses mercados são movidos por fatores regionais e econômicos distintos, o que pode oferecer oportunidades de diversificação para investidores brasileiros. Por exemplo, o valor do Tau de Kendall entre o Ibovespa e o NIKKEI é apenas 0,10, reforçando a ideia de uma menor sincronização com os mercados asiáticos.

Esses resultados são fundamentais tanto para investidores quanto para formuladores de políticas econômicas no Brasil. Para os investidores, a forte dependência entre o Ibovespa e alguns índices globais, como o SP500 e o DAX, implica em benefícios limitados de diversificação ao investir em mercados com alta correlação. Já para os reguladores, entender essas dependências é essencial para o monitoramento de riscos sistêmicos e a formulação de políticas macroprudenciais eficazes para mitigar o contágio financeiro.

A análise sugere então que, enquanto o mercado brasileiro está fortemente conectado aos mercados dos EUA e Europa, ele ainda mantém certa independência em relação aos mercados asiáticos, o que pode ser explorado como uma estratégia de diversificação.

## **6 CONSIDERAÇÕES FINAIS**

As análises deste estudo evidenciam a influência dos choques externos em mercados desenvolvidos, como os dos Estados Unidos e Europa, e reforçam a necessidade de entender a interdependência financeira entre mercados emergentes, como o brasileiro, e os principais mercados globais. Esse entendimento se torna ainda mais crucial em um cenário econômico globalizado. Através dos modelos S-GARCH, E-GARCH, GJR-GARCH, TARCH e APARCH identificou-se que os retornos dos índices possuem volatilidade condicional variável e que o efeito de alavancagem e assimetrias é uma característica marcante, refletindo a complexidade dos mercados financeiros modernos. Os resultados sugerem que a volatilidade dos índices não é apenas um fenômeno autônomo, mas é influenciada por eventos e volatilidades passadas.

As cópulas Gaussianas e t-Student, ao capturarem as dependências entre os índices, ressaltaram a existência de uma integração significativa dos mercados. A cópula t-Student, com os menores valores de AIC e BIC, mostrou-se particularmente eficaz em modelar a dependência com caudas pesadas, indicando que os índices não estão apenas interligados, mas também são susceptíveis a eventos extremos de forma conjunta.

A análise das matrizes de parâmetros e Tau de Kendall para a cópula t-Student destacou a relação estrutural entre o Ibovespa e os principais índices globais. O Ibovespa, como índice de referência do mercado acionário brasileiro, mostrou uma correlação moderada com os mercados dos EUA, como o SP500 (0,42) e o DJI (0,40), e também com os mercados europeus, como o DAX (0,28) e o FTSE (0,31). Esses resultados refletem a interconexão crescente do Brasil com as principais economias globais, onde choques externos, como mudanças na política monetária dos EUA ou crises financeiras na Europa, podem impactar diretamente o comportamento do Ibovespa.

Por outro lado, a menor correlação do Ibovespa com os mercados asiáticos, como o NIKKEI (0,10) e o HANGS (0,19), indica que o Brasil, embora integrado às economias ocidentais, ainda mantém uma certa independência em relação a algumas regiões do mundo. Isso sugere que os mercados asiáticos podem ser menos influentes sobre o comportamento do Ibovespa, o que pode ser explorado por investidores que buscam diversificar seus portfólios em mercados menos correlacionados com o Brasil.

Do ponto de vista da política econômica, a análise da dependência estrutural entre o Ibovespa e outros mercados globais é de suma importância. A forte conexão com mercados desenvolvidos implica que o Brasil pode ser vulnerável a choques externos, especialmente

aqueles oriundos dos Estados Unidos e da Europa. Reguladores brasileiros, portanto, devem estar atentos às dinâmicas globais e podem considerar a implementação de políticas macroprudenciais que protejam o sistema financeiro nacional contra possíveis contágios globais.

Para investidores, os resultados evidenciam que a dependência do Ibovespa em relação aos mercados ocidentais pode limitar as oportunidades de diversificação em momentos de alta correlação global. No entanto, a menor dependência em relação aos mercados asiáticos, conforme demonstrado pelos baixos valores de Tau de Kendall, sugere que esses mercados podem ser uma alternativa para mitigar riscos em portfólios que incluem ações brasileiras.

Em suma, este estudo visou fornecer uma contribuição relevante ao analisar a dependência estrutural entre o Ibovespa e os principais índices globais. A metodologia GARCH-Cópula mostrou-se eficaz em revelar a complexidade das interações entre o mercado brasileiro e outros mercados financeiros ao redor do mundo.

Com a globalização financeira, é crucial entender como o Ibovespa responde a diferentes estímulos econômicos internacionais, permitindo tanto aos investidores quanto aos formuladores de políticas uma melhor preparação para eventos extremos e crises globais. Pesquisas futuras podem aprofundar essa análise, incorporando mais mercados emergentes e explorando como suas interações com o Ibovespa evoluem ao longo do tempo, especialmente em cenários de instabilidade financeira.

## REFERÊNCIAS

ABHYANKAR, A.; COPELAND, L. S.; WONG, W. Uncovering Nonlinear Structure In Real-Time Stock-Market Indexes: The S&P 500, the DAX, the Nikkei 225, and the FTSE-100. **Journal of Business & Economic Statistics**, 1997.

ACHCAR, J. A.; CEPEDA-CUERVO, E.; BAROSSO-FILHO, M. Multivariate Volatility Models: An Application to Ibovespa and Dow Jones Industrial. **Cuadernos de Economía**, 2012.

AKAIKE, H. A new look at the statistical model identification. **IEEE Transactions on Automatic Control**, v. 19, n. 6, p. 716-723, dez. 1974.

AUSSENEGG, W.; CECHE, C. **Simple Time-Varying Copula Estimation**. Vienna: Vienna University of Technology, 2008.

BORIO, C. Implementing the macroprudential approach to financial regulation and supervision. **The Financial Stability Review**, v. 13, p. 31-41, 2011.

BRONDANI, L. A.; BAGGIO, D. K.; AGUDO, L. F.; SANJUÁN, I. M. Influência do índice Dow Jones industrial average sobre o índice Ibovespa. **Horizontes Empresariales**, 2013.

CHUANG, I. Y.; LU, J. R.; TSWEI, K. Interdependence of international equity variances: Evidence from East Asian markets. **Emerging Markets Review**, 2007.

DICKEY, D. A.; FULLER, W. A. Distribution of the Estimators for Autoregressive Time Series With a Unit Root. **Journal of the American Statistical Association**, 1979.

DROŽDŽ, S.; GRÜMMER, F.; RUF, F.; SPETH, J. Towards identifying the world stock market cross-correlations: DAX versus Dow Jones. **Physica A: Statistical Mechanics and its Applications**, 2001.

EICHENGREEN, B. **Globalizing Capital: A History of the International Monetary System**. Princeton University Press, 1996.

FERREIRA, R. T.; ZACHIS, S. de M. Análise dos Saltos e Co-Saltos nas Séries do IBOVESPA, Dow Jones, Taxa de Juros, Taxa de Câmbio e no Spread do C-Bond. **Revista Economia**, 2012.

GRUBEL, H. G.; FADNER, K. The Interdependence of International Equity Markets. **The Journal of Finance**, v. 26, n. 1, p. 89-94, mar. 1971.

KODRES, L. E.; PRITSKER, M. A rational expectations model of financial contagion. **The Journal of Finance**, v. 57, n. 2, p. 769-799, 2002.

LEONG, S. C.; FELMINGHAM, B. The interdependence of share markets in the developed economies of East Asia. **Pacific-Basin Finance Journal**, 2003.

LOPES, L. P.; PESSANHA, G. R. G. Análise de dependência entre mercados financeiros: uma abordagem do modelo Cópula-GARCH. **Revista de Finanças e Contabilidade da Unimep**, 2017.

NELSEN, R. B. **An introduction to copulas**. New York: Springer Science & Business Media, 2006.

OBSTFELD, M.; TAYLOR, A. M. **Global Capital Markets: Integration, Crisis, and Growth**. Cambridge University Press, 2004.

VARTANIAN, P. R. Impactos do índice Dow Jones, commodities e câmbio sobre o Ibovespa: uma análise do efeito contágio. **Revista de Administração Contemporânea**, 2012.

Yahoo Inc. **Yahoo Finance API**. Disponível em: <https://finance.yahoo.com/quote/API/>. Acesso em: 10 jun. 2023.

YAMAKA, W.; MANEEJUK, P. Analyzing the Causality and Dependence between Gold Shocks and Asian Emerging Stock Markets: A Smooth Transition Copula Approach. **Mathematics**, 2020.

# ANEXO A – TABELA AIC DOS MODELOS ESTIMADOS GARCH

Def.	Ordens	Const.	BVSP (APGARCH)	BVSP (E- GARCH)	BVSP (GARCH)	BVSP (GJR- GARCH)	BVSP (TARCH)	SP500 (APGARCH)	SP500 (E- GARCH)	SP500 (GARCH)	SP500 (GJR- GARCH)	SP500 (TARCH)
(1, 1)	0	1	-11081,24425	-11078,79246	-11089,64803	-11104,0976	-11104,9377	-13032,19729	-13017,27998	-13021,89917	-13049,17437	-13100,87847
	1	1	-11079,44725	-11077,47392	-11088,16854	-11088,67605	-11103,04383	-13042,40463	-13042,26291	-13022,103421	-13071,92767	-13106,76898
	0	1	-11076,79542	-11076,79246	-11072,07228	-11088,40186	-11103,28488	-13004,18574	-13052,27998	-12994,09705	-13051,59798	-13098,87848
(1, 2)	1	1	-11074,58058	-11075,47392	-11070,74059	-11086,89612	-11101,39278	-13017,24172	-13040,26294	-13006,2439	-13045,08082	-13104,76898
	0	1	-11078,22438	-11076,97672	-11080,51588	-11089,57207	-11102,93777	-13016,23628	-13016,603881	-12992,29464	-13039,24231	-13099,62013
	1	1	-11076,67419	-11075,6376	-11086,30946	-11087,58314	-11101,04383	-13027,37989	-13040,76182	-13005,29239	-13048,21684	-13105,15655
(2, 1)	0	1	-11082,23234	-11079,06851	-11083,08149	-11089,66684	-11101,33665	-12998,28241	-13018,85724	-12997,44221	-13048,05406	-13097,62013
	1	1	-11079,00546	-11077,99902	-11081,73353	-11087,69283	-11099,44444	-13010,41918	-13042,37472	-13007,68663	-13055,22497	-13103,15655
	1	1	-11070,69765	-11070,80343	-11061,0501	-11077,98989	-11095,90939	-13035,84815	-13035,18129	-13015,08013	-12807,9359	-13099,6094
(1, 1)	1	1	-11065,95912	-11068,80343	-11063,29076	-11076,63557	-11094,324874	-13011,59468	-13001,47309	-13020,66156	-13033,62523	-13098,04948
	1	1	-11069,62357	-11069,04673	-11064,49476	-11077,74898	-11093,90939	-13020,66156	-13033,62523	-13033,62523	-13041,05226	-13098,04948
	1	1	-11069,7131	-11070,7446	-11072,03913	-11078,11467	-11092,32984	-13003,89326	-13036,29297	-13036,29297	-13048,99087	-13096,04947
(1, 2)	1	1	-11059,96792	-11064,3307	-11049,60786	-11066,98417	-11090,52961	-13025,2598	-13025,50542	-13004,58229	-13077,821948	-13089,98211
	1	1	-11053,73081	-11062,33071	-11059,94013	-11063,91473	-11088,84144	-13000,88725	-13023,50542	-13023,50542	-13028,79118	-13087,98211
	1	1	-11057,5631	-11062,60797	-11057,91515	-11067,31954	-11088,52961	-13010,47309	-13023,99395	-1092,263067	-13031,20613	-13088,46318
(2, 2)	1	1	-11059,87022	-11064,58047	-11065,60618	-11067,19124	-11086,9177	-12993,53341	-13026,35551	-13026,35551	-13038,40104	-13086,46318
	1	1	-11062,96385	-11064,56808	-11052,56766	-11070,99356	-11091,51676	-13023,829	-13024,51316	-13002,40797	-13039,26449	-13089,27617
	1	1	-11058,83462	-11062,56808	-11056,86841	-11073,14533	-11089,83156	-12998,54407	-13022,51316	-83,16380693	-13026,08782	-13087,27617
(2, 1)	1	1	-11061,01914	-11062,76275	-11059,18966	-11071,4225	-11089,51676	-13008,9931	-13020,05893	-12976,62284	-13030,09593	-13087,68946
	1	1	-11063,18641	-11065,39846	-11065,87111	-11070,69895	-11087,8749	-12992,10804	-13022,21024	-7280,998744	-13036,72051	-13085,68946
Def.	Ordens	Const.	DJI (APGARCH)	DJI (E-GARCH)	DJI (GARCH)	DJI (GJR- GARCH)	DJI (TARCH)	FTSE (APGARCH)	FTSE (E- GARCH)	FTSE (GARCH)	FTSE (GJR- GARCH)	FTSE (TARCH)
(1, 1)	0	1	-13142,53569	-13143,79536	-13125,10863	-13172,16022	-13210,32963	-13047,00467	-13040,76394	-13037,90588	-13082,49415	-13118,21538
	1	1	-13155,8651	-13162,29398	-13163,655018	-13151,36423	-13208,32963	-13043,86035	-13039,65377	-13036,58907	-13081,04284	-13117,94225
	0	1	-13117,27111	-13141,79536	-13116,86012	-13151,36423	-13208,32963	-13041,97314	-13039,7509	-13040,82227	-13091,0021	-13075,98952
(1, 2)	1	1	-13129,60769	-13160,29455	-13130,24706	-13158,1696	-13211,35572	-13040,24678	-13038,75119	-13039,40911	-13083,02824	-13120,44552
	0	1	-13097,44623	-13143,69798	-13112,88846	-13180,09184	-13209,88811	-13033,00553	-13039,40538	-13027,27351	-13086,11112	-13116,43179
	1	1	-13141,82464	-13161,96866	-13126,74992	-13169,31663	-13212,8816	-13026,18218	-13038,3533	-13025,72486	-13081,41217	-13116,3241
(2, 1)	0	1	-13113,09739	-13145,94245	-13118,53733	-13162,90236	-13207,88811	-13026,10431	-13037,3288	-13027,25042	-13092,2798	-13121,75171
	1	1	-13124,48705	-13164,07986	-13165,20432	-13168,23062	-13145,33656	-13044,14064	-13036,17499	-13025,60207	-13082,56946	-13121,29712
	1	1	-13142,56009	-13153,05378	-13126,49279	-13169,01429	-13204,21163	-13033,68812	-13029,5778	-13026,59617	-13078,81608	-13109,33491
(1, 1)	1	1	-13118,88897	-13151,07732	-13119,23794	-13148,33844	-13202,21163	-13036,43678	-13028,91002	-13029,23462	-13068,80136	-13112,06275
	1	1	-13126,97252	-13152,65602	-13152,66602	-12832,76183	-13203,66235	-13016,6906	-13028,48336	-13015,74393	-13070,7515	-13107,77693
	1	1	-13110,44603	-13155,15158	-13116,49445	-13156,68753	-13201,66235	-13034,4702	-13022,27602	-13015,56976	-13068,00414	-13112,7067
(1, 2)	1	1	-13131,73759	-13144,06342	-13144,06342	-13144,06342	-13144,06342	-13024,26455	-13022,89213	-13017,78179	-13067,4248	-13101,16065
	1	1	-13106,75738	-13142,06342	-11647,68501	-13137,50111	-13193,02883	-13028,38958	-13022,34149	-13020,68483	-13061,95187	-13104,3002
	1	1	-13116,37978	-13143,60931	-11250,51122	-12427,22284	-13194,42681	-13007,1819	-13021,73703	-13007,05828	-13061,53809	-13099,67712
(2, 2)	1	1	-13099,8654	-13141,92522	-13019,08301	-13146,22489	-13192,42681	-13026,4279	-13020,73791	-13007,15096	-13061,46607	-13105,43234
	1	1	-13137,80803	-13145,62438	-11519,13284	-13196,54823	-13196,54823	-13027,13048	-13024,87451	-13019,99919	-13063,91488	-13102,18332
	1	1	-13111,19892	-13143,62445	-13111,17776	-13140,07676	-13194,54935	-13030,08739	-13024,23471	-13022,29654	-13065,62913	-13104,9638
(2, 1)	1	1	-13123,7755	-13145,22439	-1249,702226	-12498,42642	-13196,00754	-7664,058337	-13023,68795	-13009,22609	-13063,96698	-13100,68908
	1	1	-13106,58782	-13147,44078	-13113,0285	-13150,30138	-13194,00736	-13028,15207	-13021,3916	-13009,31019	-13064,98322	-13106,47201

Nota: i) ‘Def’ são as defasagens utilizadas na variável autorregressiva da equação da média condicional (ARX);  
 ii) ‘Const.’ refere-se a variável binária com “1” sendo para a presença de constante e “0” sem constante;  
 iii) Vale destacar que o algoritmo utilizou o critério de seleção onde todos os parâmetros fossem estatisticamente significativos a pelo menos 10% do nível de confiança.

Fonte: Autoria própria.

Def	Ordens	Const.	DAX (APGARCH)	DAX (E-GARCH)	DAX (GARCH)	DAX (GJR-GARCH)	DAX (TARCH)	STOXX50 (APGARCH)	STOXX50 (E-GARCH)	STOXX50 (GARCH)	STOXX50 (GJR-GARCH)	STOXX50 (TARCH)
(1, 1)	0	-12072,02413	-12065,16751	-12071,46011	-12125,02813	-12148,18428	-12110,62156	-12100,1928	-12098,06057	-12141,65432	-12193,55815	
	1	-12075,70344	-12071,60913	-12075,68532	-12119,14028	-12147,09281	-12115,54972	-12104,94295	-12100,53199	-12142,09513	-12191,72025	
	0	-12073,19731	-12063,16751	-12067,19549	-12112,2967	-12084,29601	-12108,62104	-12098,1928	-12099,02739	-12147,72005	-12178,99653	
	(1, 2)	1	-12081,61997	-12069,60913	-12070,70214	-12113,22938	-12148,77144	-12103,97094	-12102,94295	-12104,5283	-12147,7344	-12192,36405
(0)	0	-12076,59016	-12064,73712	-12064,28129	-12118,7792	-12148,12837	-12109,15273	-12101,51933	-12096,82966	-12144,88132	-12193,18527	
	1	-12067,90704	-12070,47964	-12067,12837	-12100,62027	-12146,74739	-12068,24303	-12105,45209	-12101,34183	-12144,64184	-12191,25372	
	0	-12073,66147	-12062,76709	-12067,27801	-12118,50356	-12153,58239	-12102,40696	-12099,5894	-12099,91902	-12151,08617	-12196,40888	
	(2, 2)	1	-12072,84627	-12068,4845	-12072,05373	-12118,61221	-12152,67922	-12099,42922	-12110,02744	-12103,30898	-12150,40929	-12194,59549
(1, 1)	1	-12066,72966	-12062,75353	-12066,72813	-12110,65865	-12139,29527	-12099,44292	-12095,56596	-12090,83679	-12132,68767	-12183,11221	
	(1, 2)	1	-12067,02237	-12060,75352	-12061,81922	-12104,93498	-12141,13201	-12094,37859	-12093,56596	-12095,04756	-12138,30731	
	(2, 1)	1	-12060,47098	-12061,67281	-12058,30396	-12105,47955	-12138,86974	-12094,22304	-12096,05236	-12091,82168	-12135,19736	
	(2, 2)	1	-12063,93092	-12059,6743	-12063,00058	-12109,99653	-12144,53472	-12102,54974	-12094,07693	-12093,74943	-12140,9301	
(1, 2)	(1, 1)	1	-12058,63683	-12053,93749	-12058,53026	-12102,19432	-12132,30512	-12091,23229	-12088,27001	-12082,57923	-12124,52074	-12175,72722
	(1, 2)	1	-12064,95865	-12053,93749	-12053,6416	-12096,7465	-12134,03408	-12086,57673	-12086,27286	-12087,80485	-12176,32469	
	(2, 1)	1	-12051,00516	-12054,87221	-12049,99682	-12093,91842	-12132,28738	-12088,0493	-12088,81738	-12084,15208	-12175,78321	
	(2, 2)	1	-12055,75653	-12052,87373	-12055,04445	-12101,94491	-12138,42735	-12082,32656	-12086,83479	-12086,07754	-12133,16675	
(2, 2)	(1, 1)	1	-12060,33234	-12057,76465	-12060,16829	-12064,45538	-12133,73258	-12093,30385	-12090,21951	-12084,63985	-12126,57782	-12177,59481
	(1, 2)	1	-12060,46454	-12055,76465	-12055,1463	-12097,99665	-12135,22117	-12089,43468	-12088,21951	-12089,84337	-12132,54851	-12178,12549
	(2, 1)	1	-12066,66407	-12056,6705	-12051,46746	-12101,25198	-12133,81136	-12088,15372	-12090,80074	-12086,25469	-12129,26872	-12177,73993
	(2, 2)	1	-12057,52405	-12054,67436	-12056,95273	-12103,48216	-12140,09693	-12083,69727	-12088,81645	-12088,17053	-12135,21958	-12181,54647
Def	Ordens	Const.	NIKKEI (APGARCH)	NIKKEI (E-GARCH)	NIKKEI (GARCH)	NIKKEI (GJR-GARCH)	NIKKEI (TARCH)	HANGS (APGARCH)	HANGS (E-GARCH)	HANGS (GARCH)	HANGS (GJR-GARCH)	HANGS (TARCH)
(1, 1)	0	-11606,50804	-11621,73477	-11616,70296	-11660,11106	-11645,05331	-11905,96733	-11897,4637	-11899,23282	-11930,81508	-11936,3188	
	1	-11624,36524	-11626,59721	-11608,63082	-11659,69516	-11679,80725	-11894,56954	-11895,7876	-11897,10373	-11928,13306	-11924,58692	
	0	-11610,88332	-11624,3402	-11614,32377	-11662,12773	-11659,09924	-11890,99808	-11895,4637	-11896,11384	-11919,90753	-11934,3188	
	(1, 2)	1	-11611,00772	-11628,37416	-11608,80494	-11664,43797	-11678,55273	-11902,17196	-11893,78761	-11894,39414	-11919,30663	
(0)	0	-11594,87376	-11627,73453	-11604,35793	-11660,39876	-11679,64677	-11897,97178	-11900,05877	-11898,66392	-11928,00795	-11932,58693	
	(2, 1)	1	-11622,36523	-11631,32381	-11602,06788	-11659,37508	-11678,53189	-11903,33506	-11898,39128	-11896,93459	-11926,29328	
	0	-11617,5481	-11625,73453	-11608,36022	-11662,09565	-11684,51952	-11810,33824	-11898,20826	-11900,24109	-11920,22588	-11937,53391	
	(2, 2)	1	-11621,42521	-11629,32381	-11612,84996	-11662,09376	-11683,59797	-11889,48843	-11896,54388	-11898,4964	-11917,20911	
(1, 1)	1	-11618,60772	-11620,33006	-11603,42445	-11651,37083	-11671,54847	-11886,97562	-11885,94295	-11887,84063	-11920,78977	-11924,84939	
	(1, 2)	1	-11602,56309	-11622,14919	-11604,00483	-11649,82716	-11670,23658	-11879,42376	-11883,94298	-11910,93627	-11922,8494	
	(2, 1)	1	-11616,60774	-11623,14452	-11595,3349	-11650,57843	-11670,21783	-11886,92337	-11884,51304	-11887,86274	-11918,6094	
	(2, 2)	1	-11599,48899	-11623,14452	-11607,81276	-11654,78601	-11675,64631	-11880,02298	-11886,65092	-11889,24134	-11908,92186	
(1, 1)	1	-11611,3397	-11612,80342	-11594,8033	-11645,19538	-11660,05216	-11875,87782	-11877,85021	-11876,44212	-11906,96368	-11917,54548	
	(1, 2)	1	-11594,72591	-11614,54063	-11596,24715	-11642,98722	-11664,58037	-11885,05195	-11875,85022	-11872,56315	-11897,10105	
	(2, 1)	1	-11609,33972	-11617,53363	-11587,85963	-11644,2311	-11664,5992	-11876,01476	-11880,51221	-11877,22922	-11905,38487	
	(2, 2)	1	-11608,38148	-11615,53367	-11600,67228	-11647,6178	-11669,09409	-11884,52611	-11878,64032	-11877,72196	-11895,3131	
(1, 1)	1	-11611,00558	-11612,77307	-11593,96329	-11647,32388	-11667,63219	-11874,95658	-11879,64026	-11877,94343	-11906,80201	-11918,78311	
	(1, 2)	1	-11597,97906	-11614,65004	-11594,2848	-11643,46447	-11666,19014	-11869,03992	-11877,61261	-11874,36546	-11897,58789	
	(2, 1)	1	-11609,00557	-11617,60191	-11588,2563	-11646,80096	-11666,36549	-11828,36837	-11882,08767	-11878,09128	-11921,8937	
	(2, 2)	1	-11588,93852	-11615,60191	-11599,12664	-11648,87231	-11670,77667	-11870,65005	-11880,23572	-11879,08658	-11880,50783	

Nota: i) ‘Def’ são as defasagens utilizadas na variável autorregressiva da equação da média condicional (ARX);  
ii) ‘Const.’ refere-se a variável binária com “1” sendo para a presença de constante e “0” sem constante;  
iii) Vale destacar que o algoritmo utilizou o critério de seleção onde todos os parâmetros fossem estatisticamente significativos a pelo menos 10% do nível de confiança.

Fonte: Autoria própria.

Def.	Ordens	Const.	SHZN (APGARCH)	SHZN (E- GARCH)	SHZN (GARCH)	SHZN (GJR- GARCH)	SHZN (TARCH)	MXZ (APGARCH)	MXZ (E- GARCH)	MXZ (GARCH)	MXZ (GJR- GARCH)	MXZ (TARCH)
(1, 1)	0	1	-1104,82199	-11119,12287	-1108,41665	-11113,74019	-11110,2593	-12795,14801	-12798,87103	-12796,48084	-12818,83944	-12806,46313
(1, 1)	1	0	-11105,71874	-11117,14963	-1106,49756	-11102,91039	-11108,26716	-12793,79593	-12797,53082	-12796,75396	-12817,8592	-12821,06269
(1, 2)	0	0	-11113,96916	-11117,12287	-11102,03952	-11100,08942	-11046,19745	-12798,99912	-12797,43266	-12793,00939	-12808,04858	-12821,36231
(1, 2)	1	1	-11073,23069	-11115,15013	-11099,62883	-11098,10723	-11106,26721	-12795,99513	-12796,05062	-12791,87022	-12801,04827	-12819,6331
(0)	0	0	-11103,57429	-11118,30245	-11109,9768	-11110,4918	-11111,10554	-12788,88461	-12797,82663	-12787,91152	-12811,75315	-12818,34204
(2, 1)	1	1	-11105,83204	-11116,33024	-11108,11401	-11105,20253	-11000,95414	-12787,13928	-12796,42153	-12788,22546	-12805,97196	-12819,06269
(2, 2)	0	0	-10934,93309	-11118,71393	-11110,09497	-11109,39993	-11111,95561	-12795,82663	-12795,82663	-12798,39993	-12802,55557	-12819,36232
(2, 2)	1	1	-11114,39464	-11116,72775	-11108,22424	-11107,46792	-11109,96125	-12792,56053	-12794,42153	-12796,64878	-12799,6752	-12817,6331
(1, 1)	1	1	-11093,86807	-11108,26127	-11097,31496	-11093,78701	-11099,11245	-12772,63025	-12792,94464	-12790,88155	-12815,51144	-12815,51144
(1, 2)	1	1	-11086,57087	-11106,26126	-11090,53221	-11089,37485	-11097,11246	-12786,77749	-12791,59322	-12785,63109	-12814,04183	-12813,51131
(2, 1)	1	1	-11092,66212	-11107,44459	-11099,53165	-11096,17247	-11099,95204	-12783,12222	-12792,11033	-12781,38534	-12799,80193	-12813,51131
(2, 2)	1	1	-11105,68504	-11107,86233	-11099,67175	-11098,42136	-11100,85296	-12787,33335	-12789,24676	-12792,1303	-12793,41343	-12812,04183
(1, 1)	1	1	-11087,55811	-11101,82684	-11091,58377	-11087,21876	-11092,93743	-12781,93655	-12788,11643	-12784,42688	-12799,05301	-12809,44602
(1, 2)	1	1	-11075,92749	-11099,82684	-11083,71181	-11082,31659	-11090,9378	-12781,09617	-12786,62623	-12780,77962	-12788,98581	-12807,93151
(2, 1)	1	1	-11086,47031	-11101,22147	-11093,18476	-11090,49771	-11094,02283	-12777,10901	-12787,01739	-12775,36616	-12807,44602	-12805,93151
(2, 2)	1	1	-11099,59276	-11101,61219	-11092,40556	-11091,8025	-11094,78372	-12781,32026	-12785,01739	-12785,90543	-12786,85607	-12805,93151
(1, 1)	1	1	-11089,76322	-11103,78303	-11093,25854	-11089,92968	-11094,88235	-12787,65652	-12782,91178	-12780,42537	-12807,4516	-12804,98366
(1, 2)	1	1	-11079,81549	-11101,78303	-11083,74108	-11084,26094	-11092,88235	-12777,03072	-12781,34734	-12777,56876	-12787,24602	-12803,52168
(2, 1)	1	1	-11089,33173	-11103,19496	-11094,93813	-11092,07177	-11095,9886	-12772,30567	-12781,63659	-12770,92071	-170140,919	-12802,98366
(2, 2)	1	1	-11101,35029	-11103,59475	-11094,55847	-11093,83289	-11096,75398	-12777,19446	-12779,17713	-12781,35232	-12782,94372	-12801,52168
Def.	Ordens	Const.	KOSPI (APGARCH)	KOSPI (E- GARCH)	KOSPI (GARCH)	KOSPI (GJR- GARCH)	KOSPI (TARCH)					
(1, 1)	0	1	-12998,04552	-12996,45484	-12991,79263	-13023,69666	-13027,33279					
(1, 1)	1	1	-12992,16735	-12995,31064	-12992,09718	-13021,80257	-13025,47316					
(1, 2)	0	0	-12988,69195	-12994,81154	-12996,83117	-13023,76738	-13028,50926					
(1, 2)	1	1	-12987,85877	-12993,68992	-12985,50672	-13021,8831	-13026,64042					
(0)	0	0	-12983,1831	-12995,07089	-12986,961	-13024,4665	-13025,34418					
(2, 1)	1	1	-12982,11112	-12993,95641	-12986,49249	-13022,49471	-13023,49138					
(2, 2)	0	0	-12988,74281	-12992,49792	-12990,77905	-13030,79618	-13037,28407					
(2, 2)	1	1	-12994,95559	-12991,30461	-12990,04771	-13025,55372	-13035,35513					
(1, 1)	1	1	-12977,54736	-12985,00659	-12980,5823	-13011,011	-12983,20477					
(1, 2)	1	1	-12972,04614	-12983,4214	-12975,16923	-13011,24394	-13016,70079					
(2, 1)	1	1	-12819,52936	-12983,71481	-12972,27632	-13011,61363	-13013,34131					
(2, 2)	1	1	-12981,1237	-12981,08331	-12976,31655	-13014,99734	-13025,64284					
(1, 1)	1	1	-12970,13299	-12977,51402	-12975,04704	-13004,84482	-13008,88377					
(1, 2)	1	1	-12964,95596	-12976,08545	-12972,18561	-13004,96679	-13010,39325					
(2, 1)	1	1	-12516,31727	-12976,48013	-12964,46953	-13004,9348	-13006,88402					
(2, 2)	1	1	-12961,35455	-12974,48013	-12968,62816	-13008,32006	-13018,12626					
(1, 1)	1	1	-12976,27416	-12979,47948	-12976,44308	-13007,22162	-13010,6259					
(1, 2)	1	1	-12970,57767	-12978,03215	-12973,45637	-13007,57249	-12983,78229					
(2, 1)	1	1	-12965,77047	-12978,40489	-12970,23398	-13007,66886	-13008,6259					
(2, 2)	1	1	-12968,24849	-12976,40489	-12973,94471	-13010,7292	-13019,51654					

Nota: i) ‘Def’ são as defasagens utilizadas na variável autorregressiva da equação da média condicional (ARX);  
 ii) ‘Const.’ refere-se a variável binária com “1” sendo para a presença de constante e “0” sem constante;  
 iii) Vale destacar que o algoritmo utilizou o critério de seleção onde todos os parâmetros fossem estatisticamente significativos a pelo menos 10% do nível de confiança.

Fonte: Autoria própria.





ISBN nº 978-65-01-11585-6

## **BRAZILIAN INDUSTRY AND GLOBAL MARKETS: A NON-LINEAR INTERDEPENDENCE**

Adilson Padovan Junior <sup>1</sup>  
Joilson Giorno <sup>2</sup>

### **Área 3 – Macroeconomia, Economia Monetária, Finanças e Economia Internacional**

**ABSTRACT:** This study aims to investigate the financial interdependence of the Brazilian Industrial Sector (via INDX from B3) and major global indices (USA, Europe, Asia) between 2010 and 2023 (linearly and non-linearly), using correlations (static and dynamic) and Recurrent Neural Networks (RNN) with 480 combinations of hyperparameters, seeking to minimize the Root Mean Square Error (RMSE). Linear correlations revealed a significant and positive relationship between the Brazilian industry and the markets of the USA, Europe, and Asia, with a general increase in correlation during the COVID-19 crisis. Non-linearly, the U.S. index (DJI) stood out, impacting up to 17% of the mean change in individual predictions for the Brazilian Industrial Sector Index (INDX), followed by the European market (STOXX50), representing up to 16% of the forecast variations. The Simple RNN model presented the lowest error (RMSE), underscoring the sensitivity of the Brazilian industry to global shocks, especially in the short term.

**Keywords:** Financial interdependence; INDX; Recurrent Neural Networks; LSTM.

**JEL Code:** G15; F37; C45.

### **1 INTRODUCTION**

The integration of world economies, driven by the globalization of production chains and the interconnection of financial markets, has increased the economic interdependence between nations and productive sectors. As highlighted by Gereffi, Humphrey, and Sturgeon (2006), the fragmentation of production stages across different nations creates greater vulnerability to external shocks, such as supply chain disruptions or fluctuations in major economies, especially in the United States, Europe, and Asia.

Furthermore, as discussed by Baldwin and Lopez-Gonzalez (2014), the growing integration of global production networks increases the exposure of countries to the volatility of international markets, leading to greater dependence on imported components and external capital flows. Additionally, Kasa (1992) argues that global financial markets share a common stochastic trend, implying that fluctuations in one market can inevitably affect others.

Longin and Solnik (2002) emphasize that this is particularly relevant during periods of crisis, when financial interdependence tends to intensify. Dornbusch, Park, and Claessens

---

<sup>1</sup> Doctoral Student in Economics at the Graduate Program in Economic Sciences at the State University of Maringá (PCE/UEM), Maringá, Paraná, Brazil, and CAPES scholarship holder (Coordination for the Improvement of Higher Education Personnel). Email: padovanjr@gmail.com

<sup>2</sup> Ph.D. in Economics from the University of South Carolina, USC, USA, and Professor at the State University of Maringá (PCE/UEM), Maringá, Paraná, Brazil. Email: jgiorno@uem.com



(2000) identify this phenomenon as the contagion effect, which can be understood as a significant increase in market interconnectedness following a shock in one economy or group of economies, spreading the adverse effects of the crisis to other countries. This process can occur through various channels, such as international trade and financial flows.

The idea, then, is that market comovements and international economic shocks, such as financial crises or unexpected events, can impact the Brazilian industrial sector by raising financing costs, increasing production costs, reducing investments, or diminishing international demand.

In this context, the objective of this study is to understand how international market performance affects the financial performance of the Brazilian industry over different periods of time. Specifically, it aims to: (i) analyze the financial interdependence and comovement of the Brazilian industrial sector and the major market indices of the United States, Europe, and Asia; (ii) identify the static and dynamic linear relationship of the indices; (iii) make non-linear forecasts using time lags to capture regressive and autoregressive effects; and (iv) assess the individual effects of external markets on the Brazilian industrial sector.

To this end, this study is organized into five main sections. In addition to the first Introduction section, the second section, Global Value Chain, Interdependence, and Financial Contagion, discusses the theories that explain financial interdependence between global markets, with an emphasis on value chains and financial contagion. The third section presents the data used and the analysis methods, with a focus on Recurrent Neural Networks (RNN) modeling. The fourth section details the main findings from the application of this methodology. Finally, the fifth conclusion section explores the implications of the results and offers suggestions for future research.

## **2 GLOBAL VALUE CHAIN, INTERDEPENDENCE AND FINANCIAL CONTAGION**

The globalization of production and financial markets has led to greater interdependence among economies, a phenomenon that deeply affects strategic sectors in emerging countries like Brazil. As argued by Gereffi, Humphrey, and Sturgeon (2006), the global value chain (GVC) is an international production network that fragments production stages across different countries, creating structural interdependence between economies. In the case of the Brazilian industry, which participates in sectors such as manufacturing, steel, and technology, its integration into such a system makes it vulnerable to external shocks.

This GVC interconnection not only shapes trade relations but also directly affects financial interdependence. According to Baldwin and Lopez-Gonzalez (2014), the growth of trade based on global production networks has transformed the world economy over the past decades. Brazil, by integrating more deeply into these networks, finds itself increasingly exposed to global market volatility. The dependence on imported components, combined with fluctuations in international capital flows, means that shocks in major markets, such as those in the U.S. and Europe, have direct effects on the Brazilian industry.

In this context, Kasa (1992) notes that the financial markets of the United States, Japan, Germany, and Canada share a common stochastic trend, suggesting that fluctuations in one market inevitably affect the others. As if that were not enough, during periods of crisis, this financial interdependence tends to intensify. In this regard, Longin and Solnik (2002) show that correlations between financial markets increase significantly during times of turbulence, especially in bear markets. This happens because, in times of uncertainty, global investors seek to reduce risks by selling assets across different markets simultaneously, which in turn amplifies correlations.

Additionally, Dornbusch, Park, and Claessens (2000) define this increase in correlations during crisis periods as the contagion effect, a phenomenon in which, after a shock in one or more economies, there is a substantial increase in interconnections between markets. This increase tends to spread the negative impacts to other countries, and contagion can manifest through various channels, such as international trade and capital flows.

This is supported by the work of Monte and Defanti (2021), who analyze the dynamic interdependence and volatility transmission between the S&P 500 and Brazilian sectoral indices (IBOVESPA and production sectors) using the GARCH/BEKK methodology. They observed an increase in conditional covariance during "critical events," such as the subprime crisis, particularly in the financial and industrial sectors, suggesting financial contagion.

For the Brazilian industry, this means that the volatility of global markets and sudden shocks in capital flows not only affect available liquidity but also impose significant pressure on its ability to adapt and grow.

Reinhart and Calvo (2000) observe that, in many emerging economies like Brazil, the phenomenon of "sudden stop" often leaves companies without access to cheap financing, forcing them to seek alternative credit sources with less favorable conditions. This not only raises the cost of capital for the industry but also restricts growth and the ability to innovate, which are essential factors for competitiveness in an increasingly dynamic global environment.

On the other hand, Forbes and Rigobon (2002) add an important nuance to the debate on interdependence and contagion. They argue that many of the correlations between markets during crises do not necessarily reflect contagion but rather an already existing structural interdependence. Adjusting for heteroscedasticity, they show that the correlation between markets is constant and that the impacts observed during crises are merely manifestations of this latent interdependence.

In light of these interrelationships, the study of financial interdependence and the comovements of the Brazilian industry is important to understand the vulnerabilities of the sector. Exposure to global shocks, whether financial or commercial, and the way these shocks are transmitted (through value chains or financial markets) can shape the performance of the Brazilian industrial sector. Thus, the next section is dedicated to presenting the data and methodologies that guided this study.

### **3 DATA AND METHODOLOGY**

Given the theoretical foundation, this section describes the data and methodology adopted to investigate the linear and non-linear financial interdependence between the Brazilian Industrial Sector Index (INDX – the companies are listed in Appendix “A”) and the main global indices: Dow Jones (USA), FTSE (UK), EuroStoxx50 (Europe), BSE (India), SSE (China), and Nikkei (Japan). The period analyzed spans from January 2010 to December 2023, using daily data. The returns for INDX were obtained from B3 (2024), and the global indices’ returns were sourced from the Yahoo Finance API (2024).

The descriptive analysis included calculating statistical summaries and static and dynamic correlations (25 steps and 500 sliding windows), allowing us to capture both linear relationships and their variations over time. Following this step, the data were normalized using the min-max scaling technique (0, 1) to ensure comparability between variables and to optimize the performance of the predictive models.

**Table 1** – Description of Hyperparameter Grid.

Hyperparameter	Grid Values	Explanation
RNN types	[SimpleRNN, LSTM]	SimpleRNN for short-term dependencies, LSTM for long-term dependencies.
Lags	[1, 2, 3]	Lags to capture regressive and autoregressive impacts.
Units	[10, 50, 100]	Number of neurons in the hidden layer (captures complex patterns).
Epochs	[10, 50, 100, 150, 200]	Full passes over the dataset (increases risk of overfitting).
Batch sizes	[16, 32, 64, 128]	Number of samples processed before weight updates (smaller batch sizes lead to more variability, larger ones lead to more stable updates).

Source: Adapted from KERAS API (2024).

For the non-linear modeling, the data were first split into training and testing sets in a 70% to 30% ratio, respectively. Next, the algorithm was configured for data cleaning and learning session reinitialization, with a fixed “seed” set to ensure the reproducibility of the experiments and eliminate the random initialization of weights in deep learning. Subsequently, Recurrent Neural Networks (RNN) were applied, with variations in Simple RNN and LSTM, given their ability to capture complex temporal patterns in financial returns. A total of 480 models were estimated with grid combinations (Appendix “B” and “C”) of the hyperparameters (Units, Epochs, and Batch Size), following the variations presented in Table 1, in order to find the combination with the lowest RMSE (Root Mean Square Error).

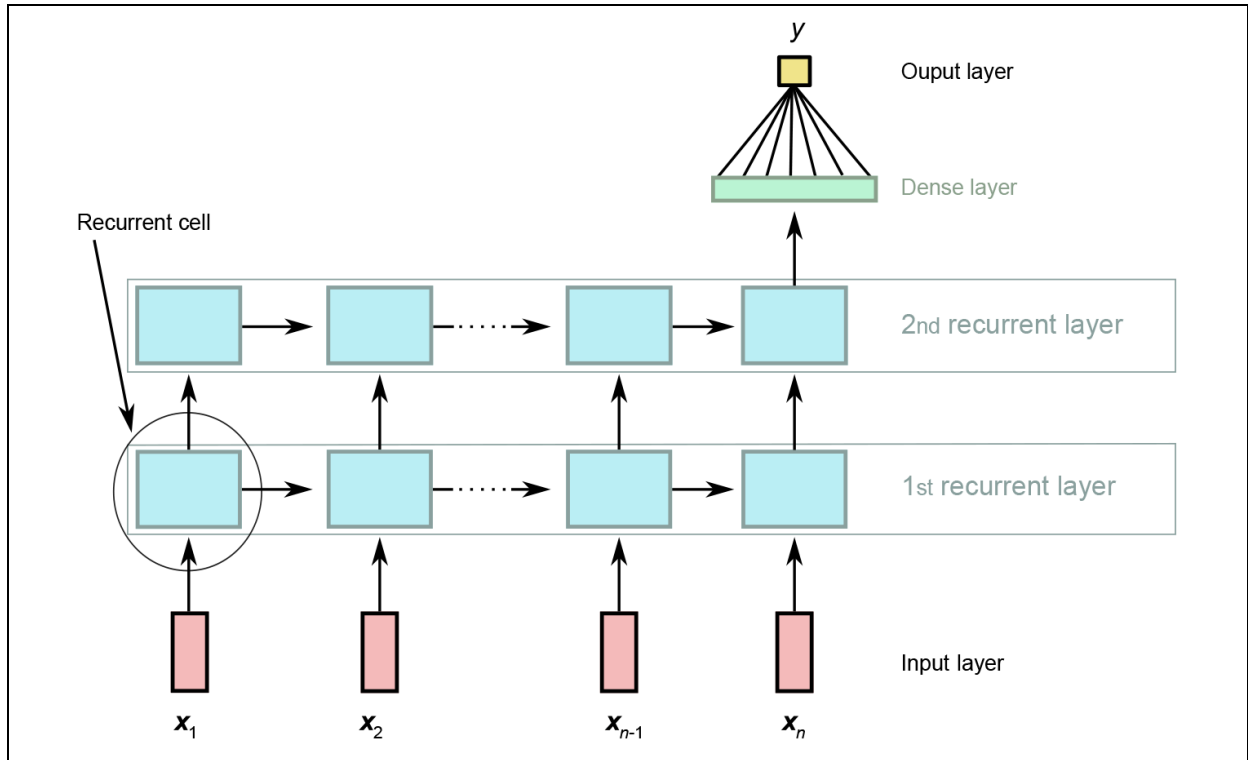
Finally, the validation of the estimated and selected models was carried out based on the predictions and actual values from the training set. Subsequently, sensitivity analysis by substitution was performed to assess the contribution of each global index to individual forecasts, providing an in-depth view of the non-linear relationship between the Brazilian industrial sector and international markets.

### 3.1 RNN METHOD (RECURRENT NEURAL NETWORKS)

Recurrent Neural Networks (RNNs) are a class of neural networks designed to process sequential data, such as time series or textual data. The key advantage of RNNs is their ability to maintain information in their “internal memory,” allowing them to make predictions by considering not only the current data point but also the preceding sequence. This is achieved through loops that allow the output of one neuron to be fed back as input to the next neuron in the time sequence, as demonstrated in Figure 1.

Despite this advantage, RNNs face challenges when learning long-term dependencies due to the vanishing gradient problem during training via backpropagation, as pointed out by Rumelhart, Hinton, and Williams (1986). This issue was later addressed by Hochreiter and Schmidhuber (1997), who proposed the Long Short-Term Memory (LSTM), a variation of RNN capable of handling long-term dependencies more efficiently (See the next subsection – LSTM Method).


**Figure 1** – Recurrent Neural Network (RNN) Architecture.



Source: Adapted from KRATZERT et al., 2018.

To continue, this study begins with the presentation of the Simple RNN, as represented in Figure 2.

**Figure 2** – Simple RNN Cell Structure.



Source: Adapted from KRATZERT et al., 2018.

The hidden state at time  $t$ , denoted as  $h_t$ , is calculated from the current input  $x_t$  and the previous hidden state  $h_{t-1}$ . This can be represented by Equation (1).

$$h_t = \text{ReLU}(W_h \cdot x_t + U_h \cdot h_{t-1} + b_h) \quad (1)$$

Here, the  $\text{ReLU}^3$  (Rectified Linear Unit) activation function is widely used in neural networks due to its simplicity and efficiency.  $W_h$  is the weight matrix associated with the input,  $U_h$  is the weight matrix connecting the previous hidden state to the current state, and  $b_h$  is the

<sup>3</sup> According to Cai, Chen, and Liu (2021), the  $\text{ReLU}$  function is defined as:  $\text{ReLU}(x) = \max(0, x)$ , which means it returns the value of  $x$  if it is positive, and 0 if it is negative.

bias vector. This architecture allows RNNs to effectively process time series, capturing temporal patterns and long-term dependencies in the data. The network's output at time  $t$ , denoted as  $\hat{y}_t$ , is obtained by Equation (2).

$$\hat{y}_t = W_y \cdot h_t + b_y \quad (2)$$

Where  $W_y$  is the weight matrix that connects the hidden state to the output and  $b_y$  is the bias vector associated with the return forecast. The training of the RNN is done by minimizing the loss function, which in this study is the root mean square error (RMSE), given by Equation (3).

$$RMSE = \sqrt{\frac{1}{N} \sum_{t=1}^N (\hat{y}_t - y_t)^2} \quad (3)$$

Where  $\hat{y}_t$  are the values predicted by the network,  $y_t$  are the actual values, and  $N$  is the number of observations. During the empirical process, different configurations of hyperparameters were tested to optimize the model's performance (See Table 1 and Appendices “B” and “C” for more details). The best hyperparameters were selected through cross-validation, comparing RMSE values for different combinations. The Adam optimization algorithm, a variation of the gradient descent method, was used to optimize the weights.


Validation was performed through prediction, where the model was evaluated on unseen data to confirm its generalization capability. Additionally, a sensitivity analysis by substitution was conducted, in which variables were systematically replaced to observe the impact of each on the model's predictive performance. This analysis helped identify which global indices exert the greatest influence on INDX forecasts, providing insights into the interdependence between markets and the robustness of the predictions made.

### 3.2 LSTM METHOD (LONG SHORT-TERM MEMORY)

The Long Short-Term Memory (LSTM) architecture, a more advanced variation of Recurrent Neural Networks (RNN), is used to capture temporal patterns more efficiently. LSTMs were developed to overcome the vanishing or exploding gradient problem, a common limitation in conventional RNNs, according to Hochreiter and Schmidhuber (1997).

With their internal memory structure, they can store and manipulate information over long periods, making them particularly effective for modeling long-term dependencies in financial time series. A cell in this architecture is composed of three main gates: the forget gate, the input gate, and the output gate.

**Figure 3** – LSTM Cell Structure (Long Short-Term Memory).



Source: Adapted from KRATZERT et al., 2018.

These gates regulate the flow of information within the cell and help maintain or update the cell state  $c_t$ , controlling what should be "remembered" or "forgotten" during sequence processing. The forget gate, represented by  $f_t$ , decides which information should be discarded from the previous cell state  $c_{t-1}$ . The equation describing this operation is Equation (4).

$$f_t = \sigma(W_f \cdot x_t + U_f \cdot h_{t-1} + b_f) \quad (4)$$

Where  $W_f$  and  $U_f$  are the weight matrices for the input  $x_t$  and the previous hidden state  $h_{t-1}$ ,  $b_f$  is the bias vector associated with the forget gate, and  $\sigma$  is the sigmoid function that maps values between 0 and 1. The input gate, represented by  $i_t$ , decides which new information will be stored in the cell state. It is defined by two operations: generating a candidate state  $\tilde{c}_t$ , and deciding how much of the new information will be stored. The equations describing this operation are Equations (5) and (6), respectively.

$$i_t = \sigma(W_i \cdot x_t + U_i \cdot h_{t-1} + b_i) \quad (5)$$

$$\tilde{c}_t = \text{ReLU}(W_c \cdot x_t + U_c \cdot h_{t-1} + b_c) \quad (6)$$

Here,  $W_i$ ,  $U_i$ ,  $W_c$ , and  $U_c$  are the weight matrices for the input  $x_t$  and the previous hidden state  $h_{t-1}$ , while  $b_i$  and  $b_c$  are the bias vectors. The cell state  $c_t$  is then updated by considering what will be "forgotten" and what will be "added," as per Equation (7).

$$c_t = f_t \cdot c_{t-1} + i_t \cdot \tilde{c}_t \quad (7)$$

Finally, the output gate, represented by  $o_t$ , decides which part of the cell state will be sent to the next step as the new hidden state  $h_t$ . This is described by Equations (8) and (9), respectively.

$$o_t = \sigma(W_o \cdot x_t + U_o \cdot h_{t-1} + b_o) \quad (8)$$


$$h_t = o_t \cdot \text{ReLU}(c_t) \quad (9)$$

Where  $W_o$  and  $U_o$  are the weight matrices for the input  $x_t$  and the previous hidden state  $h_{t-1}$ , while  $b_o$  is the bias vector associated with the output gate. According to Hochreiter and Schmidhuber (1997), the LSTM architecture is particularly effective at capturing long-term patterns and complex temporal dependencies, which are essential for modeling financial time series, where past information can have a lasting impact on future outcomes. The loss function used in LSTM training is the root mean square error (RMSE), and the optimization is carried out using the Adam algorithm, similar to the procedure used in Simple RNNs.

### 3.3 DESCRIPTIVE ANALYSIS

The descriptive analysis provides an overview of the evolution of major global indices and the B3 Industrial Sector Index (INDX), which reflects the performance of the Brazilian industry. Graph 1 shows the historical evolution of the variables between 2010 and 2023. The INDX displays consistent growth despite interruptions, such as during the COVID-19 crisis, but recovers, demonstrating resilience. Markets like the DJI (USA), BSE (India), and Nikkei (Japan) experienced strong growth, driven by post-pandemic stimulus. In contrast, the FTSE, STOXX50, and SSE exhibited greater fluctuations, reflecting vulnerability to global crises.

**Graph 1** – Evolution of the INDX and Major Market Indices (2010-2023).



Source: Own authorship using Python (version 3.11.9).



Table 2 underscores that the BSE (India) is the most volatile, followed by the DJI (USA), while the FTSE (UK) and STOXX50 (Europe) are more stable. The INDX shows intermediate volatility, typical of emerging markets.


**Table 2** – Data Summary of the B3 Industrial Sector Index and Other Global Indices.

	INDX (Brazil)	DJI (USA)	FTSE (UK)	STOXX50 (Europe)	BSE (India)	SSE (China)	NIKKEI (Japan)
<b>Count</b>	2771	2771	2771	2771	2771	2771	2771
<b>Mean</b>	15209.03	21759.50	6672.47	3277.85	33584.94	2936.52	19151.09
<b>Std.</b>	4781.24	8036.19	731.55	545.77	14953.62	512.96	6931.48
<b>Min.</b>	7701.46	9686.48	4805.80	1995.75	15175.08	1950.01	8160.01
<b>25%</b>	11580.73	15178.69	6037.05	2889.33	20003.28	2575.02	14001.63
<b>50%</b>	13104.54	19911.21	6773.30	3277.79	28832.45	3003.83	19613.28
<b>75%</b>	19327.75	27932.52	7317.45	3599.40	40244.05	3269.42	23471.83
<b>Max.</b>	27626.45	37710.10	8012.50	4549.44	72410.38	5166.35	33753.33

Source: Own authorship using Python (version 3.11.9).

In addition to the analysis, Graph 2 presents a Network Map showing the linear correlations between the INDX (Brazil) and major global indices. Notably, none of the indices analyzed show negative correlations with the INDX, indicating that all these markets share some degree of interdependence, albeit with varying or neutral intensities. The colors of the lines represent the strength of the correlations, with values closer to 1 indicating stronger interdependence.

**Graph 2** – Network Map of Correlations between INDX and Major Global Indices.



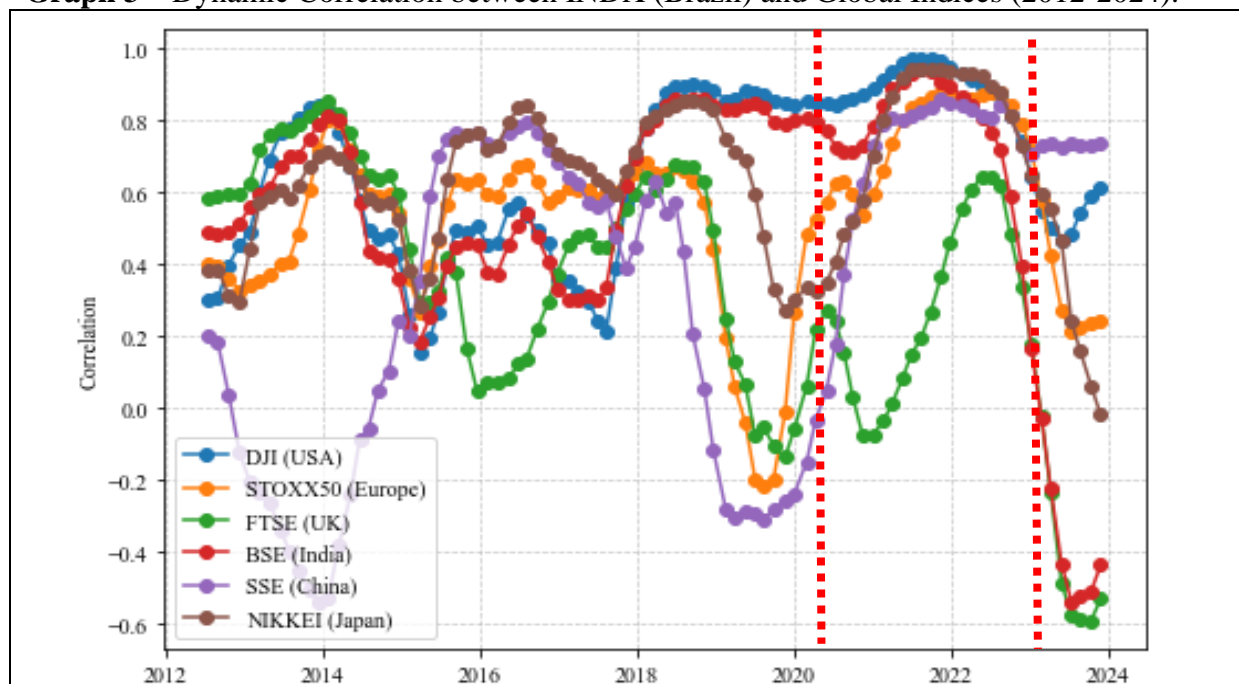
Source: Own authorship using Python (version 3.11.9).

The DJI (USA), Nikkei (Japan), and BSE (India) indices show the highest correlations with the INDX (Brazil), with coefficients of 0.95, 0.90, and 0.90, respectively. The high correlation with the DJI reflects the strong influence of the U.S. economy on the Brazilian market, especially in sectors sensitive to American demand. The relationship with the Nikkei highlights the interconnectedness of global production chains, while the high correlation with the BSE is attributed to similarities between emerging markets.

The STOXX50 (Europe) also shows a significant correlation (0.81), reflecting the connection between Brazil and eurozone economies. In contrast, the FTSE (UK) and SSE (China) display lower correlations (0.61 and 0.53, respectively), possibly due to less trade integration and internal factors in those markets. These results suggest that the markets of the U.S., Europe, India, and Japan have strong interdependence with Brazil, while the UK and China operate with less synchronization.

It is important to note that static correlations provide an aggregate view of the relationships between markets but do not capture their variations over time. With this in mind, Graph 3, showing dynamic correlations, demonstrates how the interrelations between the INDX and major global indices evolve, underscoring changes over periods and the joint response to events such as the COVID-19 pandemic.

**Graph 3 – Dynamic Correlation between INDX (Brazil) and Global Indices (2012-2024).**



Note: For the technique of steps and rolling windows, 500 samples and 25 steps were used.

Source: Own authorship using Python (version 3.11.9).

Between 2013 and 2020, the chart reveals fluctuations in correlations, particularly during 2015-2016 when the correlations between the INDX and the DJI (USA) and Nikkei (Japan) indices exceeded 0.8. This behavior reflects the impact of U.S. economic stimulus policies after the 2008 crisis, which increased global liquidity and benefited emerging markets like Brazil. During the 2020 pandemic, there was a sharp increase in correlations, especially between the INDX and the DJI, Nikkei, STOXX50 (Europe), and BSE (India) indices, which approached 1. This indicates a homogeneous reaction of the markets to the global COVID-19 shock, affecting economies similarly.

After 2023, correlations begin to decrease for most indices, except for the SSE (China), which maintained more volatile and sometimes negative behavior due to China's autonomous

economic policies. The EUROSTOXX and FTSE also showed a reduction in correlations post-pandemic, reflecting uneven economic recoveries between regions and internal factors such as fiscal policies. The analysis shows that the Brazilian industry is highly interdependent with markets like the DJI, Nikkei, and STOXX50, being highly sensitive to international fluctuations, especially during times of crisis, as seen in 2020.

#### 4 RNN RESULTS (SIMPLE RNN AND LSTM)

After the descriptive analysis, the application of nonlinear models, such as Simple RNN and LSTM, allows us to capture the complex relationships between these markets and the performance of the Brazilian industry. The sensitivity analysis by substitution provides important insights into the average magnitude of changes in the predicted values of the INDX in response to small variations in global indices.

Table 5 summarizes the sensitivity coefficients from the Simple RNN and LSTM models (best estimated models based on the lowest RMSE from a hyperparameter grid), which indicate the average change in individual INDX (Brazil) predictions when replacing the values of major global indices with zero. Since the coefficients are estimated based on the data scale, we can interpret the results as changes in INDX predictions when the impact of global indices is removed.

**Table 5** – Results of Simple RNN and LSTM Models with the Lowest RMSE.

Models	Simple RNN	LSTM
Sensitivity Analysis (Features)		
DJI (USA) (0)	0.16423 (0.00091)	0.17057 (0.00099)
DJI (USA) (1)	0.14773 (0.00082)	0.11960 (0.00071)
STOXX50 (Europe) (0)	0.13946 (0.00115)	0.06020 (0.00046)
STOXX50 (Europe) (1)	0.16455 (0.00103)	0.04290 (0.00048)
FTSE (UK) (0)	0.06478 (0.00036)	0.04068 (0.00041)
FTSE (UK) (1)	0.03218 (0.00032)	0.03063 (0.00038)
NIKKEI (Japan) (0)	0.00953 (0.00015)	0.02399 (0.00019)
NIKKEI (Japan) (1)	0.01077 (0.00007)	0.02189 (0.00022)
SSE (China) (0)	0.01699 (0.00014)	0.00371 (0.00005)
SSE (China) (1)	0.02245 (0.00017)	0.00434 (0.00009)
BSE (India) (0)	0.09994 (0.00127)	0.01523 (0.00025)

<b>BSE (India) (1)</b>	0.09191 (0.00087)	0.01510 (0.00017)
<b>INDX (Brazil) (1)</b>	0.61393 (0.00485)	0.53287 (0.00470)

<b>Best Hyperparameters</b>		
<b>Lag</b>	1	1
<b>Units</b>	10	100
<b>Epochs</b>	200	200
<b>Batch Size</b>	16	16
<b>RMSE</b>	0.01594	0.01692

Note: i) The numbers in parentheses represent the standard errors associated with each coefficient estimator;  
ii) The Simple RNN and LSTM models were compared using sensitivity analysis to assess the impact of different indices on the INDX;  
iii) RMSE (Root Mean Squared Error) is used as the model performance criterion, with lower values indicating a better fit;  
iv) The number of units (neurons) and epochs were adjusted to optimize the predictive performance of each model;  
v) A 1-period lag was incorporated to capture temporal effects on INDX returns.

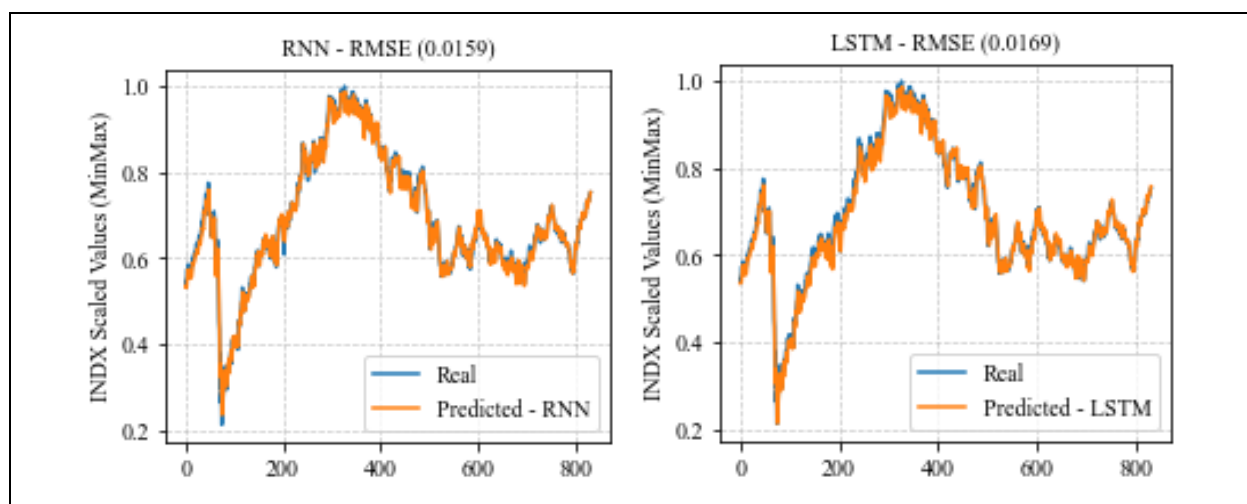
Source: Own authorship using Python (version 3.11.9).


The sensitivity analysis revealed that the DJI (USA) index has the greatest influence on the INDX, resulting in variations of 16.42% in the Simple RNN and 17.06% in the LSTM when its impact is removed. This result highlights the strong connection between the U.S. economy and the Brazilian industrial sector, due to the relevance of exports and the influence of U.S. monetary policies on capital flows to emerging markets.

Furthermore, the STOXX50 (Europe) index also showed a relevant impact, especially in the Simple RNN model, with a lagged effect of 16.45%. However, in the LSTM model, the impact was smaller, suggesting that Europe's short-term effect is more pronounced. Indices such as the FTSE (UK), NIKKEI (Japan), and SSE (China) showed less influence on the INDX, with the SSE having the lowest impact in the LSTM model (0.37%).

The statistical performance of the models, based on RMSE, showed that Simple RNN achieved a slightly better value (0.01594) compared to LSTM (0.01692), suggesting that Simple RNN is more effective in capturing short-term fluctuations, while LSTM performs better in smoothing predictions over time.

**Graph 4 – Forecasts and Average Changes of the Simple RNN and LSTM Models.**





Source: Own authorship using Python (version 3.11.9).

Therefore, following this analysis, Graph 4 presents the forecasts generated by both models and the sensitivity of the independent variables, allowing for graphical validation based on a comparison between the predictions and actual values. In the upper graphs, it is possible to observe that both models closely follow the trajectory of the real series. Simple RNN seems to capture abrupt swings better, while LSTM tends to smooth movements during periods of greater volatility.

In the lower part, the bar charts of the sensitivity analysis confirm the conclusions from Table 5, showing that the DJI (USA) is the most impactful variable in both models, right after the lagged industrial sector index itself, reinforcing the autoregressive effects of sequential data.

## 6 CONCLUSIONS

This study investigated the financial interdependence between the B3 Industrial Sector Index (INDX) and major global indices, employing linear correlations and Recurrent Neural Network (RNN) models such as Simple RNN and LSTM to capture both linear and nonlinear relationships. The linear analysis revealed that the INDX has a strong interdependence with the markets of the U.S. (DJI) and Japan (Nikkei), especially during crises such as the COVID-19 pandemic, when correlations reached nearly 1. This behavior suggests that global shocks in these markets have a rapid impact on Brazil, reflecting a strong economic connection through agent expectations, capital flows, exports, and global monetary policies.

On the other hand, the STOXX50 (Europe) and BSE (India) also showed some integration, while the SSE (China) had weaker and more volatile correlations, which can be explained by Brazil's lower financial integration with China despite significant trade relations. This suggests that Brazil is more exposed to financial markets in developed economies and less

influenced by variations in Asian markets, such as China, possibly due to the distinct structure of China's economy and policy.

The nonlinear analysis, conducted with RNN and LSTM models, captured the complex dynamics of INDX with global markets, confirming that the DJI (USA) was the most impactful variable in INDX predictions. The model performance was robust, with Simple RNN slightly outperforming LSTM in predicting abrupt swings, while LSTM proved more efficient in periods of greater volatility. The superiority of Simple RNN in capturing oscillations may be related to its simple architecture, which better captures short-term rapid changes, while LSTM, with its ability to retain longer-term memories, was useful in smoothing long-term fluctuations.

The results indicate that the Brazilian industrial sector is highly sensitive to global market conditions, and the intensity of these relationships varies according to the international economic context. The prominence of the U.S. can be explained by Brazil's strong dependence on trade and financial flows with this economy. Monetary policies, economic crises, and external shocks in the U.S. market, for example, directly affect Brazil through its exposure to foreign capital and investment flows. On the other hand, the weak correlation with China reflects a lower financial integration between the two countries, despite significant trade relations, which are largely based on commodity exports rather than Brazil's industrial sector.

In summary, the study confirms the strong interdependence between the INDX and global markets, with the U.S. as the largest influencer, underscoring the need for constant monitoring of global economic conditions to anticipate the behavior of the Brazilian industrial sector, especially during times of crisis. The combination of linear correlations and artificial intelligence techniques, such as neural networks, proved effective in capturing these interdependencies, providing valuable information for forecasting the performance of the INDX.

## REFERENCES

**B3. Industrial Sector Index (INDX B3).** Available at: [https://www.b3.com.br/en\\_us/market-data-and-indices/indices/segment-and-sector-indices/industrial-sector-index-indx-b3.htm](https://www.b3.com.br/en_us/market-data-and-indices/indices/segment-and-sector-indices/industrial-sector-index-indx-b3.htm). Accessed on: May 10, 2024.

BALDWIN, Richard; LOPEZ-GONZALEZ, Javier. Supply-chain Trade: A Portrait of Global Patterns and Several Testable Hypotheses. **The World Economy**, v. 37, n. 1, p. 168–182, 2014.

CAI, Zhiqiang; CHEN, Jingshuang; LIU, Min. Least-squares ReLU neural network (LSNN) method for linear advection-reaction equation. **Journal of Computational Physics**, v. 443, p. 110514, 2021.

DORNBUSCH, Rudiger; PARK, Yung Chul; CLAESSENS, Stijn. Contagion: Understanding how it spreads. **The World Bank Research Observer**, v. 15, n. 2, p. 177-197, 2000.

CALVO, Guillermo; REINHART, Carmen. When Capital Inflows Come to a Sudden Stop: Consequences and Policy Options. In: KENEN, Peter; SWOBODA, Alexander. (Ed.). **Reforming the International Monetary and Financial System**. Washington, DC: International Monetary Fund, 2000. p. 175-201.

FORBES, Kristin J.; RIGOBON, Roberto. No Contagion, Only Interdependence: Measuring Stock Market Comovements. **The Journal of Finance**, v. 57, n. 5, p. 2223-2261, 2002.

GEREFFI, Gary; HUMPHREY, John; STURGEON, Timothy. The governance of global value chains. **Review of International Political Economy**, v. 12, n. 1, p. 78–104, 2006.

HOCHREITER, Sepp; SCHMIDHUBER, Jürgen. Long short-term memory. **Neural Computation**, v. 9, n. 8, p. 1735-1780, 1997.

KASA, Kenneth. Common stochastic trends in international stock markets. **Journal of Monetary Economics**, v. 29, n. 1, p. 95-124, 1992.

KERAS API. **Keras 3 API Documentation (versão 3.5.0)**. Available at: <https://keras.io/api/>. Accessed on: June 4, 2024.

KRATZERT, Frederik; KLOTZ, Daniel; BRENNER, Claire; SCHULZ, Karsten; HERRNEGGER, Mathew. Rainfall–runoff modelling using Long Short-Term Memory (LSTM) networks. **Institute of Water Management, Hydrology and Hydraulic Engineering, University of Natural Resources and Life Sciences**, Vienna, 1190, Austria, 2018.

LONGIN, François; SOLNIK, Bruno. Extreme Correlation of International Equity Markets. **Journal of Finance**, v. 57, n. 2, p. 649–676, 2002.

MONTE, Edson Z.; DEFANTI, Lucas B.. Dynamic interdependence and volatility transmission from the American to the Brazilian stock market. EERI Research Paper Series, No. 09/2021. **Economics and Econometrics Research Institute (EERI)**, Brussels, 2021.



PEARSON, Karl. Mathematical Contributions to the Theory of Evolution. II. Regression, Heredity, and Panmixia. **Philosophical Transactions of the Royal Society of London A: Mathematical, Physical and Engineering Sciences**, v. 187, p. 253–318, 1896.

RODGERS, J. L.; NICEWANDER, W. A. Thirteen ways to look at the correlation coefficient. **The American Statistician**, v. 42, n. 1, p. 59–66, 1988.

RUMELHART, David E.; HINTON, Geoffrey E.; WILLIAMS, Ronald J. Learning representations by back-propagating errors. **Nature**, v. 323, p. 533-536, 1986.

YAHOO FINANCE. **Yahoo Finance Data API Python**. Available at: <https://finance.yahoo.com/>. Accessed on: May 10, 2024.

**APPENDIX A – COMPOSITION OF THE INDUSTRIAL SECTOR INDEX (INDX/B3-2024)**

<b>Code</b>	<b>Stock</b>	<b>Theoretical Quantity</b>	<b>Part. (%)</b>
ABEV3	AMBEV S/A	4,394,835,131	13.735
ALPA4	ALPARGATAS	166,460,180	0.311
ARML3	ARMAC	171,598,756	0.361
BEEF3	MINERVA	261,359,935	0.476
BRFS3	BRF SA	814,523,002	5.192
BRKM5	BRASKEM	265,388,400	1.163
CAML3	CAMIL	94,602,711	0.219
CSNA3	SID NACIONAL	736,268,400	2.122
CURY3	CURY S/A	133,117,425	0.771
CYRE3	CYRELA REALT	264,710,610	1.404
DIRR3	DIRECIONAL	109,826,474	0.772
DXCO3	DEXCO	301,760,723	0.602
EMBR3	EMBRAER	734,632,601	8.36
EZTC3	EZTEC	97,334,950	0.333
GFS3	GAFISA	89,278,305	0.057
GGBR4	GERDAU	1,242,683,687	5.526
GOAU4	GERDAU MET	661,577,619	1.687
GRND3	GRENDENE	268,102,086	0.391
INTB3	INTELBRAS	114,286,318	0.612
JBSS3	JBS	1,142,696,472	9.719
JHSF3	JHSF PART	292,921,855	0.311
KEPL3	KEPLER WEBER	176,208,413	0.478
KLBN11	KLABIN S/A	765,785,673	4.018
LEVE3	METAL LEVE	52,865,876	0.412
MDIA3	M.DIASBRANCO	66,385,773	0.438
MILS3	MILLS	172,574,701	0.462
MLAS3	MULTILASER	390,582,824	0.177
MRFG3	MARFRIG	302,019,876	1.069
MRVE3	MRV	375,335,828	0.681
MYPK3	IOCHP-MAXION	130,223,270	0.366
NTCO3	GRUPO NATURA	849,350,756	2.797
PLPL3	PLANOEPLANO	54,711,991	0.160
POMO4	MARCOPOLO	666,378,439	1.19
POS13	POSITIVO TEC	72,053,803	0.114
RANI3	IRANI	106,179,855	0.206
RAPT4	RANDON PART	176,650,127	0.473
SMT03	SAO MARTINHO	142,348,116	0.959
SUZB3	SUZANO S.A.	630,821,784	8.432
TEND3	TENDA	121,480,372	0.396
TUPY3	TUPY	143,716,238	0.956
UNIP6	UNIPAR	51,110,394	0.587
USIM5	USIMINAS	515,193,199	0.780

VIVA3	VIVARA S.A.	125,823,025	0.808
VULC3	VULCABRAS	96,358,247	0.414
WEGE3	WEG	1,482,105,837	19.504
<b>Total Theoretical Quantity</b>		20,024,230,057	100

Source: Adapted from B3 (2024).

## APPENDIX B – SIMPLE RNN MODELS ESTIMATED

Model	Lag	Units	Epochs	Batch Size	RMSE	Lag	Units	Epochs	Batch Size	RMSE
RNN	0	10	10	16	0.17996	2	10	10	16	0.10992
RNN	0	10	10	32	0.18808	2	10	10	32	0.21357
RNN	0	10	10	64	0.19375	2	10	10	64	0.22136
RNN	0	10	10	128	0.19478	2	10	10	128	0.21589
RNN	0	10	50	16	0.16386	2	10	50	16	0.02446
RNN	0	10	50	32	0.16397	2	10	50	32	0.04182
RNN	0	10	50	64	0.16926	2	10	50	64	0.08242
RNN	0	10	50	128	0.18126	2	10	50	128	0.18876
RNN	0	10	100	16	0.17084	2	10	100	16	0.02350
RNN	0	10	100	32	0.16382	2	10	100	32	0.02866
RNN	0	10	100	64	0.15800	2	10	100	64	0.03552
RNN	0	10	100	128	0.16906	2	10	100	128	0.08044
RNN	0	10	150	16	0.17873	2	10	150	16	0.02323
RNN	0	10	150	32	0.16753	2	10	150	32	0.02457
RNN	0	10	150	64	0.15914	2	10	150	64	0.02937
RNN	0	10	150	128	0.16312	2	10	150	128	0.04758
RNN	0	10	200	16	0.18043	2	10	200	16	0.02315
RNN	0	10	200	32	0.16932	2	10	200	32	0.02377
RNN	0	10	200	64	0.16233	2	10	200	64	0.02809
RNN	0	10	200	128	0.16016	2	10	200	128	0.03288
RNN	0	50	10	16	0.12039	2	50	10	16	0.04205
RNN	0	50	10	32	0.13771	2	50	10	32	0.05278
RNN	0	50	10	64	0.16271	2	50	10	64	0.07281
RNN	0	50	10	128	0.18900	2	50	10	128	0.09436
RNN	0	50	50	16	0.17214	2	50	50	16	0.02915
RNN	0	50	50	32	0.13142	2	50	50	32	0.03342
RNN	0	50	50	64	0.11527	2	50	50	64	0.02518
RNN	0	50	50	128	0.12437	2	50	50	128	0.04287
RNN	0	50	100	16	0.21553	2	50	100	16	0.02435
RNN	0	50	100	32	0.16516	2	50	100	32	0.02973
RNN	0	50	100	64	0.15182	2	50	100	64	0.02486
RNN	0	50	100	128	0.13091	2	50	100	128	0.03970
RNN	0	50	150	16	0.20902	2	50	150	16	0.02288
RNN	0	50	150	32	0.18684	2	50	150	32	0.02763
RNN	0	50	150	64	0.17701	2	50	150	64	0.02650
RNN	0	50	150	128	0.15614	2	50	150	128	0.04249
RNN	0	50	200	16	0.19096	2	50	200	16	0.02294
RNN	0	50	200	32	0.20891	2	50	200	32	0.02524
RNN	0	50	200	64	0.18890	2	50	200	64	0.02760
RNN	0	50	200	128	0.17281	2	50	200	128	0.04312
RNN	0	100	10	16	0.13828	2	100	10	16	0.02065
RNN	0	100	10	32	0.15484	2	100	10	32	0.02927
RNN	0	100	10	64	0.19889	2	100	10	64	0.03984
RNN	0	100	10	128	0.25369	2	100	10	128	0.04614
RNN	0	100	50	16	0.13151	2	100	50	16	0.01986
RNN	0	100	50	32	0.12105	2	100	50	32	0.02226
RNN	0	100	50	64	0.11381	2	100	50	64	0.02558
RNN	0	100	50	128	0.13662	2	100	50	128	0.02135
RNN	0	100	100	16	0.14083	2	100	100	16	0.01779
RNN	0	100	100	32	0.13303	2	100	100	32	0.02165
RNN	0	100	100	64	0.12497	2	100	100	64	0.02029

RNN	0	100	100	128	0.10674	2	100	100	128	0.02326
RNN	0	100	150	16	0.14596	2	100	150	16	0.01937
RNN	0	100	150	32	0.14361	2	100	150	32	0.02041
RNN	0	100	150	64	0.13444	2	100	150	64	0.01876
RNN	0	100	150	128	0.10823	2	100	150	128	0.02325
RNN	0	100	200	16	0.15158	2	100	200	16	0.02024
RNN	0	100	200	32	0.14533	2	100	200	32	0.01977
RNN	0	100	200	64	0.13986	2	100	200	64	0.01789
RNN	0	100	200	128	0.11613	2	100	200	128	0.02118
RNN	1	10	10	16	0.11728	3	10	10	16	0.09006
RNN	1	10	10	32	0.16508	3	10	10	32	0.14183
RNN	1	10	10	64	0.21546	3	10	10	64	0.19126
RNN	1	10	10	128	0.23472	3	10	10	128	0.24643
RNN	1	10	50	16	0.01731	3	10	50	16	0.03684
RNN	1	10	50	32	0.01950	3	10	50	32	0.06940
RNN	1	10	50	64	0.02701	3	10	50	64	0.08603
RNN	1	10	50	128	0.08350	3	10	50	128	0.13077
RNN	1	10	100	16	0.01675	3	10	100	16	0.03248
RNN	1	10	100	32	0.01815	3	10	100	32	0.07119
RNN	1	10	100	64	0.02844	3	10	100	64	0.07170
RNN	1	10	100	128	0.02732	3	10	100	128	0.08786
RNN	1	10	150	16	0.01619	3	10	150	16	0.02901
RNN	1	10	150	32	0.01744	3	10	150	32	0.07454
RNN	1	10	150	64	0.02973	3	10	150	64	0.06993
RNN	1	10	150	128	0.02974	3	10	150	128	0.07318
RNN	1	10	200	16	0.01594	3	10	200	16	0.02725
RNN	1	10	200	32	0.01699	3	10	200	32	0.07721
RNN	1	10	200	64	0.02536	3	10	200	64	0.07058
RNN	1	10	200	128	0.02812	3	10	200	128	0.07037
RNN	1	50	10	16	0.03183	3	50	10	16	0.02666
RNN	1	50	10	32	0.06005	3	50	10	32	0.04144
RNN	1	50	10	64	0.07654	3	50	10	64	0.03896
RNN	1	50	10	128	0.10902	3	50	10	128	0.07630
RNN	1	50	50	16	0.02107	3	50	50	16	0.02971
RNN	1	50	50	32	0.02100	3	50	50	32	0.02771
RNN	1	50	50	64	0.02216	3	50	50	64	0.02675
RNN	1	50	50	128	0.03512	3	50	50	128	0.04023
RNN	1	50	100	16	0.01957	3	50	100	16	0.03057
RNN	1	50	100	32	0.01984	3	50	100	32	0.03622
RNN	1	50	100	64	0.02820	3	50	100	64	0.02438
RNN	1	50	100	128	0.02137	3	50	100	128	0.03036
RNN	1	50	150	16	0.01822	3	50	150	16	0.03046
RNN	1	50	150	32	0.02066	3	50	150	32	0.04481
RNN	1	50	150	64	0.02623	3	50	150	64	0.03288
RNN	1	50	150	128	0.02162	3	50	150	128	0.02778
RNN	1	50	200	16	0.01773	3	50	200	16	0.03122
RNN	1	50	200	32	0.02389	3	50	200	32	0.04105
RNN	1	50	200	64	0.02363	3	50	200	64	0.03080
RNN	1	50	200	128	0.02056	3	50	200	128	0.02720
RNN	1	100	10	16	0.04260	3	100	10	16	0.02517
RNN	1	100	10	32	0.04476	3	100	10	32	0.02946
RNN	1	100	10	64	0.06947	3	100	10	64	0.02509
RNN	1	100	10	128	0.09176	3	100	10	128	0.03250
RNN	1	100	50	16	0.02422	3	100	50	16	0.02468

RNN	1	100	50	32	0.03346	3	100	50	32	0.02674
RNN	1	100	50	64	0.03426	3	100	50	64	0.02701
RNN	1	100	50	128	0.04784	3	100	50	128	0.02670
RNN	1	100	100	16	0.02362	3	100	100	16	0.02301
RNN	1	100	100	32	0.03197	3	100	100	32	0.02816
RNN	1	100	100	64	0.03544	3	100	100	64	0.02389
RNN	1	100	100	128	0.04278	3	100	100	128	0.02878
RNN	1	100	150	16	0.02278	3	100	150	16	0.02506
RNN	1	100	150	32	0.03203	3	100	150	32	0.02842
RNN	1	100	150	64	0.03878	3	100	150	64	0.02220
RNN	1	100	150	128	0.04076	3	100	150	128	0.02784
RNN	1	100	200	16	0.03161	3	100	200	16	0.02857
RNN	1	100	200	32	0.03408	3	100	200	32	0.02705
RNN	1	100	200	64	0.04118	3	100	200	64	0.02214
RNN	1	100	200	128	0.04017	3	100	200	128	0.02572

Note: Model with the lowest RMSE marked with a red dotted line.

Source: Own authorship using Python (version 3.11.9).

## APPENDIX C – LSTM MODELS ESTIMATED

Model	Lag	Units	Epochs	Batch Size	RMSE	Lag	Units	Epochs	Batch Size	RMSE
LSTM	0	10	10	16	0.14873	2	10	10	16	0.06854
LSTM	0	10	10	32	0.14841	2	10	10	32	0.10390
LSTM	0	10	10	64	0.19321	2	10	10	64	0.10725
LSTM	0	10	10	128	0.26446	2	10	10	128	0.15244
LSTM	0	10	50	16	0.17396	2	10	50	16	0.01974
LSTM	0	10	50	32	0.16066	2	10	50	32	0.04075
LSTM	0	10	50	64	0.15226	2	10	50	64	0.05678
LSTM	0	10	50	128	0.14646	2	10	50	128	0.07529
LSTM	0	10	100	16	0.18902	2	10	100	16	0.02072
LSTM	0	10	100	32	0.19146	2	10	100	32	0.02021
LSTM	0	10	100	64	0.18441	2	10	100	64	0.02474
LSTM	0	10	100	128	0.15738	2	10	100	128	0.04859
LSTM	0	10	150	16	0.17507	2	10	150	16	0.02186
LSTM	0	10	150	32	0.19267	2	10	150	32	0.02337
LSTM	0	10	150	64	0.20804	2	10	150	64	0.01983
LSTM	0	10	150	128	0.17479	2	10	150	128	0.02887
LSTM	0	10	200	16	0.16511	2	10	200	16	0.02238
LSTM	0	10	200	32	0.17916	2	10	200	32	0.02506
LSTM	0	10	200	64	0.21415	2	10	200	64	0.02113
LSTM	0	10	200	128	0.19393	2	10	200	128	0.02288
LSTM	0	50	10	16	0.14992	2	50	10	16	0.06385
LSTM	0	50	10	32	0.17162	2	50	10	32	0.10361
LSTM	0	50	10	64	0.20844	2	50	10	64	0.10415
LSTM	0	50	10	128	0.25011	2	50	10	128	0.17359
LSTM	0	50	50	16	0.12077	2	50	50	16	0.04868
LSTM	0	50	50	32	0.13485	2	50	50	32	0.05829
LSTM	0	50	50	64	0.15008	2	50	50	64	0.07128
LSTM	0	50	50	128	0.15347	2	50	50	128	0.07593
LSTM	0	50	100	16	0.13353	2	50	100	16	0.03866
LSTM	0	50	100	32	0.14802	2	50	100	32	0.03843
LSTM	0	50	100	64	0.13620	2	50	100	64	0.04532
LSTM	0	50	100	128	0.14954	2	50	100	128	0.06764
LSTM	0	50	150	16	0.13580	2	50	150	16	0.03335
LSTM	0	50	150	32	0.14534	2	50	150	32	0.02314
LSTM	0	50	150	64	0.13918	2	50	150	64	0.03535
LSTM	0	50	150	128	0.15041	2	50	150	128	0.05715
LSTM	0	50	200	16	0.13596	2	50	200	16	0.03012
LSTM	0	50	200	32	0.14122	2	50	200	32	0.02126
LSTM	0	50	200	64	0.13320	2	50	200	64	0.03288
LSTM	0	50	200	128	0.15247	2	50	200	128	0.05336
LSTM	0	100	10	16	0.15026	2	100	10	16	0.04553
LSTM	0	100	10	32	0.15940	2	100	10	32	0.05581
LSTM	0	100	10	64	0.21037	2	100	10	64	0.06875
LSTM	0	100	10	128	0.24299	2	100	10	128	0.13007
LSTM	0	100	50	16	0.20368	2	100	50	16	0.03240
LSTM	0	100	50	32	0.24011	2	100	50	32	0.04461
LSTM	0	100	50	64	0.17819	2	100	50	64	0.05195
LSTM	0	100	50	128	0.15363	2	100	50	128	0.04327
LSTM	0	100	100	16	0.17361	2	100	100	16	0.03062
LSTM	0	100	100	32	0.21911	2	100	100	32	0.02573
LSTM	0	100	100	64	0.18993	2	100	100	64	0.04112



LSTM	0	100	100	128	0.16325	2	100	100	128	0.03695
LSTM	0	100	150	16	0.13925	2	100	150	16	0.02867
LSTM	0	100	150	32	0.17596	2	100	150	32	0.01887
LSTM	0	100	150	64	0.16984	2	100	150	64	0.03562
LSTM	0	100	150	128	0.19436	2	100	150	128	0.02811
LSTM	0	100	200	16	0.12376	2	100	200	16	0.02686
LSTM	0	100	200	32	0.14204	2	100	200	32	0.02175
LSTM	0	100	200	64	0.15648	2	100	200	64	0.03358
LSTM	0	100	200	128	0.18759	2	100	200	128	0.02793
LSTM	1	10	10	16	0.08162	3	10	10	16	0.05989
LSTM	1	10	10	32	0.11074	3	10	10	32	0.07607
LSTM	1	10	10	64	0.13502	3	10	10	64	0.08408
LSTM	1	10	10	128	0.14945	3	10	10	128	0.12108
LSTM	1	10	50	16	0.02678	3	10	50	16	0.02170
LSTM	1	10	50	32	0.03655	3	10	50	32	0.05227
LSTM	1	10	50	64	0.05231	3	10	50	64	0.06061
LSTM	1	10	50	128	0.02658	3	10	50	128	0.06646
LSTM	1	10	100	16	0.01896	3	10	100	16	0.02467
LSTM	1	10	100	32	0.03006	3	10	100	32	0.02711
LSTM	1	10	100	64	0.03934	3	10	100	64	0.04376
LSTM	1	10	100	128	0.02988	3	10	100	128	0.06006
LSTM	1	10	150	16	0.01996	3	10	150	16	0.02860
LSTM	1	10	150	32	0.02182	3	10	150	32	0.02302
LSTM	1	10	150	64	0.03096	3	10	150	64	0.02654
LSTM	1	10	150	128	0.02963	3	10	150	128	0.05091
LSTM	1	10	200	16	0.02116	3	10	200	16	0.03030
LSTM	1	10	200	32	0.01770	3	10	200	32	0.02114
LSTM	1	10	200	64	0.02272	3	10	200	64	0.01843
LSTM	1	10	200	128	0.02780	3	10	200	128	0.04002
LSTM	1	50	10	16	0.05506	3	50	10	16	0.06023
LSTM	1	50	10	32	0.08622	3	50	10	32	0.06922
LSTM	1	50	10	64	0.10295	3	50	10	64	0.08296
LSTM	1	50	10	128	0.18198	3	50	10	128	0.09759
LSTM	1	50	50	16	0.02616	3	50	50	16	0.02282
LSTM	1	50	50	32	0.02464	3	50	50	32	0.02958
LSTM	1	50	50	64	0.04147	3	50	50	64	0.04907
LSTM	1	50	50	128	0.05516	3	50	50	128	0.06614
LSTM	1	50	100	16	0.02189	3	50	100	16	0.02205
LSTM	1	50	100	32	0.02089	3	50	100	32	0.02180
LSTM	1	50	100	64	0.02893	3	50	100	64	0.03390
LSTM	1	50	100	128	0.04796	3	50	100	128	0.05172
LSTM	1	50	150	16	0.02134	3	50	150	16	0.02434
LSTM	1	50	150	32	0.02051	3	50	150	32	0.01948
LSTM	1	50	150	64	0.02336	3	50	150	64	0.03267
LSTM	1	50	150	128	0.04914	3	50	150	128	0.04957
LSTM	1	50	200	16	0.02232	3	50	200	16	0.02400
LSTM	1	50	200	32	0.01999	3	50	200	32	0.02052
LSTM	1	50	200	64	0.02171	3	50	200	64	0.02832
LSTM	1	50	200	128	0.04545	3	50	200	128	0.04245
LSTM	1	100	10	16	0.04243	3	100	10	16	0.02549
LSTM	1	100	10	32	0.05802	3	100	10	32	0.02959
LSTM	1	100	10	64	0.12125	3	100	10	64	0.05476
LSTM	1	100	10	128	0.18142	3	100	10	128	0.11144
LSTM	1	100	50	16	0.02693	3	100	50	16	0.03394

LSTM	1	100	50	32	0.04166	3	100	50	32	0.01888
LSTM	1	100	50	64	0.02975	3	100	50	64	0.01947
LSTM	1	100	50	128	0.05187	3	100	50	128	0.02790
LSTM	1	100	100	16	0.01845	3	100	100	16	0.03885
LSTM	1	100	100	32	0.03427	3	100	100	32	0.01774
LSTM	1	100	100	64	0.02214	3	100	100	64	0.01835
LSTM	1	100	100	128	0.03705	3	100	100	128	0.02644
LSTM	1	100	150	16	0.01703	3	100	150	16	0.03676
LSTM	1	100	150	32	0.02269	3	100	150	32	0.01985
LSTM	1	100	150	64	0.01866	3	100	150	64	0.01744
LSTM	1	100	150	128	0.02916	3	100	150	128	0.02263
LSTM	1	100	200	16	0.01692	3	100	200	16	0.03406
LSTM	1	100	200	32	0.02169	3	100	200	32	0.01982
LSTM	1	100	200	64	0.01787	3	100	200	64	0.01748
LSTM	1	100	200	128	0.03117	3	100	200	128	0.02025

Note: Model with the lowest RMSE marked with a red dotted line.

Source: Own authorship using Python (version 3.11.9).



ISBN nº 978-65-01-11585-6

# **O CRESCIMENTO DA ECONOMIA BRASILEIRA NO PERÍODO (1995-2022): UMA ANÁLISE DA TRAJETÓRIA DO PIB**

**Gustavo Lopes da Silva<sup>1</sup>**  
**João Vitor Landgraf Rodrigues<sup>2</sup>**  
**Juliane Chaves da Silva<sup>3</sup>**

## **MACROECONOMIA**

### **RESUMO**

O texto aborda a importância do PIB (Produto Interno Bruto) como principal indicador do crescimento econômico, tanto no Brasil quanto no mundo. No entanto, ele destaca que a análise exclusiva do PIB pode não ser suficiente para uma avaliação completa da economia, sendo necessário considerar outras variáveis, como taxa de juros, desemprego, inflação e contas públicas. Mesmo assim, o PIB ainda oferece um bom indicativo da saúde econômica de um país. O objetivo do artigo é analisar a trajetória do PIB brasileiro entre 1995 e 2022, observando o crescimento econômico sob as perspectivas da oferta (produção) e da demanda (despesa). O estudo será dividido em quatro seções, que examinam o crescimento do PIB nos governos de Fernando Henrique Cardoso (1995-2002), Luiz Inácio Lula da Silva (2003-2010), Dilma Rousseff e Michel Temer (2011-2018), e Jair Bolsonaro (2019-2022). Ao final, será apresentada a conclusão.

**Palavras-chave:** PIB, Crescimento, Demanda, Oferta.

### **ABSTRACT**

The text discusses the importance of GDP (Gross Domestic Product) as the main indicator of economic growth, both in Brazil and worldwide. However, it highlights that analyzing GDP alone may not be sufficient for a complete assessment of the economy, as other variables such as interest rates, unemployment, inflation, and public accounts must also be considered. Nevertheless, GDP still provides a good indication of a country's economic health. The objective of the article is to analyze the trajectory of Brazilian GDP from 1995 to 2022, observing economic growth from the perspectives of supply (production) and demand (expenditure). The study is divided into four sections, examining GDP growth during the administrations of Fernando Henrique Cardoso (1995-2002), Luiz Inácio Lula da Silva (2003-2010), Dilma Rousseff and Michel Temer (2011-2018), and Jair Bolsonaro (2019-2022). Finally, the conclusion will be presented.

**Key-words:** GDP, Economic growth, Demand, Supply, Trajectory.

---

<sup>1</sup> Aluno do curso de Ciências Econômica da Universidade Estadual de Maringá. E-mail: ra124305@uem.br

<sup>2</sup> Aluno do curso de Ciências Econômica da Universidade Estadual de Maringá. E-mail: ra125721@uem.br

<sup>3</sup> Aluna do curso de Ciências Econômica da Universidade Estadual de Maringá. E-mail: ra103601@uem.br

**Classificação JEL:** F43, O11

## INTRODUÇÃO

O PIB (Produto Interno Bruto) é o principal agregado macroeconômico utilizado no Brasil e no mundo para medir o crescimento da economia. Contudo, apenas a sua análise pode ser insuficiente para um diagnóstico preciso. Outras variáveis precisam ser consideradas, como taxa básica de juros, desemprego, inflação, contas públicas entre outras. Ainda assim, compreender a variação do PIB pode dar um bom sinal de como anda a saúde econômica do país.

Desta forma, o objetivo deste artigo é analisar a trajetória do PIB brasileiro entre os anos 1995 a 2022. Mais especificamente, trataremos do crescimento da economia pela ótica da produção (oferta) e pela ótica da despesa (demanda).

Para cumprir o objetivo proposto, o artigo será dividido em quatro seções. Na primeira, vamos analisar trajetória do crescimento da economia no governo de Fernando Henrique Cardoso (1995-2002). Na segunda seção, trataremos sobre a variação do produto no governo de Luiz Inácio Lula da Silva (2003-2010). Na terceira seção, trabalharemos o comportamento do crescimento econômico nos governos de Dilma Vana Rousseff e de Michel Miguel Elias Temer Lulia (2011-2018). Na quarta seção, trataremos acerca da trajetória do PIB no governo de Jair Messias Bolsonaro (2019-2022). Por fim, será apresentado a conclusão do trabalho.

## 1 O CRESCIMENTO DA ECONOMIA NO GOVERNO FHC (1995-2002)

Os dois mandatos do presidente Fernando Henrique Cardoso (FHC), entre 1995 e 2002, foram cruciais para a economia brasileira, marcados por eventos significativos como a continuação do Plano Real, crises financeiras internacionais e a desvalorização da moeda. Essa sessão analisa o crescimento do Produto Interno Bruto (PIB) brasileiro durante esse período, integrando as informações das tabelas de crescimento econômico, com foco nos valores discrepantes.

Tabela 1: Taxas de crescimento do PIB - ótica da produção - 1995/1998

Discriminação	1995	1996	1997	1998	Taxa Média
PIB – Brasil	4,4	2,2	3,4	0,3	2,57
Agropecuária	5,7	3,0	0,8	3,4	3,22
Industria	4,7	1,0	4,4	-2,1	2,00
Serviços	3,2	2,3	2,5	1,4	2,35
Indústria de transformação	4,9	0,1	2,5	-4,8	0,68

Fonte: IBGE (2024).

De acordo com a Tabela 1, que apresenta o crescimento do PIB sob a ótica da produção, o ano de 1995 foi marcado por um crescimento robusto de 4,4% no PIB geral, refletindo o impacto positivo do Plano Real. Esse crescimento foi sustentado principalmente pelo setor industrial, que cresceu 4,7%, e pelo setor agropecuária que apresentou um crescimento de 5,7%. Segundo a Tabela 1, o ano de 1998 foi um período de estagnação econômica para o Brasil, com o PIB geral crescendo apenas 0,3%. Esse desempenho fraco é explicado pela crise financeira asiática, que abalou as economias emergentes e reduziu a demanda por exportações brasileiras. O setor industrial foi particularmente afetado, registrando uma queda de -2,1%, enquanto a indústria de transformação sofreu um declínio ainda mais acentuado de -4,8%.

Tabela 2: Taxas de crescimento do PIB - ótica da demanda - 1995/1998

Discriminação	1995	1996	1997	1998	Taxa Média
PIB – Brasil	4,4	2,2	3,4	0,3	2,57
Consumo das famílias	8,6	3,2	3	-0,7	3,52
Consumo do governo	1,4	-1,8	1,2	3,2	1,00
F.B.C.F.	7,3	1,2	8,4	-0,2	4,17
Exportações	-2,0	-0,4	11	4,9	3,38
(-) Importações	30,7	5,6	14,6	-0,1	12,70

Fonte: IBGE (2024).

Simultaneamente, a Tabela 2, que analisa o PIB sob a ótica da demanda, confirma o aumento significativo no consumo das famílias, no qual teve um aumento expressivo de 8,6%. A estabilização da inflação trouxe maior previsibilidade econômica, o que aumentou o poder de compra das famílias e a confiança dos investidores com 7,3%. Destaca-se que as importações aumentaram 30,7% em 1995, refletindo a abertura econômica promovida pelo governo. Essa abertura facilitou a entrada de bens de capital e tecnologia necessários para a modernização da indústria brasileira.

A Tabela 2 também revela que, nesse contexto de crise, houve um impacto negativo na formação de capital que apresentou uma queda de -0,2% e no consumo das famílias que apresentou um declínio de -0,7%, mesmo o consumo das famílias que até então mostrava força, foi impactado pela crise. A retração na demanda interna e a fuga de capitais contribuíram para a estagnação do PIB, e a confiança dos investidores foi abalada, impactando ainda mais a economia.

A Tabela 3 mostra que em 1999, após a desvalorização do real, o PIB geral cresceu modestos 0,5%. A indústria continuou em declínio, com uma queda de -2,6%, e a indústria de transformação diminuiu -1,9%. A desvalorização da moeda tornou as exportações brasileiras mais competitivas, beneficiando especialmente o setor agropecuário, que cresceu 6,5% no

mesmo ano. A crise energética de 2001, conhecida como "apagão", resultou em racionamento de energia elétrica, afetando negativamente a produção industrial e o crescimento econômico. O crescimento do PIB em 2001 foi de apenas 1,4%.

Tabela 3: Taxas de crescimento do PIB - ótica da produção - 1999/2002

Discriminação	1999	2000	2001	2002	Taxa Média
PIB – Brasil	0,5	4,4	1,4	3,1	2,35
Agropecuária	6,5	2,7	5,2	8	5,60
Indústria	-2,6	4,4	-0,6	3,8	1,25
Serviços	1,8	3,8	2,1	3,1	2,70
Indústria de transformação	-1,9	5,7	0,7	2,1	1,65

Fonte: IBGE (2024).

A indústria, dependente de energia elétrica para produção, sofreu quedas significativas apresentado uma queda de -0,6, com impacto direto no crescimento econômico geral.

Tabela 4: Taxas de crescimento do PIB - ótica da demanda - 1999/2002


Discriminação	1999	2000	2001	2002	Taxa Média
PIB – Brasil	0,5	4,4	1,4	3,1	2,35
Consumo das famílias	0,4	4	0,8	1,3	1,65
Consumo do governo	1,7	-0,2	2,6	3,8	1,97
F.B.C.F.	-8,9	4,8	1,3	-1,4	-1,45
Exportações	5,7	12,9	9,2	6,5	8,57
(-) Importações	-15,1	10,8	3,3	-13,3	-3,57

Fonte: IBGE (2024).

Na Tabela 4, podemos observar que, em 1999, a Formação Bruta de Capital Fixo (F.B.C.F.) sofreu uma queda acentuada de -8,9%. Esse indicador, que reflete os investimentos em bens de capital, foi diretamente impactado pela incerteza econômica gerada pela desvalorização do real, fazendo com que os investidores adotassem uma postura mais cautelosa. A queda nos investimentos teve um impacto significativo no crescimento econômico, refletindo o ambiente de incerteza e ajuste pelo qual a economia brasileira passava.

De acordo com o gráfico 1, no qual representa a relação das taxas de crescimento do PIB com a da indústria de transformação, existe uma correlação significativa nas altas e baixas de ambas as taxas. Ou seja, quando temos um aumento na indústria de transformação o PIB tende a crescer, e quando temos uma queda o inverso ocorre.

Gráfico 1: Taxa de crescimento do PIB e da indústria de transformação – 1995/2002



Fonte: IBGE (2024).

2 O CRESCIMENTO DA ECONOMIA NO GOVERNO LULA (2003-2010)

Os dois mandatos presidenciais de Luiz Inácio Lula da Silva, de 2003 a 2011, é um marco na trajetória econômica e social do Brasil. Quando Lula assumiu o cargo, o país enfrentava um cenário de vulnerabilidade econômica, caracterizado por inflação elevada, baixo crescimento e instabilidade política. A partir de uma série de políticas bem orquestradas, seu governo conseguiu não apenas estabilizar a economia, mas também promover um crescimento bastante considerável e distribuir melhor a renda, o que culminou no fortalecimento da indústria, no aumento do PIB e na redução significativa da pobreza. A partir daqui vamos analisar os dados resultantes do período deste governo.

Entre 2003 e 2006, o PIB do Brasil cresceu a uma taxa média de 3,52%, nesta tabela podemos destacar o ano de 2004, quando o crescimento atingiu 5,8%. A agropecuária teve um crescimento médio de 4,00%, enquanto a indústria e os serviços cresceram em média 3,07% e 3,50%, respectivamente. A indústria de transformação, um setor crucial, apresentou um crescimento médio de 3,80%, com um pico de 9,1% em 2004.

Tabela 5: Taxas de crescimento do PIB - ótica da produção - 2003/2006

Discriminação	2003	2004	2005	2006	Taxa Média
PIB – Brasil	1,1	5,8	3,2	4	3,52
Agropecuária	8,3	2	1,1	4,6	4,00
Indústria	0,1	8,2	2	2	3,07
Serviços	1	5	3,7	4,3	3,50
Indústria de transformação	2,7	9,1	2,2	1,2	3,80

Fonte: IBGE (2024).

Tabela 6: Taxas de crescimento do PIB - ótica da demanda - 2003/2006

Discriminação	2003	2004	2005	2006	Taxa Média
PIB – Brasil	1,1	5,8	3,2	4	3,52
Consumo das famílias	-0,5	3,9	4,4	5,3	3,27
Consumo do governo	1,6	3,9	2	3,6	2,77
F.B.C.F.	-4	8,5	2	6,7	3,30
Exportações	11	14,5	9,6	4,8	9,97
(-) Importações	-0,5	10,4	7,5	17,8	8,80

Fonte: IBGE (2024).

No mesmo período, o consumo das famílias cresceu a uma taxa média de 3,27%, refletindo o aumento do poder de compra da população. O consumo do governo teve um crescimento médio de 2,77%, enquanto a formação bruta de capital fixo (F.B.C.F.) cresceu em média 3,30%. As exportações cresceram a uma taxa média de 9,97%, impulsionadas pela demanda internacional, enquanto as importações cresceram em média 8,80%.

Tabela 7: Taxas de crescimento do PIB - ótica da produção - 2007/2010

Discriminação	2007	2008	2009	2010	Taxa Média
PIB – Brasil	6,1	5,1	-0,1	7,5	4,65
Agropecuária	3,2	5,8	-3,7	6,7	3,00
Indústria	6,2	4,1	-4,7	10,2	3,95
Serviços	5,8	4,8	2,1	5,8	4,62
Indústria de transformação	6,1	4,1	-9,3	9,2	2,52

Fonte: IBGE (2024).

Entre 2007 e 2010, o PIB do Brasil cresceu a uma taxa média de 4,65%, com um pico de 7,5% em 2010. A agropecuária teve um crescimento médio de 3,00%, apesar de uma queda de -3,7% em 2009. A indústria cresceu em média 3,95%, com um desempenho notável de 10,2% em 2010. O setor de serviços manteve um crescimento constante, com uma média de 4,62%, enquanto a indústria de transformação teve um crescimento médio de 2,52%, apesar de uma queda significativa de -9,3% em 2009.

Tabela 8: Taxas de crescimento do PIB - ótica da demanda - 2007/2010


Discriminação	2007	2008	2009	2010	Taxa Média
PIB – Brasil	6,1	5,1	-0,1	7,5	4,65
Consumo das famílias	6,4	6,5	4,5	6,2	5,90
Consumo do governo	4,1	2	2,9	3,9	3,22
F.B.C.F.	12	12,3	-2,1	17,9	10,02
Exportações	6,2	0,4	-9,2	11,7	2,27
(-) Importações	19,6	17	-7,6	33,6	15,65

Fonte: IBGE (2024).



De acordo com a tabela 8, o consumo das famílias cresceu a uma taxa média de 5,90%, refletindo a continuidade das políticas de aumento do poder de compra. O consumo do governo teve um crescimento médio de 3,22%, enquanto a formação bruta de capital fixo (F.B.C.F.) cresceu em média 10,02%, com um pico de 17,9% em 2010. As exportações cresceram a uma taxa média de 2,27%, enquanto as importações cresceram em média 15,65%, com um aumento significativo de 33,6% em 2010.

Gráfico 2: Taxa de crescimento do PIB e da indústria de transformação – 1995/2010



Fonte: IBGE (2024).

O gráfico 8 demonstra a correlação entre a variação do PIB e a variação da produção na indústria de transformação, onde tanto nas quedas quanto nas recuperações econômicas analisadas podemos observar um acompanhamento das linhas tendenciais.

O governo Lula implementou uma série de políticas que promoveram a inclusão social, estimularam o consumo e os investimentos, e fortaleceram a infraestrutura do país, entre eles podemos citar: Bolsa família; aumento do salário mínimo; expansão de crédito; redução da taxa de juros; PAC em 2007; acordos comerciais e diversificação de mercados. Esses esforços, aliados a um cenário internacional favorável, devido ao crescimento da China e seu aumento na demanda dos commodities que impulsionou as exportações, e o boom das commodities, resultaram em um período de crescimento econômico robusto, com melhorias significativas nos indicadores sociais e econômicos do Brasil.

### 3 O CRESCIMENTO DA ECONOMIA NO GOVERNO DILMA/TEMER (2011-2018)

Dilma Rousseff foi eleita pela primeira vez presidente do Brasil em 2010, sucedendo Luiz Inácio Lula da Silva, de quem foi ministra-chefe da Casa Civil. Dilma assumiu a presidência em 1º de janeiro de 2011, tornando-se a primeira mulher a ocupar o cargo no país.

Sua campanha focou na continuidade das políticas econômicas e sociais implementadas pelo governo Lula, como a expansão dos programas de inclusão social e o fortalecimento da economia. No início de seu governo, Dilma enfrentou desafios significativos, como a necessidade de equilibrar o crescimento econômico com o controle da inflação, além de lidar com a crescente demanda por melhorias nos serviços públicos e infraestrutura.

A Tabela 9 apresenta os dados que compõem o PIB pela ótica da produção (oferta) para o período de 2011 a 2014. Nele é destacada a indústria de transformação, componente da indústria. O seu destaque se deve a sua grande importância para o setor.

Tabela 9: Taxas de crescimento do PIB - ótica da produção - 2011/2014

Discriminação	2011	2012	2013	2014	Taxa Média
PIB – Brasil	4	1,9	3,0	0,5	2,35
Agropecuária	5,6	-3,1	8,4	2,8	3,42
Indústria	4,1	-0,7	2,2	-1,5	1,02
Serviços	3,5	2,9	2,8	1	2,55
Indústria de transformação	2,2	-2,4	3	-4,7	-0,47

Fonte: IBGE (2024).

No ano de 2011, a agropecuária se destaca na ótica da produção, tendo um desempenho positivo, beneficiada pela alta demanda internacional por commodities agrícolas. O que rendeu ao setor um crescimento na ordem de 5,6%. A indústria apresentou crescimento de 4,1% no seu total, sendo que a indústria de transformação cresceu 2,2%. O setor de serviços cresceu 3,5%, sustentado pelo aumento do consumo das famílias.

Para o ano de 2012, o setor agropecuário teve um resultado bem ruim, com uma queda de -3,1% no ano. A indústria no geral teve uma redução da sua produção na ordem de -0,7%, e a indústria de transformação foi um pouco pior, apresentando uma retração de 2,4%. O setor de serviços cresceu 2,9%, desacelerando o seu crescimento em relação ao ano anterior, porém mantendo um bom nível de crescimento.

No ano de 2013 a agropecuária teve um crescimento mais robusto, de 8,4%. A indústria teve um crescimento de 2,2%, apresentando uma melhora em relação ao resultado do ano anterior, sendo que a indústria de transformação cresceu ainda mais, chegando aos 3% para esse ano. O setor de serviços cresceu 2,8%, com desempenho positivo e relativamente estável em relação ao ano anterior.

Para o ano de 2014, o setor agropecuário cresceu 2,8%. A indústria entrou em recessão, com retração de -1,5%, tendo o subsetor da indústria de transformação uma queda na ordem de 4,7%. A produção manufatureira caiu, e a construção civil foi impactada pela redução dos investimentos públicos e privados. O setor de serviços cresceu apenas 1,0%. Portanto a queda na indústria é principal fator para a queda do PIB nessa ótica.

A taxa média de crescimento do PIB demonstra que houve uma desaceleração no crescimento do país em comparação ao governo Lula.

A tabela 10 demonstra os dados do PIB pela ótica da demanda no período de 2011 a 2014.

Tabela 10: Taxas de crescimento do PIB - ótica da demanda - 2011/2014

Discriminação	2011	2012	2013	2014	Taxa Média
PIB – Brasil	4	1,9	3	0,5	2,35
Consumo das famílias	4,8	3,5	3,5	2,3	3,52
Consumo do governo	2,2	2,3	1,5	0,8	1,70
F.B.C.F.	6,8	0,8	5,8	-4,2	2,30
Exportações	4,8	0,7	1,8	-1,6	1,42
(-) Importações	9,4	1,1	6,7	-2,3	3,72

Fonte: IBGE (2024).

Em 2011, o Brasil registrou um crescimento do PIB de 4%, impulsionado principalmente pelo investimento. O investimento cresceu 6,8% nesse ano, propulsado por projetos de infraestrutura e expectativas positivas quanto à economia. O Consumo das famílias e as exportações tiveram uma variação considerada boa de 4,8%. Alinhado a esses crescimentos, os gastos do governo aumentaram na ordem de 2,2%, um valor menor que os demais componentes do PIB nessa ótica.

O ano de 2012 marcou uma desaceleração significativa, com o PIB crescendo apenas 1,9%. O consumo das famílias ainda contribuiu para o crescimento, mas em ritmo menor, crescendo 3,5%. O investimento sofreu uma queda expressiva, crescendo apenas 0,8%. Os gastos do governo continuaram a crescer em um ritmo parecido com o do ano anterior, sendo na ordem de 2,3%. Outra conta que impulsionou a desaceleração do crescimento são as exportações, que para esse ano foi de apenas 0,7%, ante uma alta de 1,1 % das importações.

Em 2013, o crescimento do PIB foi de 3%, um valor melhor que o verificado no ao anterior. O investimento impulsionou essa conta tendo um resultado de 5,8% para o ano, um dado muito melhor do que os 0,8% de 2012. O consumo das famílias manteve o seu crescimento estável e em bom nível, repetindo o resultado de 3,5% do ano anterior. O consumo do governo apresentou uma pequena desaceleração, sendo de 1,5%. O resultado externo para o ano não foi muito bom, de forma que as exportações apresentaram um aumento de 1,8%, enquanto as importações cresceram 6,7%, o que aponta uma demanda interna que não estava conseguindo ser totalmente suprida.

Em 2014, o PIB cresceu apenas 0,5%, refletindo um cenário de estagnação econômica. O consumo das famílias teve um crescimento baixo, o menor do mandato, sendo de 2,3%. Os investimentos caíram de forma acentuada, sendo uma queda de -4,2%, o principal fator para a

queda do crescimento no ano. O governo, teve menos espaço para aumentar os gastos, tendo um crescimento em seus gastos de 0,8%. No setor externo, o déficit em transações correntes cresceu, com uma queda nas exportações de -1,6% e queda nas importações de -2,3%.

A tabela 11 apresenta os dados da taxa de crescimento do PIB pela ótica da produção entre os anos 2015 a 2018.

Tabela 11: Taxas de crescimento do PIB - ótica da produção - 2015/2018

Discriminação	2015	2016	2017	2018	Taxa Média
PIB – Brasil	-3,5	-3,3	1,3	1,8	-0,55
Agropecuária	3,3	-5,2	14,2	1,3	3,40
Indústria	-5,8	-4,6	-0,5	0,7	-2,55
Serviços	-2,7	-2,2	0,8	2,1	-0,55
Indústria de transformação	-8,5	-4,8	2,3	1,4	-2,40

Fonte: IBGE (2024).

Em 2015, a agropecuária teve um crescimento modesto de 3,3%, única conta a ter um resultado positivo. A indústria foi severamente impactada pela recessão, com uma retração de -5,8%. O subsetor da indústria de transformação foi mais impactado apresentando uma redução de -8,5%. O setor de serviços retraiu -2,7% no ano. O resultado ruim para o ano de 2015, uma queda no PIB de -3,5%, pode ser atribuído a queda na demanda interna do país.

O impeachment da Presidenta Dilma em 2016, aprovado pelo Senado por supostas irregularidades fiscais, levou à sua destituição. Michel Temer, então vice-presidente, assumiu a presidência, comprometendo-se a promover reformas econômicas e políticas para combater a crise que o país enfrentava. A agropecuária retrocedeu a sua produção em -5,2%, A indústria seguiu em retração, com queda de -4,6%, tendo a indústria de transformação uma queda de -4,8% O setor de serviços caiu -2,2%, com continuidade na sua contração. Isso fecha um cenário de queda em todos os itens do PIB pela ótica da oferta, acentuando a queda na oferta interna.

Em 2017, o setor agropecuário teve um ano excepcional, com crescimento de 14,2%, impulsionado por uma safra recorde de grãos. A indústria continuou recuando a taxa de -0,5% no ano, especialmente no setor de transformação houve um crescimento de 2,3%, o primeiro resultado positivo observado desde 2013. O setor de serviços cresceu modestos 0,8% ante a retração dos anos anteriores.

Para o ano de 2018, o setor agropecuário cresceu 1,3%, mostrando uma desaceleração após o forte crescimento de 2017. A indústria continuou a recuperação, com crescimento modesto de 0,7%, tendo a indústria de transformação um aumento de 1,4% em seus resultados. O setor de serviços cresceu 2,1%, refletindo uma recuperação mais consistente no comércio, transporte e serviços financeiros, acompanhando a melhora gradual na economia.

A tabela 12 contém os dados de taxa de crescimento do PIB pela ótica da demanda entre os anos 2015 a 2018.

Tabela 12: Taxas de crescimento do PIB - ótica da demanda - 2015/2018

Discriminação	2015	2016	2017	2018	Taxa Média
PIB – Brasil	-3,5	-3,3	1,3	1,8	-0,55
Consumo das famílias	-3,2	-3,8	2	2,4	-0,65
Consumo do governo	-1,4	0,2	-0,7	0,8	-0,22
F.B.C.F.	-13,9	-12,1	-2,6	5,2	-5,85
Exportações	6,8	0,9	4,9	4,1	4,17
(-) Importações	-14,2	-10,3	6,7	7,7	-2,55

Fonte: IBGE (2024).

Em 2015, o PIB brasileiro encolheu -3,5%, marcando o início de uma profunda recessão. O consumo das famílias caiu -3,2%. O investimento despencou -13,9%. Os gastos do governo se reduziram -1,4%, limitados pela necessidade de ajustes fiscais. Outra queda muito expressiva foi a das importações de -14,2%, deixando para as exportações a única conta positiva, sendo um aumento de 6,8%. Essa queda tão forte no PIB pode ser explicada por diversos fatores, o professores Joaquim Miguel Couto e Ana Cristina Lima Couto falam em seu livro que:

“...a queda significativa do PIB em 3,5% no ano de 2015, deveu-se aos seguintes fatores: a) medo em relação ao futuro (que derrubou o consumo das famílias); b) política fiscal restritiva do governo federal (que afetou negativamente o consumo do governo e os investimentos públicos); c) política monetária restritiva (que influenciava negativamente os investimentos privados); d) instabilidade política (que retraiu os investimentos privados); e) Operação Lava Jato (que reduziu os investimentos públicos e privados).”(COUTO; COUTO, 2023, p.150)

Em 2016, o PIB voltou a encolher, registrando uma contração de -3,3%. O consumo das famílias continuou em queda, reduzindo -3,8%. O ajuste fiscal implementado pelo governo limitou os gastos públicos, sendo um aumento de 0,2%. O investimento continuou a trajetória de queda, recuando -12,1%. No setor externo, a balança comercial continuou a se beneficiar da queda nas importações de -10,3% e um aumento modesto nas exportações de 0,9%.


Em 2017, o PIB do Brasil voltou a crescer, embora de forma tímida, registrando um aumento de 1,3%. O consumo das famílias começou a se recuperar lentamente, crescendo 2,0%. O investimento, porém, continuou reduzindo a uma taxa de -2,6%. Os gastos do governo continuaram limitados pelos ajustes fiscais, reduzindo em -0,7%. No setor externo, a recuperação do crescimento das exportações em 4,9% foi um bom resultado e foi acompanhado de um resultado positivo nas importações, tendo um aumento de 6,7%.

Em 2018, o PIB cresceu 1,8%, mostrando uma recuperação lenta. O consumo das famílias continuou a se recuperar, embora de forma desigual, refletindo o alto nível de

desemprego e a lenta recuperação dos salários, cresceu apenas 2,4%. O investimento apresentou uma leve melhora, crescendo a uma taxa de 5,2%, algo não visto desde o ano de 2013. Os gastos do governo permaneceram contidos devido às restrições fiscais, crescendo apenas 0,8%. O setor externo continuou a ser um fator positivo para o PIB, com as exportações crescendo 4,1% e as importações 7,7% ainda contidas pela recuperação lenta da demanda interna.

O gráfico 3 apresenta as taxas de crescimento do PIB relacionadas a taxa de crescimento da indústria de transformação para o período 1995 a 2018.

Gráfico 3: Taxa de crescimento do PIB e da indústria de transformação – 1995/2018



Fonte: IBGE (2024).

Conforme analisamos os dados desse gráfico, a tendência observada nos governos anteriores pode ser observada no governo Dilma/Temer. Nas variações negativas da Indústria de transformação é possível verificar a queda no PIB. No mesmo sentido, quando ocorre um aumento na produção da indústria de transformação o PIB cresce.

#### 4 O CRESCIMENTO DA ECONOMIA NO GOVERNO BOLSONARO (2019-2022)

A eleição de Jair Bolsonaro em 2018 representou uma continuidade das políticas econômicas liberais implementadas durante o governo de Michel Temer. Bolsonaro, ao assumir a presidência, manteve Paulo Guedes como ministro da Economia, um defensor do livre mercado e das reformas estruturais. Entre as medidas que seguiram a linha do governo anterior, destacam-se a reforma da previdência, a privatização de estatais e a redução da intervenção do Estado na economia. O objetivo dessas políticas era promover o crescimento econômico e atrair investimentos externos, alinhando-se com a agenda liberal estabelecida por Temer após o impeachment de Dilma Rousseff.

A tabela 13 apresenta as taxas de crescimento do PIB pela ótica da produção para os anos 2019 a 2022.

Tabela 13: Taxas de crescimento do PIB - ótica da produção - 2019/2022

Discriminação	2019	2020	2021	2022	Taxa Média
PIB – Brasil	1,2	-3,3	4,8	3	1,42
Agropecuária	0,4	4,2	0,00	-1,1	0,87
Indústria	-0,7	-3	5,0	1,5	0,70
Serviços	1,5	-3,7	4,8	4,3	1,72
Indústria de transformação	-0,4	-4,7	3,8	-0,5	-0,45

Fonte: IBGE (2024).

No ano de 2019, o setor agropecuário cresceu 0,4%. A indústria encolheu -0,7% com relação ao ano anterior e a indústria de transformação caiu -0,4%. O setor de serviços cresceu -1,5%, com destaque para o comércio e os serviços financeiros, impulsionados pelo consumo das famílias.

Em 2020 a agropecuária foi o único setor que cresceu, com expansão de 4,2%, sustentada pela forte demanda por commodities e pelo câmbio favorável para exportações. A indústria retraiu -3,0%, afetada pela paralisação de atividades e pela queda na demanda interna durante a pandemia. De forma que a indústria de transformação caiu -4,7%. O setor de serviços, o mais afetado pela pandemia, retraiu -3,7%. Setores como comércio, transporte, turismo e serviços presenciais sofreram quedas significativas devido às medidas de isolamento social.

No ano de 2021 a agropecuária apresentou estabilidade, variando 0%, impactada por problemas climáticos, como a seca e geadas, que prejudicaram a produção agrícola. A indústria se recuperou, com crescimento de 5,0%, sendo que a indústria de transformação cresceu 3,8 %. O setor de serviços cresceu 4,8%, liderado pela recuperação do comércio, transporte e serviços financeiros, à medida que a vacinação avançava e as atividades econômicas voltavam à normalidade. Em 2022 a agropecuária caiu, com uma redução de -1,1%. A indústria apresentou crescimento moderado de 1,5%, e a indústria de transformação teve uma queda de -0,5%. O setor de serviços cresceu 4,3%, refletindo uma retomada mais ampla da economia e o aumento da demanda interna, apesar da pressão inflacionária.

A tabela 14 contém as taxas de crescimento do PIB pela ótica da demanda entre os anos 2019 a 2022.

Tabela 14: Taxas de crescimento do PIB - ótica da demanda - 2019/2022

Discriminação	2019	2020	2021	2022	Taxa Média
PIB – Brasil	1,2	-3,3	4,8	3,0	1,42
Consumo das famílias	2,6	-4,6	3,0	4,1	1,27
Consumo do governo	-0,5	-3,7	4,2	2,1	0,52
F.B.C.F.	4,0	-1,7	12,9	1,1	4,07
Exportações	-2,6	-2,3	4,4	5,7	1,30
(-) Importações	1,3	-9,5	13,8	1,0	1,65

Fonte: IBGE (2024).

Em 2019, o PIB do Brasil cresceu 1,2%, refletindo um ano de crescimento modesto, mas com sinais de estabilização após anos de crise. O consumo das famílias continuou a ser um dos principais motores da demanda, crescendo 2,6%. Ocorreu um aumento expressivo nos investimentos, sendo de 4%. Os gastos do governo foram restritos pelo compromisso com o ajuste fiscal, o reduziu os gastos do governo em -0,5%. O setor externo teve uma queda nas exportações de -2,6% e um aumento nas importações de 1,3%.

Em 2020, o PIB brasileiro encolheu -3,3%, devido ao impacto da pandemia de COVID-19. O consumo das famílias sofreu uma queda significativa, sendo de -4,6%. O investimento caiu -1,7% interrompendo a frágil melhora observada nos anos anteriores. Os gastos do governo ainda caíram nesse ano, se reduzindo -3,7%. No setor externo, as exportações sofreram, caindo -2,3% no ano, já as importações caíram -9,5% impulsionados pelo choque que a economia sofreu.


No ano de 2021, o PIB cresceu 4,8%, refletindo uma recuperação após a contração de 2020. O consumo das famílias (3,0%) se recuperou com a retomada das atividades econômicas e o avanço da vacinação contra a COVID-19, embora a inflação alta tenha pressionado o poder de compra. O investimento começou a se recuperar aumentando ao uma taxa de 12,9%. Os gastos do governo subiram, aumentando 4,2% especialmente com saúde e medidas de apoio à economia. O setor externo teve um desempenho positivo, com exportações crescendo 4,4% e as importações cresceram 13,8%.

Já no ano de 2022, o PIB cresceu cerca de 3,0%, um ritmo moderado de recuperação, em um contexto de incerteza econômica e política, com as eleições presidenciais no centro das atenções. O consumo das famílias continuou a crescer aumentando 4,1%, mas foi pressionado pela inflação persistente e pelo aumento das taxas de juros. O governo manteve gastos mais elevados aumento em 2,1% o seu consumo, especialmente em programas sociais. O setor externo continuou com exportações em elevação, aumentando 5,7% no ano e as importações crescendo 1,0%.

Ao fim do governo Bolsonaro e analisando o gráfico 4, a relação observada entre a indústria de transformação e o PIB continua mantendo a mesma relação verificada nos governos anteriores. A recessão ocorrida em 2020 por causa da pandemia de Covid-19 impactou fortemente a indústria de transformação. Já para o ano seguinte ocorre o aumento dos dois agregados. Ao fim dessa análise temporal, é possível afirmar que o resultado do crescimento da economia está fortemente ligado ao resultado da indústria de transformação, de forma que é possível verificar linhas de tendência com trajetória próximas.



Gráfico 4: Taxa de crescimento do PIB e da indústria de transformação – 1995/2022



Fonte: IBGE (2024).

Para compreender o crescimento econômico em cada mandato, as taxas médias desse crescimento ajudam a suavizar os picos e vales que podem ocorrer devido à volatilidade da economia. Na Tabela 15, é possível analisar a taxa média de crescimento econômico em cada mandato, o que permite identificar qual governo apresentou o maior crescimento médio.

Tabela 15: Taxas médias de crescimento (1995-2022)

Período	Governo	Taxa média
1995-1998	I FHC	2,58
1999-2002	II FHC	2,35
2003-2006	I Lula	3,53
2007-2010	II Lula	4,65
2011-2014	I Dilma	2,35
2015-2018	Dilma/Temer	-0,93
2019-2022	Bolsonaro	1,43

Fonte: IBGE (2024).

O governo com a menor taxa de crescimento, que, nesse caso, representa uma retração da economia, é o mandato de Dilma/Temer, com uma redução média da produção econômica de -0,93%. Em seguida, vem o mandato único de Bolsonaro, com um crescimento médio de 1,43% do PIB. O próximo na lista é um empate: o primeiro mandato da Presidenta Dilma e o segundo mandato de FHC, ambos com um crescimento médio de 2,35%. Abrindo o pódio, o terceiro maior crescimento médio é o do primeiro mandato de FHC, com uma taxa de 2,58%. No topo, o mandato que apresentou o maior crescimento econômico médio é o segundo governo Lula, com uma taxa de 4,65%. Além de conquistar o primeiro lugar, o primeiro mandato de Lula ocupa o segundo maior crescimento médio do PIB no período observado, permitindo que Lula ocupe o primeiro e segundo lugar no pódio dos maiores crescimentos econômicos.

Fonte: IBGE (2024).

## CONCLUSÃO

A análise das taxas médias de crescimento do PIB revela diferenças significativas entre os governos dos diferentes presidentes que ocuparam o planalto entre 1995 a 2018. Durante os dois mandatos de FHC, entre 1995 e 2002, a economia brasileira apresentou um crescimento médio de 2,45%. Esse período foi marcado por medidas de estabilização econômica, como a continuidade do Plano Real, que ajudaram a controlar a inflação, mas o crescimento ficou relativamente contido devido a crises externas e restrições fiscais internas.

O governo de Luiz Inácio Lula da Silva registrou um crescimento médio do PIB de 4,06% entre 2003 e 2010, o maior entre os presidentes analisados. Esse período foi caracterizado por uma combinação de políticas econômicas voltadas para a inclusão social e o aumento do consumo interno, juntamente com um cenário externo favorável para as commodities, o que impulsionou a economia brasileira de forma robusta. O crescimento elevado durante esses anos permitiu a expansão de programas sociais e a redução da pobreza, colocando o Brasil em destaque no cenário econômico global.

Já nos governos seguintes, o desempenho econômico foi mais modesto. A gestão Dilma Rousseff/Michel Temer, de 2011 a 2018, apresentou uma taxa média de crescimento de apenas 0,71%, refletindo uma série de desafios, incluindo a crise fiscal, instabilidade política e recessão econômica. O governo de Jair Bolsonaro, de 2019 a 2022, registrou um crescimento médio de 1,43%, marcado por um ambiente econômico difícil devido à pandemia de COVID-19 e a crises econômicas globais. Esses resultados contrastam fortemente com o período de maior expansão econômica visto nos anos de Lula, destacando as dificuldades econômicas enfrentadas nos últimos anos.

## REFERÊNCIAS

COUTO, Joaquim Miguel; COUTO, Ana Cristina Lima. **Política econômica e dinâmica macroeconômica nos governos de Dilma Rousseff e Michel Temer (2011-2018)**. Maringá: Eduem, 2023.

IBGE. **Estatísticas**-Econômicas-Contas nacionais-SCNT – Sistemas de Contas Nacionais Trimestrais-Tabelas-Tabelas Completas. Disponível em: <https://www.ibge.gov.br/estatisticas/economicas/contas-nacionais/9300-contas-nacionais-trimestrais.html?=&t=resultados>. Acesso em 18 jul. 2024.