



UNIVERSIDADE FEDERAL DO RIO DE JANEIRO  
INSTITUTO DE ECONOMIA  
CURSO DE GRADUAÇÃO EM CIÊNCIAS ECONÔMICAS

João Victor de Souza Duarte

**VOLATILIDADE CAMBIAL NO BRASIL: UMA ANÁLISE PARA O PERÍODO  
DE 2008-2021**

Rio de Janeiro  
2022

João Victor de Souza Duarte

**VOLATILIDADE CAMBIAL NO BRASIL: UMA ANÁLISE PARA O PERÍODO  
DE 2008-2021**

Trabalho de Conclusão do Curso  
apresentado ao Instituto de Economia da  
Universidade Federal do Rio de Janeiro  
como exigência para obtenção do título de  
Bacharel em Ciências Econômicas.

Orientadora: Professora Dra. Susan  
Schommer

Rio de Janeiro

2022

D812v Duarte, João Victor de Souza .  
Volatilidade cambial no Brasil: uma análise para o período de 2008-2021 / João  
Victor de Souza Duarte. – 2022.  
70 f.; 31 cm.

Orientador: Susan Schommer.  
Trabalho de conclusão de curso (graduação) – Universidade Federal do Rio  
de Janeiro, Instituto de Economia, Bacharel em Ciências Econômicas, 2022.  
Bibliografia: f. 69-70.

1. Taxa de câmbio. 2. Volatilidade. 3. Modelo GARCH. I. Schommer, Susan,  
orient. II. Universidade Federal do Rio de Janeiro. Instituto de Economia. III. Título.

CDD 332.456

Ficha catalográfica elaborada pelo bibliotecário: Bruna Amarante Oliveira CRB 7 – 6602  
Biblioteca Eugênio Gudin/CCJE/UFRJ

JOÃO VICTOR DE SOUZA DUARTE

VOLATILIDADE CAMBIAL NO BRASIL: UMA ANÁLISE PARA O PERÍODO DE 2008-  
2021

Trabalho de conclusão de curso apresentado  
ao Instituto de Economia da Universidade  
Federal do Rio de Janeiro, como requisito  
para a obtenção do título de Bacharel em  
Ciências Econômicas.

Rio de Janeiro, 05 de agosto de 2022.

---

SUSAN SCHOMMER - Presidente  
Professora Dra. do Instituto de Economia da UFRJ

---

MARGARIDA MARIA GOMES PEREIRA SARMIENTO GUTIERREZ  
Professora Dra. da COPPEAD da UFRJ

---

PEDRO JAMES FRIAS HEMSLEY  
Professor Dr. do Instituto de Economia da UFRJ

Dedico esse trabalho aos meus pais e à minha  
irmã, os quais sempre me apoiaram em todas as minhas  
decisões.

## **AGRADECIMENTOS**

Agradeço aqui aos meus pais, Janete Simplício de Souza e João Carlos da Silva Duarte, que me apoiaram emocionalmente e financeiramente durante minha jornada de estudos. Agradeço também à minha irmã, Juliana de Souza Duarte, por ter me auxiliado e acredito que poderia realizar o sonho de estudar em uma Universidade Federal. Eu amo muito vocês. Obrigado.

***“You know very well who you are, don't let 'em hold you down.  
Reach for the stars.” (Notorius BIG, Rapper americano)***

## **RESUMO**

Desde a adoção do regime de câmbio flutuante, a economia brasileira sofreu e sofre com problemas relacionados às altas volatilidades em sua taxa de câmbio. Em especial nos períodos que antecederam as eleições de 2002, em 2015 e na pandemia provocada pela COVID-19 em 2020, o preço do dólar passou a ganhar muito enfoque na mídia e cada vez mais atenção dos brasileiros. O presente trabalho tem por objetivo analisar e modelar a taxa de câmbio real brasileira para o período de 2008-2021. Diante do modelo GARCH estimado, concluímos que as volatilidades extraídas foram consequências de cenários políticos conturbados e erros de condução de política econômica.

**Palavras-chave:** Câmbio; Volatilidade; ARIMA; GARCH

## **ABSTRACT**



Since the adoption of the floating exchange rate regime, the Brazilian economy has suffered and still suffers from problems related to high volatilities in its exchange rate. Especially in the periods leading up to the 2002 elections, in 2015 and in the pandemic caused by COVID-19 in 2020, the price of the dollar began to gain a lot of focus in the media and more and more attention from Brazilians. The present work aims to analyze and model the Brazilian real exchange rate for the period 2008-2021. In view of the estimated GARCH model, we conclude that the volatilities extracted were consequences of troubled political scenarios and errors in the conduct of economic policy

**Keywords:** Exchange Rate; Volatility; GARCH

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b>	<b>12</b>
1.1	OBJETIVOS	13
<b>2</b>	<b>REVISÃO BIBLIOGRÁFICA</b>	<b>14</b>
2.1	O SISTEMA MONETÁRIO INTERNACIONAL E SUA EVOLUÇÃO	14
2.2	REGIMES CAMBIAIS	16
2.3	VOLATILIDADE DA TAXA DE CÂMBIO REAL CAUSAS E CONSEQUÊNCIAS	16
<b>3.</b>	<b>SÉRIES TEMPORAIS</b>	<b>18</b>
3.1	ESTACIONARIEDADE	18
3.1.1	Raiz Unitária	20
3.1.2	Dickey-Fuller	21
3.1.3	Dickey-Fuller Aumentado	23
3.1.4	KPSS	23
3.1.5	Função de Autocorrelação e Autocorrelação Parcial	24
3.1.6	Teste Ljung-Box	25
3.2	MODELOS LINEARES	25
3.2.1	Médias Móveis - MA	25
3.2.2	Processos Auto Regressivos - AR	27
3.2.3	Processos Auto Regressivos de Médias Móveis - ARMA	27
3.2.4	Modelo Auto Regressivo, Integrado e de Médias Móveis - ARIMA	28
3.2.5	Critérios de Informação	29
3.3	MODELOS NÃO-LINEARES	30
3.3.1	Modelos ARCH	31
3.3.2	Modelos GARCH	31
<b>4</b>	<b>MODELAGEM DE VOLATILIDADE CAMBIAL</b>	<b>32</b>
4.1	BASE DE DADOS E TRATAMENTO	32
4.2	ANÁLISE E DESCRIÇÃO DA SÉRIE EM NÍVEL	33
4.3	DIFERENCIAÇÃO E MODELAGEM	36
4.4	MODELAGEM DA VOLATILIDADE	45
4.5	DIAGNÓSTICO DO MODELO	55
4.6	CONSIDERAÇÕES FINAIS	61

**REFERÊNCIAS**

62

**APÊNDICES**

63

## 1 INTRODUÇÃO

Diante de um mundo cada vez mais globalizado e com inúmeras crises financeiras já registradas na história, é de suma importância as discussões acerca das políticas econômicas e cambiais que os países adotam. Nesse sentido, dada a relativa facilidade de realizar transações cambiais nos mercados financeiros globais, torna-se cada vez mais difícil, para os banqueiros centrais, manter uma certa estabilidade cambial aliada com uma política monetária que seja independente.

Quando se aproximava o fim da Segunda Guerra Mundial, em 1944, as principais potências capitalistas da época, lideradas pelos Estados Unidos, buscavam regular a economia mundial por meio da cooperação entre os países. Com instabilidade causada pelo padrão-ouro, estabeleceu-se um acordo entre as políticas monetárias dos países de modo a manter uma paridade das moedas nacionais com relação ao ouro. Iniciava-se o sistema de *Bretton Woods*. Todavia, já na década de 1960, o sistema começa a perder sua força especialmente pelo intenso conflito entre as duas principais nações da época, os Estados Unidos e a União Soviética.

Com a derrota militar americana na Guerra do Vietnã (1965-1975), a estabilidade do dólar é posta em cheque o que, conseqüentemente, também colocou *Bretton Woods* em uma situação crítica visto que o dólar tinha seu lastreamento em ouro na proporção de 31 gramas do material para cada 35 dólares americanos. Em 1971, o presidente Nixon Shock altera a imposição do sistema de conversão no minério, causando um colapso do sistema vigente. Nesse sentido, a partir da década de 1970, as moedas fizeram sua migração para o sistema de câmbio flutuante e tendo o dólar como referência em relação ao ouro.

Com a adoção do regime flutuante, as economias viram suas moedas tornarem-se cada vez mais instáveis e menos previsíveis. Tal preocupação é justificável haja vista os muitos trabalhos que mostram que a volatilidade cambial pode afetar variáveis reais da economia, como o crescimento, exportação e investimento.

DARBY *et al.* (1999), analisa dados para os países europeus e concluem que a volatilidade cambial tem um importante impacto negativo no investimento. SERVÉN (2003)

realiza o mesmo estudo para os países em desenvolvimento e conclui que o impacto é significativamente negativo.

Em termos de fluxo de comércio, CHOWDHURY (1993), em uma análise realizada para os países do G-7, apresenta algumas evidências de que a volatilidade cambial prejudica as exportações.

Verifica-se, portanto, que a volatilidade da taxa de câmbio tem custos econômicos que não são desconsiderados. Esta seria uma justificativa para investigarmos as causas das tais instabilidades.

O trabalho será dividido em seis partes. Na primeira seção, analisa-se a evolução do Sistema Monetário Internacional e as possíveis causas da volatilidade da taxa de câmbio. Na segunda, apresenta-se os principais modelos de previsão de séries temporais. Na terceira, é apresentada uma discussão sobre os modelos de volatilidade cambial. Na quarta seção, a base de dados e os tratamentos econométricos. Na quinta, os resultados das análises e, na sexta, as considerações finais.

## 1.1 OBJETIVOS

Neste estudo objetiva-se analisar e modelar o comportamento da taxa de câmbio (TCR) da economia brasileira e da sua volatilidade no período de janeiro de 2008 até dezembro de 2021. Para tanto, serão utilizados dados diários de série de taxa de câmbio real e, a partir desta análise, poderemos modelar e estudar a volatilidade.

## **2. VOLATILIDADE CAMBIAL: TEORIAS E DISCUSSÕES**

### 2.1 O SISTEMA MONETÁRIO INTERNACIONAL E SUA EVOLUÇÃO

As relações comerciais, financeiras etc. entre os países surgem a partir de normas e regras que são estabelecidas pelas nações hegemônicas em sua época. Pode-se entender que o

seu desenvolvimento acontece para harmonizar as relações entre os países e com caráter de igualdade e, por vezes, moldado para objetivar interesses de nações líderes, como expõe Marinho (2007).

Segundo Marinho (2007), a eclosão da Primeira Guerra Mundial põe em xeque o Sistema Monetário Internacional (SMI) existentes na época, o padrão-ouro. Ao financiar os seus gastos militares com a emissão de moeda e reduções tanto na força de trabalho quanto na capacidade produtiva, a economia mundial passa por um período que resultou em altas taxas inflacionárias e o quadro mundial torna-se incompatível com o padrão-ouro. As autoridades britânicas à época buscaram duas soluções para o problema: a) propõem taxas de juros mais altas, inclusive na Grã-Bretanha; b) instituição do padrão câmbio-ouro, no qual os bancos centrais dos países poderiam deter uma parte considerável de suas reservas em libra esterlina. Tal sistema não vigorou e em 1939 eclode a Segunda Guerra Mundial.

Busca-se, novamente, o estabelecimento de um arranjo internacional que fosse consistente e suportasse períodos de tensões políticas e econômicas (OLIVEIRA;MAIA;MARIANO, 2008).

Em 1939, explode a Segunda Guerra Mundial e em 1944 percebe-se a necessidade da existência de uma ordem econômica internacional para o Ocidente (MARINHO, 2007). Em fevereiro de 1942, acontece a Conferência do Atlântico de Ajuda Mútua, onde Estados Unidos e Inglaterra, em meio à guerra, iniciam planos de reestruturação econômica. Esses planos são consolidados em Bretton Wood em dois planos: “Plano Keynes” e “Plano White”.

Os americanos impuseram a sua hegemonia e fizeram prevalecer o Plano White. Bretton Wood foi um mix dos dois, porém prevalecendo um pouco mais o Plano Americano.

De forma resumida, o Plano Keynes propunha a criação de uma Câmara de Compensações Internacionais (International Clearing Union, ICU), um tipo de Banco Central dos bancos centrais, que de posse de um grande volume de recursos e centralizando o sistema de pagamentos em âmbito global, teria a função de corrigir os desequilíbrios dos balanços de pagamentos dos países de forma ordenada, contemplando credores e devedores.. (Oliveira, Maia e Mariano, 2008, p. 199).

“O Plano White, por outro lado, propunha o restabelecimento do ouro como instrumento de reserva internacional. Sugeriu, ademais, um regime de paridades cambiais fixas, como Keynes, porém ajustáveis sob condições excepcionais...” (Oliveira, Maia e Mariano, 2008, p. 201).

Marinho (2007) afirma que um dos grandes feitos de Bretton Wood foi a criação do Fundo Monetário Internacional (FMI) e do Banco Mundial. Ambos surgem para garantir “uma trajetória relativamente equilibrada das balanças de pagamentos e estável quanto às relações cambiais” (LICHTENSZTEJN e BAER, 1987, p.31).

Belluzo (2016) afirma que as instituições mencionadas nasceram com seus papéis regulatórios inferiores aos desejados por Keynes e White. Sendo assim, a função de regulação da liquidez e prestador de última instância, que havia sido proposta por Keynes para na figura de uma *Clearing Union*, passa para as mãos do Federal Reserve. Com isso, garantindo a função de prestador, a economia americana começou a sentir os efeitos da ascensão dos países parceiros/competidores, como o Japão e a Alemanha, os quais reconstruíram seus sistemas industriais e empresariais e, assim, os periféricos ganharam mais força no volume do comércio internacional.

Neste contexto, a partir do início dos anos 70, a economia americana começa a registrar sucessivos saldos negativos em sua balança de pagamentos e déficits em sua balança comercial. As pressões sobre o dólar se intensificaram e já em 1971 Nixon suspendeu a sua conversão a uma taxa fixa em ouro e passou a vigorar o sistema de “flutuações sujas”.

## 2.2 REGIMES CAMBIAIS

Diversos fatores podem afetar a taxa de câmbio, dentre eles os regimes cambiais. Estes podem ser divididos em três grandes grupos: regimes de câmbio flutuante, paridade flexível e paridade rígida.

Segundo Terra (2013), os regimes de câmbio flutuante podem ser divididos entre: flutuação livre e flutuação gerenciada ou “suja”. As flutuações livres acontecem quando a taxa de câmbio é determinada pelo nível de oferta e demanda de divisas, sem haver a intervenção do governo nesse mercado. Já os regimes onde prevalece a flutuação “suja” a taxa de câmbio é, em princípio, flutuante, mas o governo aplica intervenções pontuais para evitar variações excessivas nas suas taxas.

Terra (2013) aponta, ainda, que os regimes de paridade flexível podem ser divididos em bandas cambiais, paridade móvel e câmbio fixo. Nas bandas cambiais o câmbio pode flutuar dentro de um intervalo anunciado e o governo intervém sempre que essa banda for ultrapassada. As bandas podem ser: móveis ou horizontais. Em regimes de bandas cambiais horizontais o câmbio flutua em torno de uma paridade fixa. Já nas móveis, a paridade na qual o câmbio flutua segue uma tendência, a qual pode ser de valorização ou desvalorização. A paridade móvel os ajustes cambiais são condicionados a uma programação previamente anunciada”, ou seja, são condicionados a indicadores selecionados. No câmbio fixo, o governo se compromete a intervir no mercado de câmbio e usar sua política de juros para manter o câmbio a níveis pré-estabelecidos.

Ainda em Terra (2013), os regimes de paridade rígida são: caixa de conversão, onde há comprometimento legal em manter a paridade da taxa de câmbio; dolarização, onde um país adota a moeda de um outro país como a principal em seu próprio país; e União Monetária, onde indivíduos compartilham a mesma moeda e geram acordos em comum.

### 2.3 VOLATILIDADE DA TAXA DE CÂMBIO REAL: CAUSAS E CONSEQUÊNCIAS

No debate teórico e empírico sobre o tema, muitas são as explicações para as causas da volatilidade cambial.

Calvo e Reinhart (2002) argumentaram que diversos países anunciam permitir que suas taxas de câmbio sejam flutuantes, porém muitas vezes não o fazem, o chamado *fear of floating* (medo de flutuar). Os autores apontam como uma das explicações deste medo, que é uma das características de um país emergente como o Brasil, a falta de credibilidade nas autoridades monetárias, em particular em relação à condução de sua política monetária.

Rocha e Curado (2011) apontam que os problemas de credibilidade podem se manifestar de diversas formas, uma delas é o aumento da volatilidade cambial e na piora da percepção de risco sobre a capacidade de arcar com as dívidas nacionais, além de aumentar a dolarização da dívida e limitação na capacidade de atuação dos bancos centrais como emprestadores de última instância.

Hau (2002) aponta também para uma das causas da volatilidade da taxa de câmbio real, o grau de abertura comercial. A justificativa de tal argumento dá-se que quanto menor o grau de abertura, maior será o impacto de choques macroeconômicos nas movimentações do câmbio. Uma elevada participação de bens não transacionáveis na composição dos índices de



preços, dado que os preços desses bens são rígidos em relação a choques monetários e cambiais, o seu ajustamento seria lento e incompleto.

Do ponto de vista das consequências da volatilidade cambial, Côté (1994) aponta que a volatilidade cambial tem efeitos diretos e indiretos sobre o comércio internacional. Diretos por meio do aumento da incerteza e dos custos de ajustamentos e, indiretos, por meio da alocação de recursos e das políticas de Governo. Sendo assim, aumentos inesperados na volatilidade da moeda podem levar os agentes mais avessos ao risco a reduzirem as suas atividades comerciais. Por outro lado, há autores que apontam que esta relação negativa entre instabilidade cambial e comércio internacional não é tão clara. Ao invés de resultar em maior incerteza e inibirem o comércio, a instabilidade cambial gera oportunidades para diversificação de *portfolio* de risco, o que aumentaria suas expectativas de retornos futuros. Segundo os autores, isso aconteceria em países desenvolvidos e com mercados financeiros altamente eficientes.

Uma segunda consequência para a economia causada pela volatilidade cambial é quanto a sua relação com os investimentos. Não há consenso. Todavia, em alguns estudos apontam que um câmbio instável causa incerteza ao ambiente econômico e, por consequência, uma diminuição nos investimentos. Dal Bianco e Loan (2017) analisam a influência do preço e da volatilidade cambial para os investimentos estrangeiros diretos (*FDI*) para 10 países Latinos Americanos e o Caribe. Utilizando de modelo GARCH, o investimento direto, mensurado como percentual do PIB, e os preços, a volatilidade do câmbio real, abertura comercial, desenvolvimento da infraestrutura e abertura comercial como variáveis independentes, os autores concluíram a existência de uma relação negativa da volatilidade cambial com os influxos de investimentos nestes países.

Fica claro, portanto, que inúmeros são os fatores que afetam a volatilidade da taxa de câmbio de uma economia. Além disso, suas consequências são enormes também não são desprezíveis. Torna-se importante, nesse sentido, que a volatilidade cambial seja uma variável cada vez mais estudada.

### 3. SÉRIES TEMPORAIS

Uma série temporal pode ser descrita, de maneira bastante geral, como um vetor  $\mathbf{X}(t)$ , onde  $\mathbf{X}$  é um vetor  $n \times 1$  que representa o número de observações da série. (Morettin, Toloi, 2004).

As séries temporais podem ser estacionárias ou não estacionárias. Além disso, elas também podem ser estocásticas ou determinísticas. Uma série estacionária determinística é a mais simples, seguindo o padrão de uma constante,  $\mu \in \mathbb{R}$ , isto é (Bueno, 2012):

$$\mu_t = \mu$$

Se nela for acrescentado um componente aleatório independente extraído de uma distribuição normal,  $\mu_t \sim N(0, \sigma^2)$  (Bueno, 2012):

$$y_t = \mu + \mu_t$$

Já a série não estacionária preside uma tendência, a qual pode ser determinística ou estocástica. Determinística, quando acrescida de algum componente aleatório extraído de uma distribuição normal, flutuará em torno de uma tendência temporal (Bueno, 2012), tal qual o exemplo abaixo:

$$\mu_t = \mu + \mu_t + \mu_t$$

As não-estacionárias com tendências estocásticas movem-se em torno de médias flutuantes (Bueno, 2012), tal como abaixo:

$$\mu_t = \mu_{t-1} + \mu_t$$

### 3.1 ESTACIONARIEDADE

A estacionariedade é a ideia principal que deve-se estimar em uma série temporal (Bueno, 2012). Na prática, dificilmente encontramos uma série que seja totalmente estacionária, a maior parte das séries apresentam alguma forma de não-estacionariedade. De maneira geral, as séries apresentam algum tipo de tendência ao longo do tempo, sendo a mais comum a tendência linear, mas também pode ter uma tendência explosiva, um caso comum é o crescimento de uma colônia de bactérias. (Morettin, Toloi, 2004).


Segundo Bueno(2012), uma série temporal será considerada fracamente estacionária se:

1.  $\sum_{j=0}^{\infty} |\mu_j| < \infty$
2.  $\mu(\mu_j) = \mu$ , para todo  $j \in \mathbb{Z}$ ; e
3.  $\mu(\mu_j - \mu)(\mu_{j-k} - \mu) = \mu_j$

Em resumo, a primeira condição afirma que a série não pode ter o seu segundo momento centrado infinito. A segunda que a média é igual para todo o período. E a terceira estabelece que a variância da série é constante para todo o período.

As séries estacionárias e não estacionária que não apresentam comportamentos explosivos são denominadas *homogêneas*, ou seja, a série pode até ser estacionária, flutuando ao redor de uma média, mas em determinado momento a sua flutuação passa a ser em torno de uma outra média, ou mudar até a sua inclinação (Morettin, Toloí, 2004)

**Figura 1 – Série não-estacionária quanto ao nível e a inclinação**



Fonte: Morettin, Toloí (2011, p. 5).

Segundo Morettin e Toloí (2004), a maioria das séries temporais não apresenta um padrão de estacionaridade. Como a maioria dos modelos e procedimentos de análise de séries temporais pressupõe a sua existência, é necessário realizar uma transformação nos dados originais para transformá-las em estacionárias. Para isso, o procedimento mais comum é tomarmos sucessivas diferenças da série original. Na primeira diferença de uma série  $Z(t)$  temos:

$$\Delta Z(t) = Z(t) - Z(t - 1)$$

a segunda diferença é:

$$\Delta^2 Z(t) = \Delta[\Delta Z(t)] = \Delta[Z(t) - Z(t - 1)]$$

ou

$$\Delta^2 Z(t) = Z(t) - 2Z(t-1) + Z(t-2)$$

Generalizando, teremos que n-ésima diferença de  $Z(t)$  é:

$$\Delta^n Z(t) = \Delta[\Delta^{n-1} Z(t)]$$

### 3.1.1 Raiz Unitária

No presente trabalho, serão utilizados alguns testes para verificação da estacionariedade da série. Todavia, é necessário, antes, apresentarmos alguns conceitos importantes sobre identificação deste padrão nas séries.

Um deles é o conceito de raiz unitária. Se um processo estocástico apresentar uma de suas raízes polinomiais da sua equação característica igual a um, dizemos que este processo apresenta raiz unitária.

Basicamente, quando a série apresenta raiz unitária, os resultados tornam-se viesados, nos quais invalidam os pressupostos clássicos de média e variância constantes ao longo do tempo e, assim, dificultando a modelagem a partir de duas ou mais variáveis. Além disso, a série também apresentará permanência dos efeitos de choques sofridos nos instantes anteriores e não apresentará comportamento estacionário.

### 3.1.2 Dickey-Fuller

Uma das técnicas mais utilizadas para testar a existência de raízes unitárias em um processo estacionário foi descrito por Dickey e Fuller (1979). Denominaremos este teste de DF.

De modo geral, a ideia por trás do teste de DF é realizar a regressão de uma série que apresenta raiz unitária, tal como a abaixo:

$$Z_t = \alpha Z_{t-1} + \epsilon_t \quad -1 \leq \alpha \leq 1 \quad (1.1)$$

onde  $\epsilon_t$  é um ruído branco. A regressão será sobre o seu valor defasado (de um período),  $Z_{t-1}$ , e verifica-se se  $\alpha$  é estatisticamente igual a 1. Caso seja verdade, então  $Z_t$  não é estacionário. (GUJARATI, 2000).

Considerando (1.1), se subtrairmos  $\square_{\square-1}$  de ambos os lados, obteremos

$$\square_{\square} - \square_{\square-1} = (\square - 1)\square_{\square-1} + \square_{\square} \quad (1.2)$$

onde podemos reescrever como

$$\square\square_{\square} = \square\square_{\square-1} + \square_{\square} \quad (1.3)$$

em que  $\square = (\square - 1)$  e  $\square$  é a primeira diferença do operador. Na prática, estimamos a equação (1.3) e testamos a hipótese nula de  $\square = 0$  ou  $\square > 1$ . Se  $\square = 0$ ,  $\square = 1$  e temos presença de raiz unitária, logo, a série não é estacionária.

A maneira utilizada para a estimação é utilizando a estatística tau ( $\tau$ ), ou teste Dickey-Fuller (DF), conforme Gujarati (2000), existem três especificações para o teste. A primeira é de que a variável  $\square_{\square}$  é, na verdade, uma passeio aleatório, tal como representado em (1.3); ou um passeio aleatório com um deslocamento (*drift*), onde incluímos uma constante  $\square$  a equação (1.3), tal como:

$$\square\square_{\square} = \square_1 + \square\square_{\square-1} + \square_{\square} \quad (1.4)$$

ou até um passeio aleatório com deslocamento em torno de uma tendência determinística

$$\square\square_{\square} = \square_1 + \square_2\square + \square\square_{\square-1} + \square_{\square} \quad (1.5)$$

e em todos os casos temos as hipóteses que são:

(1) Hipótese nula:  $\square_0: \square = 0$

(2) Hipótese alternativa:  $\square_1: \square \neq 0$

se (1) significa a presença de raiz unitária ou série não estacionária; (2) série estacionária. O seu procedimento é a estimação da equação (1.3) pelo método de Mínimos Quadrados Ordinários (MQO), divide-se o coeficiente que foi estimado para  $\square_{\square-1}$  pelo seu erro padrão para computar a estatística tau e consultamos a tabela Dickey-Fuller. Se o valor absoluto da estatística tau exceder o seu valor crítico, temos a rejeição de  $\square_0$  e concluímos que a série é

não estacionária. Por outro lado, se o valor absoluto da estatística tau não exceder a estatística tau, temos a não rejeição da hipótese nula e, logo, a série é estacionário.

### 3.1.3 Dickey-Fuller Aumentado

A condução do teste DF é admitido que o termo de erro  $\varepsilon_t$  é não correlacionado. Para casos em que seja, recomenda-se a utilização da extensão do teste DF, o Dickey-Fuller Aumentado (ADF). A extensão, basicamente, adiciona valores defasados da variável dependente  $\Delta y_t$ . Para este caso, devemos especificar a seguinte expressão:

$$\Delta y_t = \alpha_1 + \alpha_2 y_t + \alpha_3 y_{t-1} + \sum_{i=1}^p \alpha_{i+1} \Delta y_{t-i} + \varepsilon_t \quad (1.6)$$

onde  $\varepsilon_t$  é um ruído branco e  $\Delta y_{t-1} = (y_{t-1} - y_{t-2})$ ,  $\Delta y_{t-2} = (y_{t-2} - y_{t-3})$  e assim por diante. A ideia é basicamente incluir termos de erro de diferença defasado suficientes para que os termos de (1.6) sejam não correlacionados e possamos obter um  $\alpha$  não viesado (GUJARATI, 2000). É importante frisarmos que o número de termos depende de algum critério de informação.

### 3.1.4 KPSS

Um problema que temos ao realizar os testes propostos por Dickey e Fuller é seu baixo poder, principalmente quando temos um componente de médias móveis que está perto do círculo unitário (Bueno, 2012). Sendo assim, quatro autores desenvolveram o teste KPSS Kwiatkowski, Phillips, Schmidt e Shin (1991). Basicamente, a hipótese nula é de estacionaridade da série contra de não estacionariedade da hipótese alternativa. A ideia dos autores é utilizar o teste de forma complementar ao teste de raiz unitária. Argumentando que, assim, podemos distinguir a raiz unitária das séries que não são totalmente conclusivas.

### 3.1.5 Função de Autocorrelação e Autocorrelação Parcial

Um outro teste de estacionariedade de extrema relevância é a função de autocorrelação, que nada mais é do que o gráfico da autocorrelação da série contra as suas defasagens.

A função de autocorrelação (ACF), com defasagem  $k$ , denotada por  $\rho_k = \frac{\gamma_k}{\gamma_0}$

onde  $\gamma_k$  é a covariância com a defasagem  $k$  e  $\gamma_0$  é a variância. Bueno (2012) afirma que a importância de conhecermos ACF é que ela nos permite identificar a ordem  $q$  de um processo MA. Já na função de autocorrelação parcial (PACF) elimina-se a correlação implícita entre duas observações. De maneira formal, PACF pode ser definida através de seguidas regressões no qual a sua série original tem a média subtraída:

$$\rho_k = \rho_{k,1}\rho_{k-1} + \rho_{k,2}\rho_{k-2} + \dots + \rho_{k,q}\rho_{k-q} + \epsilon_k, \quad k = 1, 2, \dots,$$

onde  $\epsilon_k$  é um erro.

Em suma, esse procedimento consiste na regressão de  $\rho_k$  contra o  $\rho_{k-1}$  e obtenção dos coeficientes estimados  $\hat{\rho}_{1,1}$ . Depois, deve-se regredir  $\rho_k$  contra  $\rho_{k-1}$  e  $\rho_{k-2}$  e obteremos os coeficientes  $\hat{\rho}_{2,1}$  e  $\hat{\rho}_{2,2}$  e assim por diante (BUENO, 2012).

Sabemos também que com o aumento da defasagem, a ACF de AR decai e a sua PACF é truncada a partir da defasagem  $p$ . Já no caso de MA ocorre o inverso: é truncado na defasagem  $q$  e PACF decai. Em ARMA (p,q) ambas decaem a partir da defasagem de truncagem. O quadro abaixo resume as condições apresentadas.

MODELO	FAC	FACP
AR (p)	Decai	Truncada na defasagem p
MA (q)	Truncada na Defasagem q	Decai
ARMA (p,q)	Decai se $j > q$	Decai se $j > p$

Fonte: Bueno (2012, p. 47)

### 3.1.6 Teste Ljung-Box

O teste Ljung-Box é utilizado para verificar a falha do ajuste de um modelo de série temporais aplicado a uma série temporal após o ajustamento de um modelo ARMA(p,q) aos dados (BUENO, 2012). O teste analisa  $m$  autocorrelações residuais. Caso as autocorrelações sejam pequenas, concluímos que não há uma falha do ajuste.

De modo geral, o teste Ljung-Box é especificado em duas hipóteses:

- i)  $\hat{\rho}_0$ : O modelo não exibe falha no ajuste;
- ii)  $\hat{\rho}_1$ : O modelo apresenta uma falha ao ajuste.

Dada uma série temporal  $Y$  de tamanho  $T$ , o teste estatístico é definido por

$$\hat{\rho}_j = \frac{\sum_{t=1}^{T-j} (Y_t - \bar{Y})(Y_{t+j} - \bar{Y})}{\sum_{t=1}^{T-j} (Y_t - \bar{Y})^2}$$

onde  $\hat{\rho}_j$  é a autocorrelação estimada da série no lag  $j$  e  $n$  é o número de lags utilizados.

## 3.2 MODELOS LINEARES

### 3.2.1 Médias Móveis - MA

Segundo Bueno (2012), um processo de Médias Móveis, MA, está sempre associado aos erros dos modelos e além disso os seus pesos também dependerão da sua importância nas observações passadas. Matematicamente, um processo de médias móveis MA(1) é definido como abaixo.

$$Y_t = \mu + \epsilon_t + \theta \epsilon_{t-1}$$

onde  $\epsilon_t$  é um termo de erro aleatório independente e identicamente distribuído (iid), também chamado de ruído branco, ou seja, tem média zero e variância constante e  $\theta$  é o seu peso.

Generalizando, o modelo de médias móveis para  $q$  defasagens:

$$Y_t = \mu + \epsilon_t + \theta_1 \epsilon_{t-1} + \theta_2 \epsilon_{t-2} + \dots + \theta_q \epsilon_{t-q}$$

onde, novamente,  $\epsilon_t \sim N(0, \sigma^2)$ . De maneira compacta, temos que o processo de médias móveis para  $q$  defasagens pode ser escrito como:

$$Y_t = \mu + \sum_{j=0}^q \theta_j \epsilon_{t-j}, \quad \theta_0 = 1 \quad (1.1)$$

É importante compreendermos se  $Y_t$  satisfaz a definição de estacionaridade. Para tal, calculamos a esperança e a variância dos processos.

$$E(Y_t) = \mu + \sum_{j=1}^q \theta_j E(\epsilon_{t-j}) = \mu$$



Realizando os cálculos, chegaremos a conclusão que a média de um processo MA(q) é a própria constante do modelo, ou seja,  $E(\hat{\mu}_t) = \mu$ . Podemos concluir, portanto, que o modelo de médias móveis terá sempre uma média estacionária pois os erros do modelo tem por característica média zero.

Já a variância, temos o seguinte:

$$E(\hat{\mu}_t - \mu)^2 = \sigma^2 \sum_{i=0}^q \theta_i^2 \quad (1.2)$$

Substituindo (1.1) e (1.2), temos

$$E(\hat{\mu}_t - \mu)^2 = \sigma^2 \left( \sum_{i=0}^q \theta_i^2 \right) = \sum_{i=0}^q \sigma^2 \theta_i^2 = \sigma^2 \sum_{i=0}^q \theta_i^2$$

Concluimos que, se o coeficiente  $\theta$  e o valor de  $q$  são finitos, podemos afirmar que não existe restrição para  $\sigma^2$ .

### 3.2.2 Processos Auto Regressivos - AR

Segundo Bueno (2012), um modelo autoregressivo de ordem  $q$  pode ser escrito como:

$$\hat{\mu}_t = \mu + \theta_1 \hat{\mu}_{t-1} + \theta_2 \hat{\mu}_{t-2} + \theta_3 \hat{\mu}_{t-3} + \dots + \theta_p \hat{\mu}_{t-p} + \epsilon_t$$

ou

$$\hat{\mu}_t = \mu + \sum_{i=1}^p \theta_i \hat{\mu}_{t-i} + \epsilon_t$$

onde  $\epsilon_t$  é um ruído branco,  $\epsilon_t \sim \text{WN}(0, \sigma^2)$ .

Neste modelo, é suposto que o valor atual da série é uma combinação linear dos seus  $p$  valores passados e de um ruído branco.

### 3.2.3 Processo Autorregressivo de Médias Móveis - ARMA

Considerando uma série descrita por processos de médias móveis e autorregressivos, temos que um modelo ARMA pode ser descrito como:

$$\begin{aligned} \hat{x}_t = & \phi_1 \hat{x}_{t-1} + \phi_2 \hat{x}_{t-2} + \dots + \phi_p \hat{x}_{t-p} + \hat{\epsilon}_t - \theta_1 \hat{\epsilon}_{t-1} \\ & - \theta_2 \hat{\epsilon}_{t-2} - \dots - \theta_q \hat{\epsilon}_{t-q} \end{aligned}$$

ou, de maneira sintética

$$\hat{x}_t = \hat{\epsilon}_t + \sum_{i=1}^p \phi_i \hat{x}_{t-i} + \sum_{j=0}^q \theta_j \hat{\epsilon}_{t-j}$$

assim, diz-se que  $\hat{x}_t$  é um processo autorregressivo de médias-móveis de ordem  $p$  e  $q$ , respectivamente, com parâmetros  $\phi'$  e  $\theta'$ .

Bueno (2012) afirma que a estacionaridade de modelos ARMA é necessário que suas raízes dos processos AR e MA estejam simultaneamente fora do círculo unitário.

### 3.2.4 Modelo Autorregressivo, Integrado e de Médias Móveis - ARIMA

O modelo ARIMA é útil quando temos o intuito de modelar séries não-estacionárias e não explosivas. Segundo Morettin e Tolo (2004), as estratégias para a construção de um modelo é baseada em um ciclo iterativo onde a escolha é baseada nos próprios dados. Os ciclos são:

- (a) Uma classe geral de modelos é considerada para a análise
- (b) Identifica-se o modelo, baseando-se na autocorrelação, autocorrelação parcial e outros critérios
- (c) Estima-se os parâmetros do modelo
- (d) Finalmente, realiza-se o diagnóstico do modelo, através de análise dos resíduos para saber se foi adequado para os fins propostos (previsão, por exemplo).

Segundo Morettin e Tolo, seja um série  $\hat{x}_t$  qualquer, se tomarmos um número finito de diferenças,  $d$ , tornam-se estacionárias, são denominadas não-estacionárias homogêneas, ou ainda, portadoras de raízes unitárias.

O modelo ARIMA pode ser descrito pela seguinte equação:

$$\phi(\hat{x}) \hat{x}_t = \theta(\hat{\epsilon}) \hat{\epsilon}_t$$

no qual  $\phi(\cdot)$  é o operador autorregressivo de ordem  $p$ ;  $\psi(\cdot)$  é o operador de médias móveis de ordem  $q$ ;  $d$  representa as diferenças tomadas em relação a série original; e  $\epsilon_t$  um ruído branco.

### 3.2.5 Critérios de Informação

Critérios de informações são a forma de encontrar o número ideal de parâmetros dentro de um modelo (Bueno, 2012). Nesse sentido, devemos ter em mente que a cada regressor adicionado ao modelo, a soma dos resíduos diminuirá. Para balancear a redução dos erros e um aumento no número de parâmetros, aplica-se uma penalidade a este aumento. Se a penalidade for menor do que a diminuição dos resíduos, o parâmetro deve ser utilizado. Caso contrário, não deverá ser utilizado. É importante salientarmos que o princípio da parcimônia deve ser sempre levado em consideração na modelagem, priorizando o menor número de parâmetros possíveis e satisfazendo a condições que os resíduos sejam os menores possíveis.

Segundo Bueno (2012), os critérios de informação tem a seguinte forma:

$$CIC = \sum_{t=1}^n \hat{\epsilon}_t^2 + \lambda \cdot p$$

onde  $\hat{\epsilon}_t^2$  é a variância dos resíduos;  $p$  é o número de parâmetros; e  $\lambda$  é a ordem do processo, o qual penaliza a falta de parcimônia.

Temos três critérios de informação: a estatística Schwarz, também chamado de *BIC* (*Bayesian Information Criterion*); Akaike, denotado por *AIC* (*Akaike Information Criterion*); e Hannan-Quinn, *HQ*. Suas respectivas expressões podem ser visto como abaixo.

$$CIC(n, p) = \sum_{t=1}^n \hat{\epsilon}_t^2 + \lambda \frac{p^2}{n}$$

onde  $n = p + q$ , se o modelo não houver constantes e  $n = p + q + 1$  caso haja constantes. Caso haja constantes, temos ainda que:

$$\hat{\epsilon}_t^2 = \frac{\sum_{t=1}^n \hat{\epsilon}_t^2}{n}$$

A estatística Akaike pode ser denotada como segue abaixo

$$CIC(n, p) = \sum_{t=1}^n \hat{\epsilon}_t^2 + \lambda \frac{2}{n}$$

e HQ, temos:

$$HQ(\hat{\beta}, \hat{\sigma}^2) = \sum_{i=1}^n \hat{\sigma}^2 + \frac{2}{n} \sum_{i=1}^n \hat{\sigma}^2$$

Quanto maior o número de parâmetros, menor será o erro estimado, porém isso será penalizado na estatística escolhida. Logo, deseja-se sempre utilizar o menor *AIC*, *HQ* ou *BIC* possível.

### 3.3 MODELOS NÃO-LINEARES

A incerteza assume um papel de suma importância no âmbito do mercado financeiro. Gestores de recursos, por exemplo, visando proteger suas carteiras, monitoram constantemente a volatilidade do seu *portfólio* e até buscam realizar previsões da mesma.

As séries financeiras, como de preço de ações, taxas de câmbios, taxas de inflação etc. apresentam o que se denomina de aglomeração por volatilidade, ou seja, períodos de grandes oscilações seguido por períodos onde há relativa calma. (GUJARATI, 2000)

O conhecimento de volatilidade das séries é de extrema importância para, por exemplo, tomadores de decisão de investimentos analisarem o comportamento futuro da inflação. Caso a sua variabilidade seja alta, torna o planejamento financeiro difícil para os agentes.

Para importadores e exportadores, os quais podem obter grandes lucros ou prejuízos com a alta da taxa de câmbio, caso não realizem posições de proteção cambial (*hedge*) no mercado.

Nesse sentido, percebeu-se, por volta dos anos de 1980, que os modelos que assumiam como hipótese as médias e variâncias como constantes ao longo do tempo, não eram mais capazes de modelar os comportamentos futuros de alguns tipos específicos de séries temporais, notadamente as financeiras e algumas econômicas.

Nesse contexto, Engle (1982) introduziu o conceito dos processos auto regressivos que consideravam médias e variâncias como não constantes ao longo do tempo, o modelo ARCH. Posteriormente, Bollerslev (1986) deu origem ao Generalized ARCH, ou GARCH, como é conhecido.

### 3.3.1 Modelos ARCH

Segundo Morettin e Tolo (2004), a ideia básica de modelos Autorregressivo com heterocedasticidade condicional é que o retorno  $\varepsilon_t$  de uma série é não-correlacionado serialmente, mas a sua volatilidade, que é a variância condicional, depende dos seus retornos por meio de uma função quadrática. A especificação de um modelo ARCH (r) é a seguinte:

$$\varepsilon_t = \sqrt{h_t} \varepsilon_t$$

$$h_t = \omega_0 + \alpha_1 \varepsilon_{t-1}^2 + \dots + \alpha_p \varepsilon_{t-p}^2$$

onde  $\varepsilon_t$  é uma sequência de variáveis i.i.d com média zero e variância igual à 1,  $\omega_0 > 0$ ,  $\alpha_i \geq 0$ ,  $\alpha > 0$ .

Ainda em Morettin e Tolo (2004), os autores realizam algumas deduções acerca das propriedades do modelo. Omitidas tais deduções, temos que:

- (i)  $E(\varepsilon_t) = 0$
- (ii)  $E(\varepsilon_t^2) = \frac{\omega_0}{1 - \alpha}$
- (iii)  $E(\varepsilon_t^4) = 0, \alpha \geq 1$ ,

o que nos indica que  $\varepsilon_t$  é, na verdade, uma sequência de variáveis aleatórias não correlacionadas com média zero e variância dada pela expressão (iii).

### 3.3.2 Modelos GARCH

Segundo Morettin e Tolo (2004), o modelo GARCH, sugerido por Bollerslev (1986), detém a vantagem de modelar volatilidade com uma quantidade de parâmetros menor do que o modelo ARCH, ou seja, é mais parcimonioso.

Um modelo GARCH(r, s) é definido por:

$$\varepsilon_t = \sqrt{h_t} \varepsilon_t$$

(1.3)

$$h_t = \omega_0 + \sum_{i=1}^r \alpha_i \varepsilon_{t-i}^2 + \sum_{j=1}^s \beta_j h_{t-j}$$

onde  $\alpha_i, \beta_j \in (0, 1)$ ,  $\omega_0 > 0$ ,  $\alpha_i > 0$ ,  $\beta_j \geq 0$ ,  $\sum_{i=1}^r \alpha_i + \sum_{j=1}^s \beta_j < 1$ ,  $\alpha = \sum_{i=1}^r \alpha_i$ ,  $\beta = \sum_{j=1}^s \beta_j$ .

Ainda em Morettin e Tolo (2004), usualmente, supomos que  $\varepsilon_t \sim \varepsilon(0, 1)$  ou  $\varepsilon_t \sim \varepsilon(\mu, \sigma)$  e seja  $\varepsilon_t^2 = \varepsilon_t^2 - h_t$ , podemos obter, ao substituímos em (1.3),

$$\sigma_{\varepsilon_t}^2 = \sigma_0 + \sum_{i=1}^p (\alpha_i + \beta_i) \sigma_{\varepsilon_{t-i}}^2 + \sigma_{\varepsilon_t} - \sum_{i=1}^p \alpha_i \sigma_{\varepsilon_{t-i}} \quad (1.4)$$

no qual

$$(i) \quad \sigma(\sigma_{\varepsilon_t}) = 0$$

$$(ii) \quad \sigma(\sigma_{\varepsilon_t}^2) = \frac{\sigma_0}{1 - \sum_{i=1}^p (\alpha_i + \beta_i)}$$

#### 4. MODELAGEM DE VOLATILIDADE CAMBIAL

Neste capítulo daremos início a modelagem. Sendo assim, o passo-a-passo será elucidado nas próximas seções.

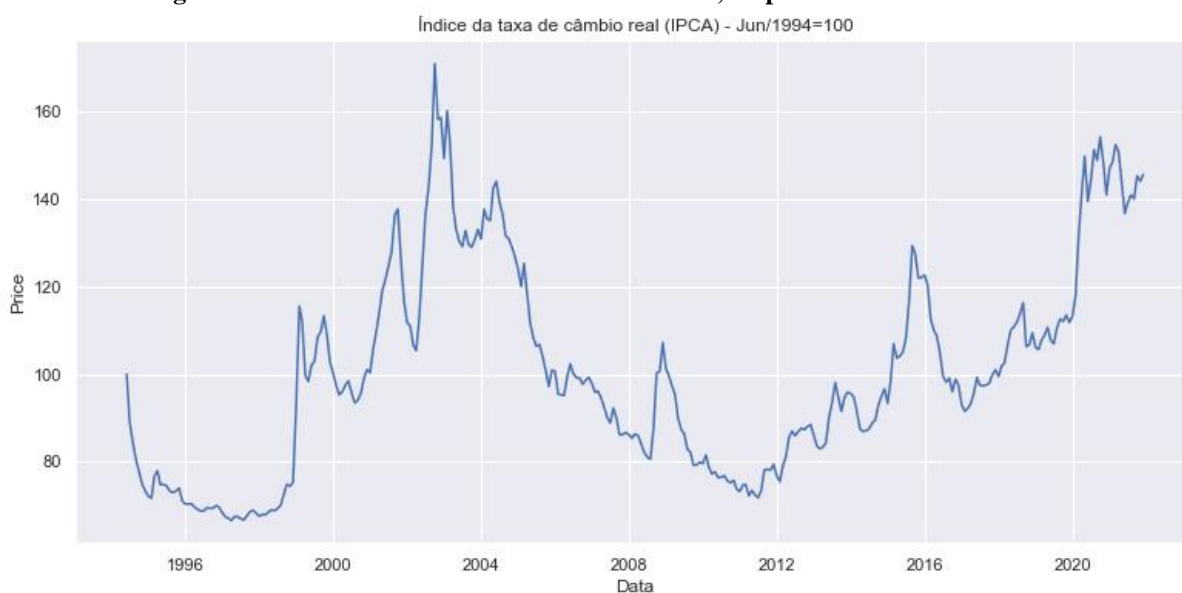
##### 4.1 BASE DE DADOS E TRATAMENTO

Para a realização do estudo, primeiro foi necessário a coleta de dados. Para isso, utilizou-se o índice Índice da taxa de câmbio real, o qual reflete a Taxa de Câmbio Real da economia brasileira, ou seja, considerando a inflação interna e externa para o período de 1º de janeiro de 2008 até o final de 2021. A taxa de câmbio real foi escolhida devido a sua vantagem ao considerar a inflação interna e externa no seu cálculo, o que resulta no seu melhor poder de previsão. Além disso, é fato estilizado que a taxa de câmbio nominal é nada além de um passeio aleatório e, portanto, não existe uma tendência de reversão a média. Disponível no Sistema Gerenciador de Séries Temporais (SGS), no site do Banco do Central do Brasil (BCB), o índice foi escolhido pois possibilita uma melhor referência para o valor da moeda, o que possibilita uma melhor modelagem da volatilidade. É importante ressaltarmos que os dados disponíveis na série começaram em agosto de 1994 com base 100. Realizou-se um corte para a possibilidade do estudo. Dito isto, fez-se a análise da série em nível, construindo gráficos e verificando a existência de alguma tendência. Em seguida, realizou-se análise dos retornos e dos retornos quadráticos da série. Estimou-se um modelo ARMA(3,3) na tentativa de eliminar a dependência temporal dos valores. Por fim, modelou-se um GARCH(1,0,1) para os resíduos do modelo ARMA. Para a análise, utilizou-se a linguagem de programação *Python*.

##### 4.2 ANÁLISE E DESCRIÇÃO DA SÉRIE EM NÍVEL

A Figura 2 mostra um gráfico do índice da taxa de câmbio real brasileira, no período de 1994 até o final de 2021. É importante ressaltarmos que para este estudo será considerado apenas os valores de 2008 até o final de 2021.

**Figura 2 – Índice da taxa de câmbio real em nível, no período de 1994 até 2021.**



Fonte: Elaborado pelo autor, dados obtidos no site do BCB

Por meio da análise gráfico, podemos observar que a série não apresenta nenhuma tendência clara, oscilando entre períodos de altos e baixos, logo não estacionária.

Em seguida, realizou-se uma análise estatística dos dados, coletando valores de tendência central, ou seja, de média e mediana e valores de dispersão como mínimo, máximo, intervalo (*range*), *skew*, *kurtosis* e desvio padrão.

**Tabela 1 – Sumário estatística do Índice JBDCBRL**

Mínimo	66.32
--------	-------

Máximo	171.03
Intervalo	104.71
Média	100.151418
Mediana	98.61
Desvio padrão	22.370873
Skew	0.627833
Kurtosis	-0.166025

Fonte: Elaborado pelo autor, dados obtidos por meio linguagem *Python*

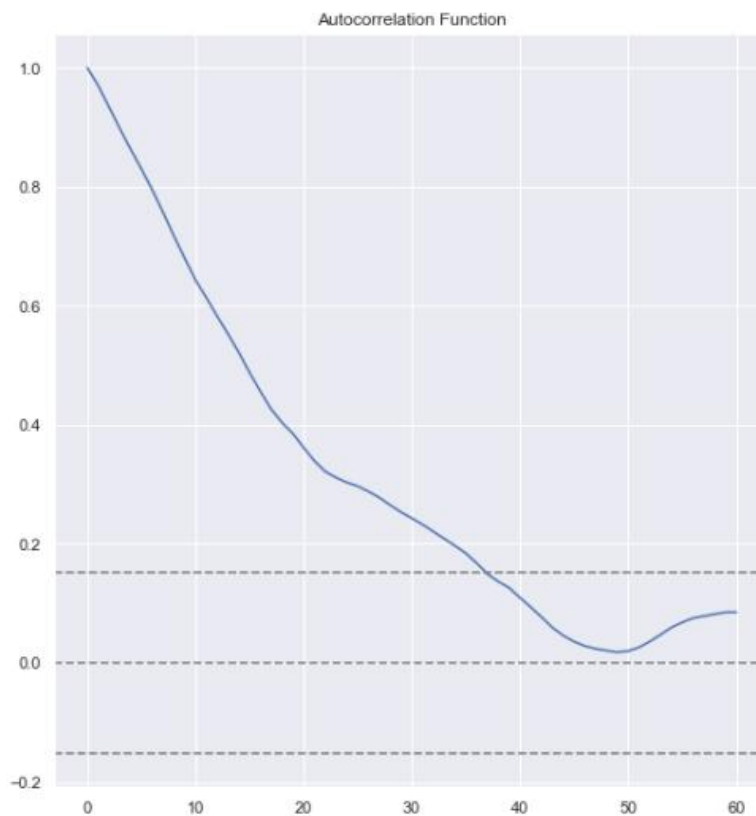
Todavia, apenas a análise visual não é válida. Faz-se necessário a análise de alguns testes estatísticos para análise da estacionariedade da série, como os testes de Dickey-Fuller e análise de correlograma, ambos explicitados na revisão bibliográfica.

Ao analisar a Função de Autocorrelação (ACF) da série em nível, observamos, de fato, que a série apresenta características de não-estacionariedade, dado que as defasagens (*lags*) não decaem de maneira exponencial. Para este caso, utilizamos 60 defasagens.

Realizando o teste Dickey-Fuller Aumentado percebemos que o valor  $p$  (*p-value*) da série não é inferior aos 5% de nível de significância. Sendo assim, não rejeitamos a hipótese nula de não-estacionariedade da série, ou seja, a série apresenta algum grau de dependência temporal e sua variância não é constante ao longo do tempo. Já ao realizarmos o teste KPSS, encontramos o mesmo resultado de não-estacionariedade da série. É importante salientar que, ao contrário do teste Dickey Fuller, KPSS tem a sua hipótese nula como estacionariedade da série, ou seja, ao rejeitarmos a hipótese nula (com base no valor- $p$  e os valores críticos) provamos a presença de raiz unitária.

**Figura 3 – Gráfico da função ACF da Série em nível entre 2008 e 2021.**





Fonte: Elaborado pelo autor, dados obtidos por meio linguagem *Python*

**Tabela 2 – Teste Dickey-Fuller Aumentado para Série em Nível**

Teste Estatístico	-0.789100
Valor-p	0.822303
Defasagens utilizadas	5
Número de observações usadas	161
Valor crítico (1%)	-3.471633
Valor crítico (5%)	-2.576434
Valor crítico (10%)	-2.576434

Fonte: Elaborado pelo autor, dados obtidos por meio linguagem *Python*

**Tabela 3 – Teste KPSS para Série em Nível**

Teste Estatístico	1.413534
-------------------	----------

Valor-p	0.01
Defasagens utilizadas	8
Valor crítico (1%)	0.739
Valor crítico (5%)	0.463
Valor crítico (10%)	0.347

Fonte: Elaborado pelo autor, dados obtidos por meio linguagem *Python*

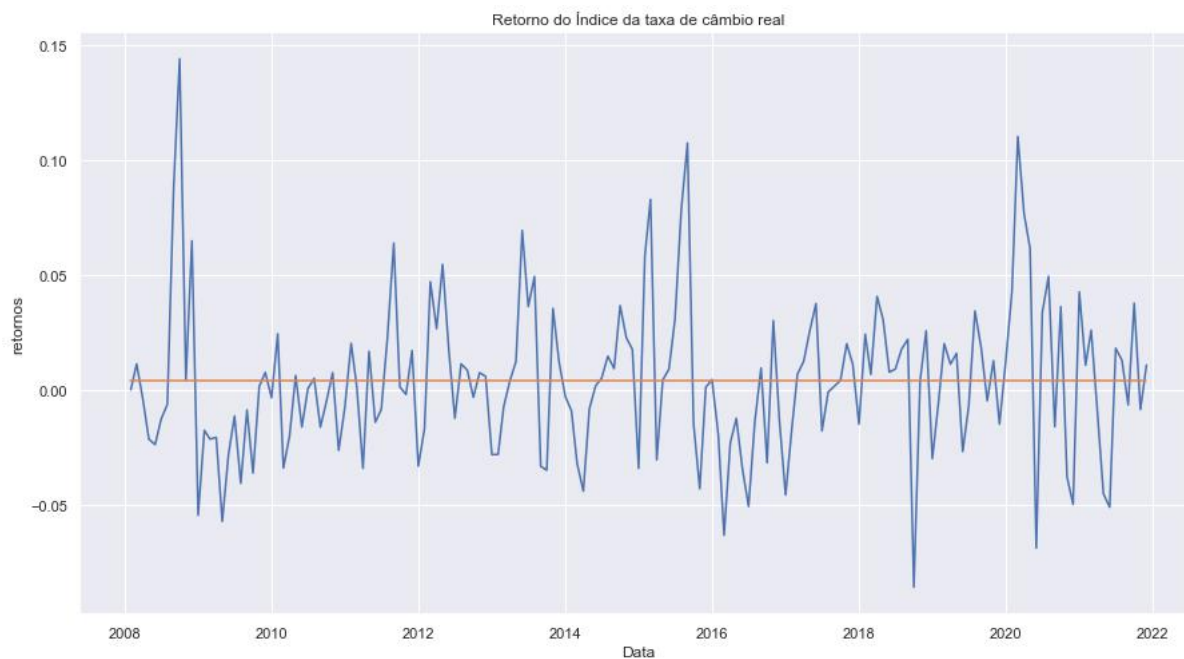
### 4.3 DIFERENCIAÇÃO E MODELAGEM

Após a comprovação da não-estacionariedade da série, torna-se necessário torná-la estacionária para a modelagem. Primeiramente, foi calculado o retorno do índice e o seu retorno ao quadrado e observou-se o comportamento da série. Apenas com a análise visual podemos enxergar algum tipo de estabilidade da série em torno de uma média, demonstrando uma certa estacionariedade. Além disso, também enxergamos períodos de picos e vales na série, manifestando uma possível presença de volatilidade. Todavia, como já dito, faz-se necessário a realização dos testes, assim como na série em nível.

Os testes são expressos nas Tabela 4 para Dickey-Fuller e Tabela 5, para KPSS, respectivamente. Para o primeiro, observamos um valor-p menor do que 5%, rejeitando a  $H_0$  de não-estacionariedade da série, ou seja, a série é estacionária. Já para o teste KPSS, observamos um p-valor maior do que 5%, ou seja, rejeitamos a hipótese alternativa de não-estacionariedade. Provando, assim, que apenas a primeira diferença se faz necessária para estacionarizar a série.

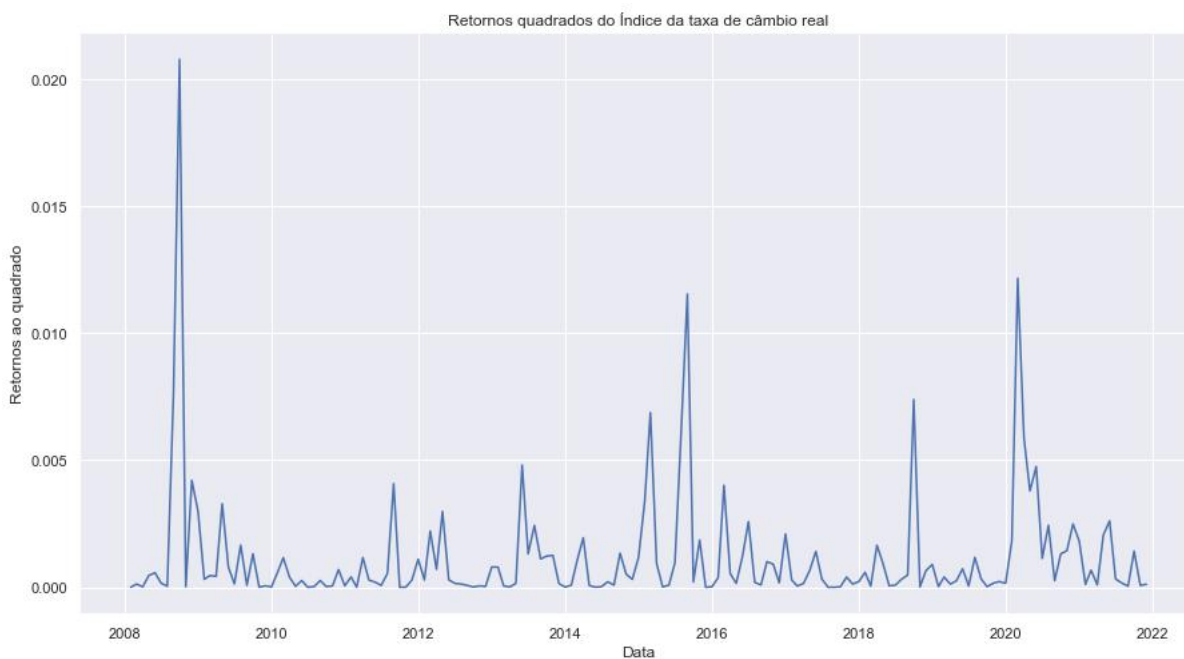
Dado a estacionariedade, a próxima característica que devemos investigar na série é sua correlação com seus valores passados. Para tal, realizamos o teste Ljung-Box, para um número de *lags* iguais a 60 e observamos o comportamento das funções de autocorrelação. Para o teste Ljung-Box, obtivemos um valor-p de 0.016078, ou seja, a série demonstra algum tipo de correlação serial.

**Figura 4 – Retornos do índice da taxa de câmbio real, no Período de 2008 até 2021.**



Fonte: Elaborado pelo autor, dados obtidos por meio linguagem *Python*

**Figura 5 – Retornos ao quadrado do índice da taxa de câmbio real, no Período de 2008 até 2021.**



Fonte: Elaborado pelo autor, dados obtidos por meio linguagem *Python*

**Tabela 4 – Teste Dickey-Fuller para os retornos**

Teste Estatístico	0.102237
Valor-p	9.905361e-17

Defasagens utilizadas	3
Número de observações usadas	1.66e+02
Valor crítico (1%)	-3,47037
Valor crítico (5%)	-2.879114
Valor crítico (10%)	-2.576139


Fonte: Elaborado pelo autor, dados obtidos por meio linguagem *Python*

**Tabela 5 – Teste KPSS para os retornos**

Teste Estatístico	0.102237
Valor-p	0.1
Defasagens utilizadas	3
Valor crítico (1%)	0,347
Valor crítico (5%)	0.463000
Valor crítico (10%)	0.347000


Fonte: Elaborado pelo autor, dados obtidos por meio linguagem *Python*

**Figura 6 – Função de Autocorrelação (ACF) e Autocorrelação Parcial (PACF) para os retornos**



Fonte: Elaborado pelo autor, dados obtidos por meio linguagem *Python*

**Figura 7 – Função de Autocorrelação (ACF) Autocorrelação Parcial (PACF) para os retornos ao quadrado**



Fonte: Elaborado pelo autor, dados obtidos por meio linguagem *Python*

Nesse sentido, como aponta Bueno (2012), um modelo GARCH  $(p,q)$  assemelha-se ao um modelo  $ARMA(\max(p,q), q)$ , de forma a tentar remover a correlação serial. Estimou-se, portanto, três modelos ARMA que estão especificados abaixo. Valendo-se do critério *Akaike*, o modelo escolhido foi o ARMA(3,3), apresentou o menor critério e também significância nos seus parâmetros. Os modelos ARMA(1,1) e ARMA(2,2) estão nos apêndices A e B, respectivamente.


**Tabela 6 – Sumário para o modelo ARMA(3,3)**

Fonte: Elaborado pelo autor, dados obtidos por meio linguagem *Python*

Como recomenda a literatura, prosseguiu-se com os testes nos resíduos do modelo ARMA(3,3) estimado. Ao realizarmos os correlogramas PACF e ACF dos resíduos do modelo, podemos observar os valores dentro do intervalo de confiança, demonstrando que os resíduos são um ruído branco. Para confirmar isso, podemos realizar um teste de Ljung-Box. Os resultados do teste foram uma estatística Ljung-Box de 20.268703 e um valor-p de

0.909357, como apresentados na Tabela 5. Podemos concluir, então, que os resíduos do modelo são ruídos brancos.

**Figura 8 – ACF e PACF para os resíduos do modelo ARMA(3,3)**



Fonte: Elaborado pelo autor, dados obtidos por meio linguagem *Python*

**Tabela 7 – Teste de Ljung-Box para os resíduos**

Teste Estatístico	20.268703
Valor-p do teste estatístico	0.909357

Fonte: Elaborado pelo autor, dados obtidos por meio linguagem *Python*

Por fim, podemos realizar o teste de heterocedasticidade Engle (1982). Basicamente o teste é baseado no fato de que se os resíduos do modelo são heterocedásticos, os mesmos, quando elevados ao quadrado, são autocorrelacionados. O primeiro tipo do teste trata-se de analisar se os resíduos quadráticos são uma sequência de ruídos brancos. O segundo tipo, que foi proposto por Engle, é o multiplicador de Lagrange que ajusta um modelo de regressão linear e examina se o modelo ajustado é significativo. A hipótese nula é que o quadrado dos resíduos são uma sequência de ruídos brancos, ou seja, os resíduos são homocedásticos. Realizando o teste, temos os resultados apresentados na tabela 7. Com o valor-p abaixo do nível de significância de 5%, rejeitamos a hipótese nula e, logo, os resíduos são heterocedásticos.

**Tabela 8 – Teste de heterocedasticidade de Engle para os resíduos**

Teste Estatístico	28.57432501938868
Valor-p do teste estatístico	0.000820150781439232

Fonte: Elaborado pelo autor, dados obtidos por meio linguagem *Python*

#### 4.4 MODELAGEM DA VOLATILIDADE

Dada a existência de heterocedasticidade nos resíduos do modelo ARMA estimado, se faz necessário o ajuste ao modelo GARCH. Para tal, foram estimados três modelos GARCH(1,0,1), GARCH(2,0,1) e GARCH(1,0,2), com diferentes distribuições: normal, t-Student e t-Student *skewed*; totalizando nove modelos estimados. Aquele escolhido foi o GARCH(1,1) com distribuição t-Student, pois apresentou o menor critério *Akaike* e também o menor critério *BIC* e os parâmetros significativos. É importante apontarmos que os estimadores do modelo foram obtidos pelo método de máxima verossimilhança condicional e os *inputs* do modelo foram a série de valores dos resíduos do modelo ARMA. O modelo GARCH escolhido apresentou os parâmetros abaixo, representado na tabela 9. Os outros modelos, estão nos apêndices.




**Tabela 9 – Sumário GARCH (1,1) com distribuição t-Student**

Fonte: Elaborado pelo autor, dados obtidos por meio linguagem *Python*

#### 4.5 DIAGNÓSTICO DO MODELO

Esta seção será destinada a verificação da adequação do modelo GARCH a série estudada, ou melhor, os resíduos do modelo estimado. O primeiro passo foi a realização do teste Ljung-Box, o qual apresentou um valor de estatística LB de 14.726503 e um valor-p de 0.791837. O teste demonstra, portanto, um valor acima dos 5%, o que nos permite afirmar a não-correlação dos resíduos do modelo, e nos gráficos podemos ver que a série dos resíduos ficou dentro do nível de significância na maior parte do tempo.

**Figura 9 – Gráficos PACF e ACF para os resíduos do modelo GARCH(1,1)**



Fonte: Elaborado pelo autor, dados obtidos por meio linguagem *Python*

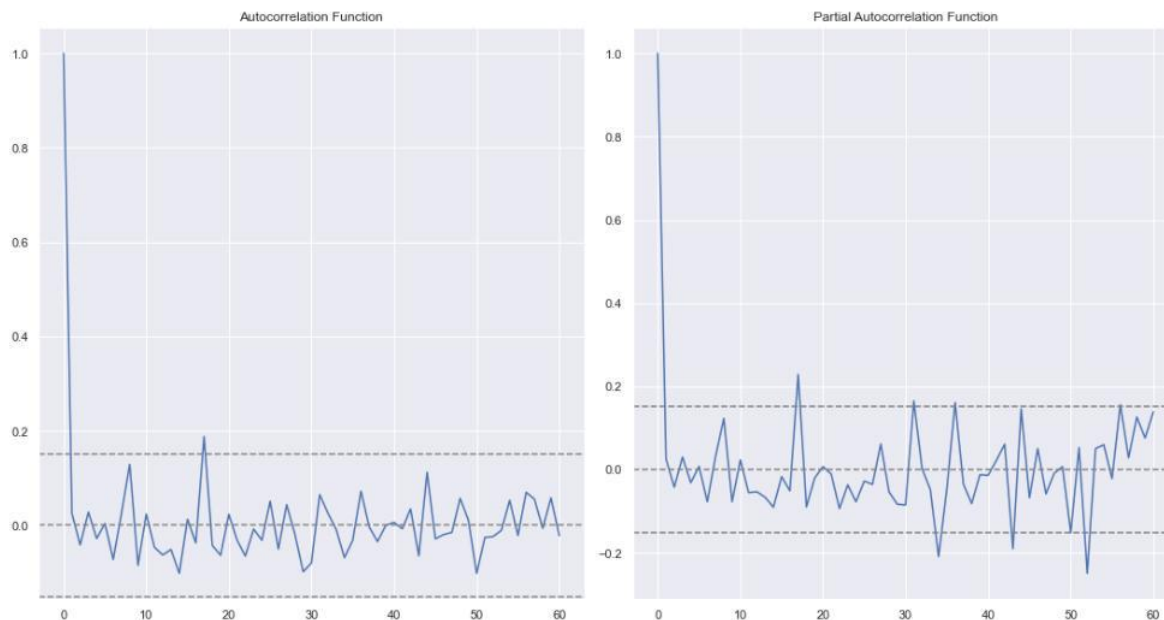
**Tabela 10 – Teste Ljung-Box para os resíduos do modelo GARCH(1,1)**

Estatística LB	15.405895
Valor-p do teste estatístico	0.75273

Fonte: Elaborado pelo autor, dados obtidos por meio linguagem *Python*

Um segundo teste que é necessário que analisemos se o modelo foi capaz de eliminar a heterocedasticidade dentro da série. Para tal, realizamos os mesmos ACF e PACF para os resíduos quadrados padronizados do modelo. Analisando também o teste de Ljung-Box apresentado na tabela 9, concluímos que de fato a série não apresenta nenhum tipo de heterocedasticidade.

**Figura 10 – Gráficos ACF e PACF para os resíduos quadráticos do modelo GARCH(1,1)**



Fonte: Elaborado pelo autor, dados obtidos por meio linguagem *Python*

**Tabela 11 – Teste Ljung-Box para os resíduos quadráticos do modelo GARCH(1,1)**

Estatística LB	20.11704
Valor-p do teste estatístico	0.913458

Fonte: Elaborado pelo autor, dados obtidos por meio linguagem *Python*


Por fim, realizou-se o teste de heterocedasticidade de Engle, ou teste ARCH-LM para os resíduos padronizados do modelo proposto. O valor-p encontrado foi de 0.68422 e a estatística-F encontrada foi de aproximadamente 0.74171. Provamos, assim, que o valor-p acima de 5% demonstra que o efeito ARCH não está mais presente na série.

**Tabela 12 – Teste de heterocedasticidade de Engle os resíduos do modelo GARCH(1,1)**

Estatística F	0.74171
Valor-p do teste estatístico	0.68422

Fonte: Elaborado pelo autor, dados obtidos por meio linguagem *Python*

**Figura 11 – Volatilidade Estimada pelo modelo GARCH (1,1)**



Fonte: Elaborado pelo autor, dados obtidos por meio linguagem *Python*

A grande volatilidade descrita pelo modelo entre as observações 0-260 representa a crise do *subprime* (termo utilizado para se referir ao fato dos tomadores de crédito não disporem de uma garantia de fato, comprovantes de renda ou históricos de bons pagamentos) ocorrida entre 2008-2009. A crise eclodiu em um momento em que a economia brasileira se expandiu a taxas consideráveis nos trimestres anteriores, com uma redução gradativa nos níveis de desemprego e aumentos no consumo. Como apontou Prates e Farhi (2009), à partir de agosto de 2008, após a falência do Lehman Brothers, intensificou-se a crise e houveram fortes aversões ao risco, o que desencadeou grandes fugas de capitais, como podemos ver na Figura 12 a queda abrupta de investimento em carteira e diretos, após 2008.


Entre as observações 320-340 temos o período de 2014-2016 marcado por um cenário político interno incerto e de uma escala nos preços das commodities no mercado internacional. Segundo Barbosa Filho (2017), a crise ocorrida neste período foi resultado de um choque de oferta e de demanda. Pelo lado da oferta, a Nova Matriz Econômica (NME) adotada entre 2011/2012 reduziu a produtividade da economia brasileira, como pode ser visto na figura 13, e, conseqüentemente, o nosso produto potencial. Já pelo lado da demanda, ainda segundo Barbosa Filho (2017), podemos dividir em três grupos. O primeiro deve-se ao esgotamento do NME que combinava política monetária “frouxa” com política fiscal intervencionista, com elevações de gastos públicos e concessões de subsídios. A política monetária, através do seu instrumento principal, a taxa de juros, foi mantida estimulante em 2012 num momento em que a inflação se acelerava. Como consequência, a inflação se acelerou mais e perdeu-se a credibilidade do Banco Central. O segundo fator pelo lado da demanda deve-se a política de controle de preços, principalmente no setor energético. Por

fim, as intervenções governamentais e estímulos fiscais geraram uma deterioração das contas públicas brasileiras.

Entre as observações 360-380, o pico de volatilidade estimado pelo modelo deve-se à, novamente, ambiente político conturbado do Governo de Michel Temer. Soma-se a isso a greve dos caminhoneiros ocasionada pelos sucessivos aumento dos combustíveis, principalmente o diesel.

Por fim, entre o período 380-400 explica-se pela pandemia de Covid-19, a qual proporcionou uma imensa fuga de capital, principalmente nos países emergentes, para ativos de menor risco. Como apontaram Braga, Toneto e Carvalho (2021), um dos fatores que levaram a forte desvalorização do real frente ao dólar foi a redução do juros doméstico, levando um aumento do diferencial de juros em relação aos países emergentes mas principalmente aos Estados Unidos, culminando a um retorno relativo maior das aplicações em dólar. Do ponto de vista da oferta, empresas se fecharam e linhas de produção foram paralisadas. Pelo lado da demanda, as restrições impostas para impedir a contaminação. A atitude dos *policy makers* foi, portanto, emissões de dívidas e políticas de renda temporária. Todo esse cenário prejudicou toda a nossa economia e tal incerteza refletiu-se no câmbio.

**Figura 12 – Investimento direto e investimento em carteira (Bilhões R\$): 1994-2021**



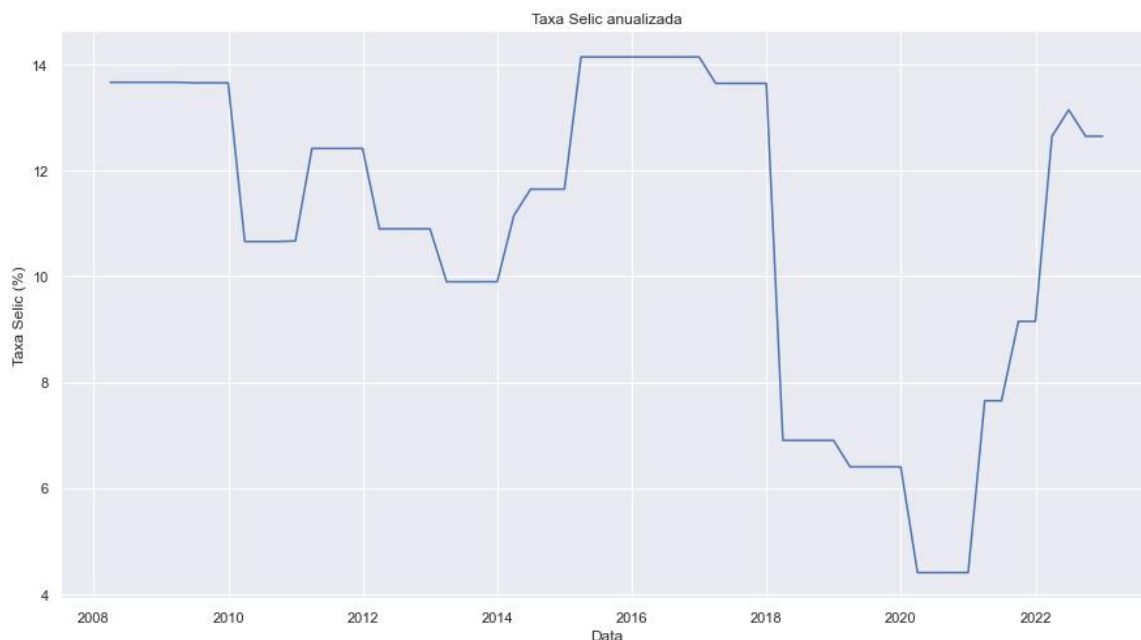
Fonte: Elaborado pelo autor, dados obtidos no SGS do BCB

**Figura 13 – Produtividade Brasileira entre 1998-2021**



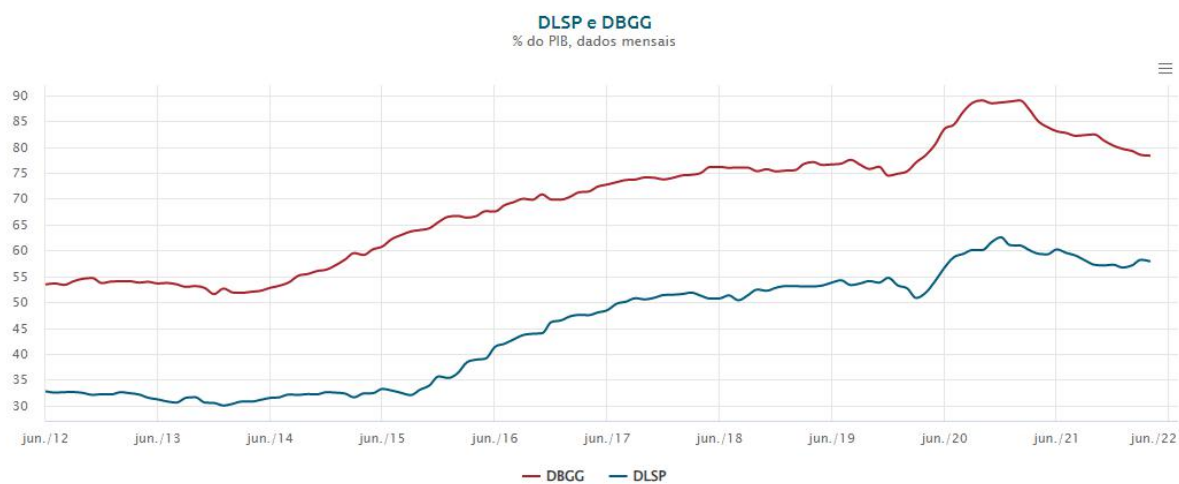
Fonte: Elaborado por TradingEconomics

**Figura 14 –Taxa Selic Anualizada entre 2008-2022**



Fonte: Elaborado pelo autor, dados obtidos no SGS do BCB

**Figura 15 – Dívida Líquida Setor Público (DLSP) e Dívida Bruta Governo Geral (DBGG): 2012-2022**



Fonte: Banco Central do Brasil

#### 4.6 CONSIDERAÇÕES FINAIS

Com o fim do acordo de *Bretton Woods*, as taxas de câmbio tornaram-se menos previsíveis em todo o mundo. Dada a sua importância em diversos âmbitos da economia, o câmbio tornou-se uma variável de extrema importância na economia, servindo de uma

espécie de *proxy* para expectativas sobre o país. No caso brasileiro, podemos explicar a nossa volatilidade como um mix entre erros de políticas adotadas, quer sejam econômicas ou monetárias, além de ambientes políticos conturbados ao longo dos últimos anos.

O presente trabalho utilizou-se da taxa de câmbio real brasileira, valendo-se de um modelo ARMA-GARCH. O primeiro passo foi a estimação de um modelo ARMA(3,3) e, após a observação de heterocedasticidade nos resíduos, urge a necessidade de utilizar um modelo que capture e elimine essa heterocedasticidade. Utilizou-se de uma série de modelos GARCH e, valendo-se do critério de menor *Akaike*, escolheu-se o GARCH(1,1) com distribuição t-Student. Este foi capaz de eliminar a heterocedasticidade presente nos resíduos do modelo ARMA, como pudemos perceber a partir dos testes ACF e PACF, Ljung-Box e ARCH-LM.

#### REFERÊNCIAS

BANCO CENTRAL DO BRASIL. Volatilidade do câmbio no Brasil. **Relatório Trimestral de Inflação**, v. 23, n. 1, p. 1-91, 2021.

BARBOSA FILHO, F. H. **A crise econômica de 2014/2017**. Saídas para a crise econômica, *Estud. av.* 31 (89) Jan-Apr 2017

DOI: <https://doi.org/10.1590/s0103-40142017.31890006>



BELLUZZO, L. G. de M. O declínio de Bretton Woods e a emergência dos mercados “globalizados”. **Economia e Sociedade**, [S. l.], v. 4, n. 1, p. 11–20, 2016. Disponível em: <https://periodicos.sbu.unicamp.br/ojs/index.php/ecos/article/view/8643205>. Acesso em: 16 abr. 2022.

BRAGA, J.; TONETO, R.; CARVALHO, L.. A montanha russa do câmbio: o que explica a desvalorização e a valorização do Real durante a pandemia? (**Nota de Política Econômica nº 012**). MADE/USP

BUENO, R. de L. da S. **Econometria de Séries Temporais**. 2. ed [S.l: s.n.], 2012.

CALVO, G.; REINHART, C. “Fear of floating”. *Quarterly Journal of Economics*, v. 107, n. 2, 2002

CÔTÉ, A. (1994), 'Exchange rate volatility and trade', **Working Paper of Bank of Canada** 94(5), 1-28. <http://www.bankofcanada.ca/wp-content/uploads/2010/04/wp94-5.pdf>.

DAL BIANCO, Silvia, and Nguyen Cong To Loan. 2017. FDI inflows, price and exchange rate volatility: New empirical evidence from Latin America. **International Journal of Financial Studies** 5: 6

DARBY, J. *et al.* The impact of exchange rate uncertainty on level of investment. **The Economic Journal**, v. 109, n. 454, p. c55-c67, 1999

Dellas, H. & B., Z. (1993), 'Real exchange rate volatility and international trade: a reexamination of the theory', **Southern Economic Journal** 59(2), 651-657.

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

ENGLE, R. F., **Autoregressive conditional heteroskedasticity with estimates of the variance of United Kingdom inflation**, *Econometrica*, 50, 987-1008, 1982.

GUJARATI, D.M. **Econometria básica**. 3. ed. São Paulo: Makron books, 2000. 846p.

HAU, H. Real exchange rate volatility and economic openness: theory and evidence. **Journal of Money, Credit and Banking**, v. 34, n. 3, part 1, p. 611-630, 2002.

HENTSCHEL, L. (1995) **All in the Family Nesting Symmetric and Asymmetric GARCH Models**. **Journal of Financial Economics**, 39, 71-104 .  
DOI: [https://doi.org/10.1016/0304-405X\(94\)00821-H](https://doi.org/10.1016/0304-405X(94)00821-H)

KWIATKOWSKI, D; PHILLIPS, P. C. B .; SCHMIDT, P. "**Testing the Null Hypothesis of Stationarity Against the Alternative of a Unit Root: How Sure Are We That Economic Time Series Have a Unit Root?**" (1991). Cowles Foundation Discussion Papers. 1222

LICHTENSZTEJN, S; BAER, M.. **Fundo Monetário Internacional e Banco Mundial: estratégias e políticas do poder financeiro**. São Paulo: Brasiliense, 1987.

MARINHO, P. L. **O Sistema Monetário Internacional: Uma interpretação a partir do conceito de hegemonia mundial**. 2007

MORETTIN, P. A.; TOLOI, C. M. C. **Análise de Séries Temporais**, 2.ed., São Paulo: Edgard Blucher, 2004

OLIVEIRA, G. C. de; MAIA, G.; MARIANO, J. **O Sistema de Bretton Woods e a Dinâmica do Sistema Monetário Internacional Contemporâneo**. **Pesquisa & Debate**, São Paulo, v. 19, n. 2 (34), p. 195-219, 2008

PRATES, D. M.; FARHI, M. **A crise financeira internacional, o grau de investimento e a taxa de câmbio do real**. Campinas: IE/UNICAMP, 2009. (Texto para Discussão, n. 164).

ROCHA, M.; CURADO, M. **Metas de inflação e volatilidade cambial: uma análise da experiência internacional com PAINEL-GARCH\***. **Rev. Econ. Contemp**, Rio de Janeiro, v. 15, n.2, p. 342-361, 2011

SERVÉN, L. Real-Exchange-Rate Uncertainty and Private Investment in LDCS. **The Review of Economics and Statistics**, v. 85, n. 1, p. 212-218, 2003

TERRA, C. **Finanças Internacionais: Macroeconomia Aberta**. 1. ed - Rio de Janeiro: Elsevier, 2014

## **APÊNDICE**

### **APÊNDICE A - Sumário modelo ARMA (1,1)**

<b>Dep. Variable:</b>	retornos	<b>No. Observations:</b>	167			
<b>Model:</b>	SARIMAX(1, 0, 1)	<b>Log Likelihood</b>	332.684			
<b>Date:</b>	Thu, 16 Jun 2022	<b>AIC</b>	-659.368			
<b>Time:</b>	13:51:50	<b>BIC</b>	-650.014			
<b>Sample:</b>	0	<b>HQIC</b>	-655.572			
	- 167					
<b>Covariance Type:</b>	opg					
	<b>coef</b>	<b>std err</b>	<b>z</b>	<b>P&gt; z </b>	<b>[0.025</b>	<b>0.975]</b>
<b>ar.L1</b>	-0.0898	0.244	-0.368	0.713	-0.568	0.388
<b>ma.L1</b>	0.3855	0.230	1.675	0.094	-0.066	0.837
<b>sigma2</b>	0.0011	0.0001	10.889	0.000	0.001	0.001
<b>Ljung-Box (L1) (Q):</b>	0.00	<b>Jarque-Bera (JB):</b>	13.14			
<b>Prob(Q):</b>	0.97	<b>Prob(JB):</b>	0.00			
<b>Heteroskedasticity (H):</b>	1.06	<b>Skew:</b>	0.39			
<b>Prob(H) (two-sided):</b>	0.81	<b>Kurtosis:</b>	4.13			

Warnings:

Fonte: Elaborado pelo autor, dados obtidos por meio linguagem *Python*

## APÊNDICE B: Sumário modelo ARMA (2,2)

<b>Dep. Variable:</b>	retornos	<b>No. Observations:</b>	167			
<b>Model:</b>	SARIMAX(2, 0, 2)	<b>Log Likelihood</b>	333.195			
<b>Date:</b>	Thu, 16 Jun 2022	<b>AIC</b>	-656.390			
<b>Time:</b>	13:52:00	<b>BIC</b>	-640.800			
<b>Sample:</b>	0	<b>HQIC</b>	-650.062			
			- 167			
<b>Covariance Type:</b>	opg					
	<b>coef</b>	<b>std err</b>	<b>z</b>	<b>P&gt; z </b>	<b>[0.025</b>	<b>0.975]</b>
<b>ar.L1</b>	-0.0333	0.975	-0.034	0.973	-1.945	1.879
<b>ar.L2</b>	0.2448	0.254	0.962	0.336	-0.254	0.744
<b>ma.L1</b>	0.3149	0.989	0.319	0.750	-1.623	2.252
<b>ma.L2</b>	-0.2543	0.489	-0.520	0.603	-1.213	0.704
<b>sigma2</b>	0.0011	0.000	10.462	0.000	0.001	0.001
<b>Ljung-Box (L1) (Q):</b>	0.05	<b>Jarque-Bera (JB):</b>	16.54			
<b>Prob(Q):</b>	0.83	<b>Prob(JB):</b>	0.00			
<b>Heteroskedasticity (H):</b>	1.05	<b>Skew:</b>	0.36			
<b>Prob(H) (two-sided):</b>	0.85	<b>Kurtosis:</b>	4.36			

Fonte: Elaborado pelo autor, dados obtidos por meio linguagem *Python*

APÊNDICE C: Sumário modelo GARCH (1,1) com distribuição normal

Dep. Variable:	None	R-squared:	0.000
Mean Model:	Constant Mean	Adj. R-squared:	0.000
Vol Model:	GARCH	Log-Likelihood:	346.176
Distribution:	Normal	AIC:	-682.352
Method:	Maximum Likelihood	BIC:	-666.762
		No. Observations:	167
Date:	Thu, Jun 16 2022	Df Residuals:	166
Time:	13:52:24	Df Model:	1

Mean Model

	coef	std err	t	P> t	95.0% Conf. Int.
mu	2.6786e-04	2.403e-03	0.111	0.911	[-4.442e-03, 4.978e-03]

Volatility Model

	coef	std err	t	P> t	95.0% Conf. Int.
omega	6.4403e-04	4.582e-04	1.406	0.160	[-2.540e-04, 1.542e-03]
alpha[1]	0.3298	0.142	2.321	2.030e-02	[5.127e-02, 0.608]
alpha[2]	0.0455	0.233	0.195	0.845	[-0.411, 0.502]
beta[1]	1.4541e-17	0.680	2.138e-17	1.000	[-1.333, 1.333]

Fonte: Elaborado pelo autor, dados obtidos por meio linguagem *Python*

APÊNDICE D: Sumário modelo GARCH (1,2) com distribuição normal

<b>Dep. Variable:</b>	None	<b>R-squared:</b>	0.000
<b>Mean Model:</b>	Constant Mean	<b>Adj. R-squared:</b>	0.000
<b>Vol Model:</b>	GARCH	<b>Log-Likelihood:</b>	346.163
<b>Distribution:</b>	Normal	<b>AIC:</b>	-682.326
<b>Method:</b>	Maximum Likelihood	<b>BIC:</b>	-666.736
		<b>No. Observations:</b>	167
<b>Date:</b>	Thu, Jun 16 2022	<b>Df Residuals:</b>	166
<b>Time:</b>	13:52:26	<b>Df Model:</b>	1

## Mean Model

	coef	std err	t	P> t	95.0% Conf. Int.
<b>mu</b>	3.4308e-04	3.059e-03	0.112	0.911	[-5.652e-03, 6.338e-03]

## Volatility Model

	coef	std err	t	P> t	95.0% Conf. Int.
<b>omega</b>	5.6043e-04	3.167e-04	1.769	7.681e-02	[-6.033e-05, 1.181e-03]
<b>alpha[1]</b>	0.3289	0.171	1.927	5.393e-02	[-5.554e-03, 0.663]
<b>beta[1]</b>	0.1279	0.179	0.713	0.476	[-0.224, 0.479]
<b>beta[2]</b>	0.0000	0.425	0.000	1.000	[-0.833, 0.833]

Fonte: Elaborado pelo autor, dados obtidos por meio linguagem *Python*

## APÊNDICE E: Sumário modelo GARCH (2,1) com distribuição t-Student

<b>Dep. Variable:</b>	None	<b>R-squared:</b>	0.000
<b>Mean Model:</b>	Constant Mean	<b>Adj. R-squared:</b>	0.000
<b>Vol Model:</b>	GARCH	<b>Log-Likelihood:</b>	348.218
<b>Distribution:</b>	Standardized Student's t	<b>AIC:</b>	-684.436
<b>Method:</b>	Maximum Likelihood	<b>BIC:</b>	-665.728
		<b>No. Observations:</b>	167
<b>Date:</b>	Thu, Jun 16 2022	<b>Df Residuals:</b>	166
<b>Time:</b>	13:52:31	<b>Df Model:</b>	1

## Mean Model

	coef	std err	t	P> t	95.0% Conf. Int.
<b>mu</b>	3.4305e-04	2.219e-03	0.155	0.877	[-4.006e-03,4.693e-03]

## Volatility Model

	coef	std err	t	P> t	95.0% Conf. Int.
<b>omega</b>	4.6808e-04	5.553e-04	0.843	0.399	[-6.203e-04,1.556e-03]
<b>alpha[1]</b>	0.3346	0.159	2.105	3.527e-02	[2.309e-02, 0.646]
<b>alpha[2]</b>	4.5077e-12	0.320	1.409e-11	1.000	[-0.627, 0.627]
<b>beta[1]</b>	0.2361	0.832	0.284	0.777	[-1.394, 1.866]

## Distribution

	coef	std err	t	P> t	95.0% Conf. Int.
<b>nu</b>	6.9097	3.812	1.813	6.988e-02	[-0.561, 14.381]

Fonte: Elaborado pelo autor, dados obtidos por meio linguagem *Python*

## APÊNDICE F: Sumário modelo GARCH (1,2) com distribuição t-Student



Dep. Variable:	None	R-squared:	0.000
Mean Model:	Constant Mean	Adj. R-squared:	0.000
Vol Model:	GARCH	Log-Likelihood:	348.482
Distribution:	Standardized Student's t	AIC:	-684.965
Method:	Maximum Likelihood	BIC:	-666.257
		No. Observations:	167
Date:	Thu, Jun 16 2022	Df Residuals:	166
Time:	13:52:32	Df Model:	1

## Mean Model

	coef	std err	t	P> t	95.0% Conf. Int.
mu	1.2910e-03	0.142	9.119e-03	0.993	[-0.276, 0.279]

## Volatility Model

	coef	std err	t	P> t	95.0% Conf. Int.
omega	3.4950e-04	1.017e-02	3.436e-02	0.973	[-1.959e-02, 2.029e-02]
alpha[1]	0.3015	2.930	0.103	0.918	[-5.441, 6.044]
beta[1]	0.0000	48.696	0.000	1.000	[-95.443, 95.443]
beta[2]	0.3804	40.167	9.470e-03	0.992	[-78.346, 79.107]

## Distribution

	coef	std err	t	P> t	95.0% Conf. Int.
nu	6.4873	32.782	0.198	0.843	[-57.763, 70.738]

Fonte: Elaborado pelo autor, dados obtidos por meio linguagem *Python*

**APÊNDICE G:** Sumário modelo GARCH (1,2) com distribuição t-Student *skew*

Dep. Variable:	None	R-squared:	0.000
Mean Model:	Constant Mean	Adj. R-squared:	0.000
Vol Model:	GARCH	Log-Likelihood:	348.241
Distribution:	Standardized Skew Student's t	AIC:	-684.482
Method:	Maximum Likelihood	BIC:	-665.774
		No. Observations:	167
Date:	Thu, Jun 16 2022	Df Residuals:	166
Time:	13:52:33	Df Model:	1

## Mean Model

	coef	std err	t	P> t	95.0% Conf. Int.
mu	1.6886e-04	2.372e-03	7.118e-02	0.943	[-4.481e-03, 4.818e-03]

## Volatility Model

	coef	std err	t	P> t	95.0% Conf. Int.
omega	4.7008e-04	2.705e-04	1.738	8.224e-02	[-6.009e-05, 1.000e-03]
alpha[1]	0.3412	0.192	1.776	7.579e-02	[-3.543e-02, 0.718]
beta[1]	0.2347	0.347	0.677	0.498	[-0.445, 0.914]

## Distribution

	coef	std err	t	P> t	95.0% Conf. Int.
eta	6.6802	3.724	1.794	7.286e-02	[-0.619, 13.980]
lambda	-0.0230	0.102	-0.226	0.821	[-0.222, 0.176]

Fonte: Elaborado pelo autor, dados obtidos por meio linguagem *Python*

## APÊNDICE H: Sumário modelo GARCH (2,1) com distribuição t-Student *skew*

<b>Dep. Variable:</b>	None	<b>R-squared:</b>	0.000
<b>Mean Model:</b>	Constant Mean	<b>Adj. R-squared:</b>	0.000
<b>Vol Model:</b>	GARCH	<b>Log-Likelihood:</b>	348.241
<b>Distribution:</b>	Standardized Skew Student's t	<b>AIC:</b>	-682.482
<b>Method:</b>	Maximum Likelihood	<b>BIC:</b>	-660.656
		<b>No. Observations:</b>	167
<b>Date:</b>	Thu, Jun 16 2022	<b>Df Residuals:</b>	166
<b>Time:</b>	13:52:33	<b>Df Model:</b>	1

## Mean Model

	coef	std err	t	P> t	95.0% Conf. Int.
<b>mu</b>	1.6939e-04	2.416e-03	7.012e-02	0.944	[-4.565e-03, 4.904e-03]

## Volatility Model

	coef	std err	t	P> t	95.0% Conf. Int.
<b>omega</b>	4.7007e-04	5.093e-04	0.923	0.356	[-5.282e-04, 1.468e-03]
<b>alpha[1]</b>	0.3412	0.163	2.092	3.647e-02	[2.148e-02, 0.661]
<b>alpha[2]</b>	2.7967e-17	0.299	9.341e-17	1.000	[-0.587, 0.587]
<b>beta[1]</b>	0.2347	0.740	0.317	0.751	[-1.216, 1.685]

## Distribution

	coef	std err	t	P> t	95.0% Conf. Int.
<b>eta</b>	6.6812	3.725	1.794	7.288e-02	[-0.620, 13.982]
<b>lambda</b>	-0.0229	0.104	-0.220	0.826	[-0.227, 0.182]

Fonte: Elaborado pelo autor, dados obtidos por meio linguagem *Python*

## APÊNDICE H: Sumário modelo GARCH (1,2) com distribuição t-Student *skew*

<b>Dep. Variable:</b>	None	<b>R-squared:</b>	0.000
<b>Mean Model:</b>	Constant Mean	<b>Adj. R-squared:</b>	0.000
<b>Vol Model:</b>	GARCH	<b>Log-Likelihood:</b>	348.661
<b>Distribution:</b>	Standardized Skew Student's t	<b>AIC:</b>	-683.323
<b>Method:</b>	Maximum Likelihood	<b>BIC:</b>	-661.497
		<b>No. Observations:</b>	167
<b>Date:</b>	Thu, Jun 16 2022	<b>Df Residuals:</b>	166
<b>Time:</b>	13:52:33	<b>Df Model:</b>	1

## Mean Model

	coef	std err	t	P> t	95.0% Conf. Int.
<b>mu</b>	1.8967e-03	1.182e-02	0.160	0.873	[-2.127e-02, 2.506e-02]

## Volatility Model

	coef	std err	t	P> t	95.0% Conf. Int.
<b>omega</b>	3.1693e-04	7.429e-04	0.427	0.670	[-1.139e-03, 1.773e-03]
<b>alpha[1]</b>	0.2865	0.130	2.202	2.768e-02	[3.147e-02, 0.542]
<b>beta[1]</b>	0.0000	3.073	0.000	1.000	[-6.024, 6.024]
<b>beta[2]</b>	0.4179	2.307	0.181	0.856	[-4.103, 4.939]

## Distribution

	coef	std err	t	P> t	95.0% Conf. Int.
<b>eta</b>	6.9221	8.098	0.855	0.393	[-8.950, 22.794]
<b>lambda</b>	0.0666	0.504	0.132	0.895	[-0.921, 1.054]

Fonte: Elaborado pelo autor, dados obtidos por meio linguagem *Python*