

UNIVERSIDADE FEDERAL DE JUIZ DE FORA
FACULDADE DE CIÊNCIAS ECONÔMICAS
DEPARTAMENTO DE ECONOMIA E FINANÇAS

MATHEUS FELIPE SILVA BEZERRA

**INFLAÇÃO DE ALIMENTOS, TRANSPORTE E HABITAÇÃO: UMA ANÁLISE
DINÂMICA DE 2000 À 2023**

Juiz de Fora

2023

INFLAÇÃO DE ALIMENTOS, TRANSPORTE E HABITAÇÃO: UMA ANÁLISE
DINÂMICA DE 2000 À 2023

Monografia direcionada à conclusão do trabalho final do curso de Ciências Econômicas da Universidade Federal de Juiz de Fora, como pré-requisito parcial para conclusão do curso de Economia.

Orientador: Prof. Dr. Sidney Martins Caetano.

Juiz de Fora

2023

Ficha catalográfica elaborada através do programa de geração automática da Biblioteca Universitária da UFJF, com os dados fornecidos pelo(a) autor(a)

Bezerra, Matheus Felipe .

INFLAÇÃO DE ALIMENTOS, TRANSPORTE E HABITAÇÃO:
UMA ANÁLISE DINÂMICA DE 2000 À 2023 / Matheus Felipe
Bezerra. -- 2023.

46 f.

Orientador: Sidney Martins Caetano

Trabalho de Conclusão de Curso (graduação) - Universidade
Federal de Juiz de Fora, Faculdade de Economia, 2023.

1. Inflação. 2. SARIMA . 3. Alimentação . 4. Transporte . 5.
Habitação . I. Caetano , Sidney Martins , orient. II. Título.



UNIVERSIDADE FEDERAL DE JUIZ DE FORA
REITORIA - FACECON - Depto. de Economia

FACULDADE DE ECONOMIA / UFJF

ATA DE APROVAÇÃO DE MONOGRAFIA II (MONO B)

Na data de 06 / 12 / 2023, a Banca Examinadora, composta pelos professores

1 – SIDNEY MARTINS CAETANO - orientador; e

2 – WILSON LUIZ ROTATORI CORREA,

reuniu-se para avaliar a monografia do acadêmico MATHEUS FELIPE SILVA BEZERRA, intitulada: INFLAÇÃO DE ALIMENTOS, TRANSPORTE E HABITAÇÃO: UMA ANÁLISE DINÂMICA DE 2000 À 2023.

Após primeira avaliação, resolveu a Banca sugerir alterações ao texto apresentado, conforme relatório sintetizado pelo orientador. A Banca, delegando ao orientador a observância das alterações propostas, resolveu APROVAR a referida monografia.

ASSINATURA ELETRÔNICA DOS PROFESSORES AVALIADORES



Documento assinado eletronicamente por **Sidney Martins Caetano, Professor(a)**, em 06/12/2023, às 19:41, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Wilson Luiz Rotatori Correa, Professor(a)**, em 08/12/2023, às 09:43, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no Portal do SEI-Ufjf (www2.ufjf.br/SEI) através do ícone Conferência de Documentos, informando o código verificador **1614127** e o código CRC **20A552CC**.

RESUMO

Esse trabalho de monografia é uma análise da série temporal da variação dos preços de Alimentação, Transporte e Habitação, abrangendo o período de 2000 a 2023. O objetivo principal é compreender os picos e flutuações observados nesses indicadores ao longo dos anos. Para isso, seguiu-se uma metodologia que incluiu uma análise exploratória da série principal. Foi plotado um gráfico para compreender o comportamento da série, seguida pelo teste de estacionariedade e decomposição via SEATS para identificação de sazonalidades. Adicionalmente, foi realizada a modelagem utilizando um modelo SARIMA (AutoRegressive Integrated Moving Average). Além disso, avaliou-se a qualidade dos resíduos do modelo SARIMA, garantindo que se encaixassem nos pressupostos estatísticos.

O trabalho também incorporou variáveis exógenas, como taxa de câmbio, cotação do trigo, cotação de petróleo, cotação de carne e dívida pública total, para explorar sua influência na variação dos preços de Alimentação, Transporte e Habitação. No entanto, a análise comparativa indicou que o modelo SARIMA superou o modelo de Regressão Linear Temporal na captura dos picos e depressões da série, sugerindo que a série em si é mais eficaz para explicar as flutuações do que os fatores externos utilizados na análise. No geral, o trabalho oferece insights interessantes sobre a dinâmica desses indicadores ao longo dos anos, fornecendo uma análise das tendências e padrões subjacentes que moldaram a variação de preços da Alimentação, Transporte e Habitação durante o período de estudo.

PALAVRAS-CHAVE: inflação, modelo, SARIMA.

ABSTRACT

This thesis work is an analysis of the time series of price variations in Food, Transportation, and Housing, spanning from 2000 to 2023. The main objective is to comprehend the peaks and fluctuations observed in these indicators over the years. To achieve this, a methodology was followed, including an exploratory analysis of the main series. A graph was plotted to understand the series behavior, followed by a stationarity test and decomposition via SEATS to identify seasonalities. Additionally, modeling was performed using a SARIMA (Seasonal AutoRegressive Integrated Moving Average) model. Furthermore, the quality of the SARIMA model residuals was assessed to ensure they adhered to statistical assumptions.

The study also incorporated exogenous variables such as exchange rate, wheat quotation, oil quotation, meat quotation, and total public debt to explore their influence on the variation in prices of Food, Transportation, and Housing. However, comparative analysis indicated that the SARIMA model outperformed the Temporal Linear Regression model in capturing the peaks and troughs of the series, suggesting that the series itself is more effective in explaining the fluctuations than the external factors used in the analysis. Overall, the work provides interesting insights into the dynamics of these indicators over the years, offering an analysis of the underlying trends and patterns that shaped the price variations in Food, Transportation, and Housing during the study period.

KEYWORDS: inflation, model, SARIMA.

LISTA DE FIGURAS

Figura 8 - Gasto médio familiar mensal por tipo de despesa	25
Figura 1 - Função de Autocorrelação (FAC) e Função de Autocorrelação Parcial (FACP)....	28
Figura 2 - Decomposição Aditiva da Série Temporal – VAR de ATH	28
Figura 3 - Análise de Resíduos: Histograma e ACF – VAR de ATH	31
Figura 4 - Gráficos das variáveis secundárias	32
Figura 5 - Matriz de Correlação.....	32
Figura 6 - Análise de Resíduos: Histograma e ADC – REG SECUNDÁRIA.....	34
Figura 7 - Gráfico comparativo – VAR ATH	34
Figura 9 - VAR acumulada de ATH	36
Figura 10 - Marcações de Picos - VAR acumulada ATH.....	36
Figura 11 - VAR ATH	37
Figura 12 - Picos - Série diferenciada	37
Figura 13 - Gráfico comparativo – VAR ATH e VAR de Dívida Publica	38
Figura 14 - Modelo Autorregressivo SARIMA (1, 0, 1)[12]	39
Figura 15 - Modelo (Regressão Linear Tempotal)	39
Figura 16 - Comparação da série estacionaria – VAR ATH e VAR DLSP%PIB.....	40
Figura 17 - Comparação – VAR acumulada ATH e NF%PIB.....	41
Figura 18 - Comparação – VAR acumulada de Salário e VAR acumulada ATH.....	43
Figura 19 - Salário Real 2000 à 2023	43
Figura 20 - Projeção – VAR ATH (Sem Covid)	44

LISTA DE TABELAS

Tabela 1 – Calculo ponderado de ATH.....	25
Tabela 2 – Resultados do Teste de Dickey-Fuller para a Série temporal VAR ATH	27
Tabela 3 - Teste de KPSS para estacionariedade.....	27
Tabela 4 – Resultados dos modelos SARIMA	29
Tabela 5 – Resultado do Modelo SARIMA escolhido	30
Tabela 6 - Resultados do modelo secundário TSLM (Time Series Linear Model).....	33
Tabela 7 - Resultado do modelo TSLM (Time Series Linear Model) com a variável de Dívida pública	35
Tabela 8 - Ajuste de Salário anual 2000 à 2023	42

SUMÁRIO

1	INTRODUÇÃO:	10
2	REVISÃO DE LITERATURA:	11
3	METODOLOGIA:	23
3.1	COLETA E TRATAMENTO DOS DADOS.....	24
3.2	ANÁLISE EXPLORATÓRIA DA SÉRIE PRINCIPAL:	26
3.2.1	Estacionariedade:	26
3.3	MODELAGEM DA SÉRIE PRINCIPAL (FAC, FACP E ESCOLHA INICIAL DO MODELO):.....	27
3.3.1	Análise dos Resíduos	30
3.4	ANÁLISE DAS SÉRIES SECUNDÁRIAS:	31
3.5	MODELAGEM DA SÉRIE PRINCIPAL COM A INCORPORAÇÃO DAS SÉRIES SECUNDÁRIAS	33
3.6	AJUSTE DA VARIÁVEL DE DÍVIDA PÚBLICA	34
4	RESULTADOS EMPÍRICOS:	36
4.1	ANÁLISE EXPLORATÓRIA DA SÉRIE PRINCIPAL	36
4.2	COMPARAÇÃO ENTRE OS 2 MODELOS.....	38
4.3	PROJEÇÕES E ANÁLISES DE CENÁRIOS	41
	CONCLUSÃO	45
5	REFERÊNCIAS:	47

1 INTRODUÇÃO:

No cenário econômico global, a análise das tendências de inflação desempenha um papel crucial na formulação de políticas monetárias, no planejamento de gastos domésticos e no entendimento dos impactos econômicos sobre os diversos estratos da população. A inflação afeta diretamente o poder de compra das famílias, e sua variação ao longo do tempo é de interesse não apenas para acadêmicos e pesquisadores, mas também para governos e tomadores de decisão. Este trabalho se propõe a explorar e compreender a série temporal de variação de preço dos itens Alimentação, Transporte e Habitação no período de 2000 a 2023. Trata-se de uma análise que utiliza técnicas estatísticas econômicas para analisar os padrões subjacentes que moldaram a evolução dos preços desses bens essenciais. A escolha dessas três séries de Alimentação, Transporte e Habitação é fundamentada na relevância desses itens no orçamento das famílias de baixa renda. Esses são os três pilares essenciais para a qualidade de vida, e as flutuações em seus preços podem impactar significativamente a situação financeira dessas famílias. Essa escolha se baseia nas ponderações estabelecidas pela Pesquisa de Orçamentos Familiares (POF) de 2018 do Instituto Brasileiro de Geografia e Estatística (IBGE), que descrevem os parâmetros de consumo dos brasileiros como sendo 36,6% em habitação, 18,1% em Transporte, 17,5% em alimentação e 36,6% em outros itens, ou seja a partir disso foram construídos pesos referentes a cada parcela de gasto das famílias. A análise da série temporal de variação de ATH (Alimentação, Transporte e Habitação) permite não apenas reconhecer os picos e vales na evolução dos preços, mas também entender as tendências subjacentes, comportamentos específicos e se existe sazonalidades nessas categorias de consumo. Além disso, o estudo pode ser usado para a comparação de diferentes modelos preventivos, contribuindo assim para o avanço da compreensão dos fatores que impulsionam a inflação nesses itens. Isso permite que se identifique a causalidade entre as variáveis exógenas, como a taxa de câmbio, a dívida pública, e a inflação em Alimentação, Transporte e Habitação.

Compreender como a inflação afeta esses grupos de produtos essenciais é fundamental para desenvolver estratégias de mitigação de impacto e para promover uma melhor qualidade de vida para os segmentos de menor poder aquisitivo da população. Ao longo deste estudo, serão exploradas técnicas de análise de séries temporais e modelagem, permitindo a obtenção de uma visão mais clara dos movimentos dos preços de Alimentação, Transporte e Habitação.

2 REVISÃO DE LITERATURA:

Como o trabalho está sendo feito com dados atualizados de alimentação, transporte, habitação, taxa de cambio e poder de compra de commodities internacionais, é pertinente trazer para a revisão de literatura experiências e análises que também foram executadas recentemente, além claro, de experiências anteriores com temas e metodologias mais distintas. A primeira obra é um estudo realizado pelo Cepea (2021), Centro de Estudos Avançados em Economia Aplicada, da Esalq/USP que faz uso de variáveis bem semelhantes a dessa monografia, a pesquisa do Cepea busca explicar o primeiro ano de pandemia de covid19 e o impacto das restrições sobre a inflação (medida pelo IPCA) e o que mais surpreendeu em 2020, é que a inflação observada não foi tão alta como a esperada, apesar do grande aumento no índice durante o último trimestre do ano. A inflação anual de 2020 fechou o ano em 4,42%, enquanto a inflação esperada era de 6,11%. Isso significa que a inflação ficou 1,69 ponto percentual abaixo do previsto.

Os fatores principais que contribuíram para a inflação ser menor do que o esperado, conforme destacado no artigo, foram os preços do petróleo que registrou uma queda de 72% no mercado internacional de dezembro de 2019 a abril de 2020, devido ao impacto da pandemia de Covid-19 na demanda. Isso afetou o preço do diesel, que teve uma redução de 56% em dólares e 21% no Brasil.

A expectativa de inflação por parte dos agentes econômicos permaneceu contida, não estimulando ajustes preventivos significativos de preços. Isso contribuiu para uma evolução mais suave da inflação, resultando em uma diferença de 0,96 ponto percentual menor do que o esperado.

Curiosamente, em 2020, a indexação de preços atuou no sentido de reduzir a inflação observada, em parte devido à conjuntura recessiva causada pela pandemia, que impediu a recomposição de preços.

Por outro lado, os fatores que contribuíram para a inflação ser maior do que o esperado incluíram a desvalorização do real em relação ao dólar que elevou os preços de produtos importados, como o diesel, contribuindo para um aumento de 1,32 ponto percentual na inflação.

Os preços dos produtos agropecuários aumentaram, sendo que 10,7% da alta se deveu à demanda interna, 31% à alta do dólar e 8,7% ao aumento dos preços internacionais em dólares, contribuindo com 0,41 ponto percentual para a inflação ficar acima das expectativas.

Os preços internacionais de commodities também tiveram um impacto positivo na inflação, adicionando 0,21 ponto percentual.

Conforme mencionado, a aceleração inflacionária no último trimestre ocorreu devido à recomposição do preço do diesel para compensar a elevação do preço internacional e à desvalorização cambial no primeiro semestre. O aumento da renda proporcionado pelo programa emergencial e o impacto dos preços agropecuários contribuíram para a aceleração da inflação nesse período.

Para chegar a esses resultados e compreender o impacto de cada item na inflação a equipe macroeconômica da Cepea utilizou de um modelo econométrico de Metodologia de Vetores Autoregressivos (VAR) para estudo dos determinantes da inflação brasileira baseado no conjunto de instrumentos desenvolvido no contexto. Os procedimentos enquadram-se na categoria de Modelos Híbridos de Curva de Phillips Novo-Keynesiana. (MHCPKN).

A análise do Cepea compara as taxas de inflação observadas com aquelas que seriam esperadas sem os choques não antecipados nos determinantes da inflação. A diferença entre essas taxas é decomposta em termos das contribuições de choques em cada um dos determinantes.

O modelo considera que a inflação brasileira (medida pelo IPCA) é influenciada pelo hiato do produto (diferença entre o produto observado e o produto potencial), expectativa de inflação dos agentes econômicos, choque de oferta (como combustíveis e agropecuária), taxa de câmbio e preços internacionais de commodities agropecuárias.

A análise busca identificar a origem das variações na inflação, considerando diferentes fatores que podem influenciar os preços, como oferta, custos de produção, câmbio e demanda. O objetivo é entender as causas por trás das mudanças nos preços e identificar as principais variáveis que afetam a inflação.

A equipe do Cepea realiza análises tanto considerando grupos de preços domésticos individualmente quanto considerando o preço médio agregado da agropecuária, levando em conta os efeitos do setor externo, como a taxa de câmbio e os preços internacionais de commodities agropecuárias.

O artigo de Baccarin e Oliveira (2021) vem na mesma linha do artigo anterior do Cepea (2021), porém eles usam uma metodologia empírica. De acordo com o artigo, durante a

pandemia, contrariando as expectativas iniciais, a inflação não aumentou de forma significativa durante esse período. Isso se deve a uma combinação de fatores econômicos e políticas governamentais adotadas para mitigar os impactos da crise.

Uma das principais razões para a ausência de um aumento acentuado da inflação foi a forte queda na demanda agregada. Com o fechamento de muitas empresas e o aumento do desemprego, os consumidores reduziram seus gastos, o que diminuiu a pressão inflacionária. Além disso, medidas de distanciamento social e restrições de mobilidade também contribuíram para a queda na demanda.

Outro fator importante foi a resposta das autoridades monetárias e fiscais. Os bancos centrais e governos implementaram políticas expansionistas, como cortes nas taxas de juros e programas de estímulo fiscal, a fim de manter a liquidez no sistema financeiro e estimular a atividade econômica. Essas medidas ajudaram a evitar uma espiral deflacionária e a estabilizar os preços.

No entanto, é importante ressaltar que, à medida que a pandemia avançava e a economia começava a se recuperar, a inflação começou a apresentar sinais de aumento. Vários fatores contribuíram para esse aumento. Um deles foi a interrupção das cadeias de suprimentos globais, o que levou a escassez de alguns produtos e, conseqüentemente, ao aumento de seus preços. Além disso, os preços das commodities, como o petróleo, também subiram devido a fatores geopolíticos e à recuperação da demanda.

Os impactos desse aumento da inflação são variados. Em primeiro lugar, pode reduzir o poder de compra dos consumidores, uma vez que os preços dos bens e serviços aumentam mais rapidamente do que os salários. Isso pode levar a uma diminuição do consumo e impactar negativamente a demanda agregada. Além disso, a inflação pode afetar negativamente os investimentos, uma vez que a incerteza sobre os preços futuros dificulta o planejamento a longo prazo das empresas.

Para combater os efeitos negativos da inflação, os bancos centrais podem optar por aumentar as taxas de juros, o que torna o crédito mais caro e desestimula o consumo e o investimento. No entanto, essa decisão precisa ser cuidadosamente equilibrada, levando em consideração outros objetivos econômicos, como o crescimento e o emprego.

Em resumo, a inflação durante a pandemia foi baixa devido à queda na demanda agregada e às políticas adotadas pelos governos. No entanto, à medida que a economia se recuperou, a inflação voltou a aumentar devido a fatores como escassez de produtos e aumento

dos preços das commodities. Os impactos da inflação inclui a redução do poder de compra dos consumidores e impacto nos investimentos.

Outro artigo interessante para o andamento desse trabalho, é o artigo de Souza (2001) sobre o debate das causas da inflação já que tem se tornado consensual a ideia de que a inflação é frequentemente de natureza fiscal, causada pelo déficit público financiado por emissão monetária. Esse tipo de inflação é geralmente classificado como inflação de demanda, pois resulta de um aumento nos gastos públicos ou uma diminuição dos impostos, levando a um crescimento na demanda agregada acima do produto de pleno emprego.

No entanto, vale ressaltar que existem visões alternativas sobre as principais causas de inflação, uma delas é argumento de que a inflação pode ter outra natureza, não diretamente relacionada ao excesso de demanda na economia, mas sim causada por aumentos nos custos de produção, como mão de obra, contratos e insumos. O artigo de Luiz Willcox busca resgatar a importância de refletir sobre a inflação de custos como uma explicação mais teoricamente robusta e empiricamente relevante para os processos inflacionários nas economias capitalistas. Para alcançar esse objetivo, o artigo de Willcox é dividido em várias seções.

A primeira seção explora a possibilidade teórica da existência da inflação de custos. Isso implica abandonar a ideia de que as economias capitalistas têm uma tendência automática ao pleno emprego e aceitar o princípio da demanda efetiva, mesmo a longo prazo.

A segunda seção crítica a visão de que a inflação de demanda é um fenômeno persistente. A terceira seção aborda confusões comuns na classificação da inflação como fenômeno de demanda ou de custos. Por fim, na quarta seção, o artigo discute a hiperinflação, argumentando que, da mesma forma que a inflação, a hiperinflação pode ser explicada de maneira mais consistente pela abordagem da inflação de custos.

A análise demonstra que a inflação de custos pode ser uma explicação plausível para a inflação em muitos casos, particularmente quando a economia não opera em pleno emprego. Argumenta-se que, mesmo em uma economia aberta, a inflação de demanda não é a única explicação para a inflação persistente, e que a inflação de custos desempenha um papel fundamental.

Portanto, o artigo defende a importância de considerar a inflação de custos como um conceito válido na análise da inflação em economias capitalistas, questionando a visão predominante de que a inflação é principalmente resultado de excesso de demanda.

Como dito, o trecho final do artigo explora a questão da hiperinflação e discute como ela pode

ser interpretada tanto a partir da abordagem da inflação de demanda quanto da inflação de custos. No caso da hiperinflação de demanda, os autores analisam a equação quantitativa da moeda ($MV=PY$), onde M é a quantidade de moeda, V é a velocidade de circulação da moeda, P é o nível geral de preços e Y é o produto da economia. A hiperinflação de demanda é vista como resultado do aumento da velocidade de circulação da moeda devido às expectativas de aumento de preços. Quando os agentes antecipam aumento de preços, a demanda por moeda diminui, levando a um aumento na velocidade da circulação da moeda e, subsequentemente, a um aumento dos preços. Esse processo gera um ciclo de expectativas de inflação, levando a uma aceleração endógena da inflação.

No caso da hiperinflação de custos, os autores argumentam que a inflação se acelera porque os agentes econômicos tentam ajustar seus contratos com intervalos de reajuste cada vez menores. Isso ocorre devido à incerteza causada pela inflação, à falta de coordenação entre os reajustes de renda e a presença de um conflito distributivo não resolvido. Como resultado, a inflação se acelera, e os contratos passam a ser ajustados em intervalos mais curtos. Isso cria um mecanismo automático de aceleração da inflação.

Em resumo, o artigo destaca a importância de considerar tanto a inflação de custos quanto a inflação de demanda na análise da inflação, incluindo a hiperinflação. Argumenta que a hiperinflação pode ser explicada a partir de ambas as abordagens, mas destaca que a inflação de custos oferece uma explicação mais teórica e empiricamente plausível para a hiperinflação.

Como estamos trabalhando com inflação, vale ressaltar a importância do estudo e da compreensão dos fenômenos causadores de inflação não apenas para maximizar o crescimento econômico, mas também para evitar a piora da distribuição de renda e aumento da pobreza no país, por isso na área acadêmica, vários estudos têm se dedicado a desenvolver modelos teóricos de equilíbrio geral dinâmico que levam em consideração a presença de agentes heterogêneos. Alguns modelos teóricos que exploram os efeitos distributivos da inflação na economia são os modelos mencionados de Erosa e Ventura (2002) e Cysne, Maldonado e Monteiro (2005). Esses primeiros modelos abordam modelos teóricos desenvolvidos por Erosa e Ventura (2002) e também por Albanesi (2007) que exploram os efeitos distributivos da inflação na economia. O primeiro modelo, de Erosa e Ventura, a economia possui uma variedade de bens que podem ser adquiridos com moeda ou crédito, sendo que o acesso ao crédito apresenta ganhos de escala. Os agentes mais ricos compram uma proporção maior de bens com crédito, enquanto os pobres dependem mais da moeda. Devido a essa diferença no acesso aos mecanismos de compra, os custos de bem-estar da inflação são maiores para os agentes de baixa renda que não possuem o

benefício do crédito. Nesse modelo, a inflação funciona como um imposto não linear sobre o consumo.

Albanesi (2007), por sua vez, desenvolve um modelo semelhante, mas introduz a endogeneidade da política econômica (monetária e fiscal) e um mecanismo político. A escolha das políticas ocorre por meio de um jogo de barganha entre os agentes pobres e ricos. Assim, a autora estabelece um modelo no qual a inflação tem impactos distributivos semelhantes a um imposto regressivo, e ainda assim, existe uma correlação positiva entre essa variável e a desigualdade de renda.

Portanto, esses modelos teóricos demonstram como a inflação afeta de forma desigual os diferentes grupos socioeconômicos, sendo mais prejudicial para os agentes de baixa renda, e contribui para o aumento da desigualdade de renda.

Já o modelo de Cysne, Maldonado e Monteiro (2005) explica um cenário de ricos e pobres - que têm acesso diferenciado a ativos financeiros e produtividades distintas na produção de bens de consumo. Ambos os grupos mantêm moeda, pois as compras levam tempo e usar moeda reduz esse tempo o chamado "shopping-time economy".

O modelo não se concentra na diferença entre ricos e pobres em termos de acesso a ativos financeiros com diferentes taxas de retorno, mas sim no tempo gasto pelos agentes nas compras (shopping-time), que é afetado pela taxa de inflação. Quanto maior a inflação, maior a taxa de juros nominal e, portanto, maior o custo de manter moeda, o que aumenta o shopping-time. Devido às diferenças de produtividade, o shopping-time é maior entre os pobres. Consequentemente, aqueles com melhor acesso às tecnologias de transação (os ricos) se beneficiam mais quando a inflação é alta, resultando em maior concentração de renda na economia, medida pelo índice de Gini.

Os autores afirmam que esse modelo pode ser interpretado como uma formalização indireta do argumento de que os pobres suportam um ônus inflacionário maior do que os ricos. Essa conclusão está alinhada com evidências empíricas apresentadas por Romer e Romer (1998), Easterly e Fischer (2001) e Bulíř (2001).

Por outro lado, na literatura empírica temos o trabalho clássico de Romer e Romer (1998), sobre o impacto da política monetária na pobreza, tanto no curto quanto no longo prazo. No curto prazo, os autores analisam o efeito de expansões monetárias e inflação inesperada na economia dos Estados Unidos usando dados trimestrais. Os resultados indicam que uma expansão

monetária pode melhorar a renda dos mais pobres no curto prazo, reduzindo o desemprego, mas não por meio de mudanças diretas na inflação.

No entanto, Romer e Romer destacam que a política monetária não pode ter efeitos expansionistas no longo prazo. Portanto, eles realizam uma análise de regressão em uma amostra de aproximadamente 70 países, usando dados médios do período de 1983 a 1993, para investigar o efeito das taxas de inflação na pobreza e na desigualdade de renda. No que diz respeito à desigualdade de renda, o principal resultado encontrado, ao controlar variáveis continentais, é que um aumento de um ponto percentual na inflação média aumenta o índice de Gini em 0,34 pontos percentuais.

Usando esse efeito linear, eles mostram que um desvio padrão na taxa média de inflação (17 pontos percentuais), em comparação com um desvio padrão do índice de Gini de 10,6 pontos percentuais, leva a um aumento de 3,3 pontos no índice de Gini.

Portanto, o trabalho de Romer e Romer fornece evidências empíricas sobre o impacto da política monetária na pobreza e desigualdade de renda, mostrando que aumentos na taxa de inflação estão associados a um aumento na desigualdade de renda, medido pelo índice de Gini.

Easterly e Fischer (2001) conduzem duas investigações empíricas um pouco distintas relacionadas à inflação e renda. Na primeira parte, eles realizam uma pesquisa sobre as principais preocupações dos cidadãos em 38 países, com mais de 30 mil participantes. Cada pessoa foi solicitada a escolher suas três maiores preocupações de uma lista de 15 assuntos. Com base nesses dados, os autores estimam a probabilidade de indivíduos de diferentes níveis de renda citarem a inflação como uma de suas preocupações, controlando pelos efeitos fixos de cada país.

Os resultados mostram que "inflação e preços altos" foram o terceiro assunto mais citado, ficando atrás apenas de "criminalidade" e "desemprego/recessão". As estimativas do modelo probit que eles usaram revelam que indivíduos mais pobres têm uma maior probabilidade de citar a inflação como uma preocupação.

Na segunda parte do artigo, Easterly e Fischer examinam o efeito do imposto inflacionário na desigualdade e na pobreza por meio de regressões cross-country. A desigualdade é medida pela renda do quintil mais pobre da economia, enquanto a pobreza é medida pela porcentagem de pessoas abaixo de uma linha de pobreza específica em cada país.

As regressões revelam que mais inflação está associada a níveis mais altos de pobreza e maior desigualdade de renda. Uma das estimativas mostra que a transição de uma situação de

inflação zero para hiperinflação reduziria em 1,7 pontos percentuais a parcela da renda total pertencente ao último quintil (os mais pobres), em média, 6,2%. Se a inflação subisse de zero para 40%, a queda seria de 0,5 pontos percentuais.

Portanto, os estudos empíricos de Easterly e Fischer fornecem evidências de que a inflação tem um impacto negativo na renda dos mais pobres, aumentando a pobreza e a desigualdade de renda.

Bulíř (2001) realiza uma análise dos dados em linha com estudos anteriores sobre a hipótese de Kuznets, que postula uma relação em forma de "U" invertido entre renda e desigualdade. Com o objetivo de estudar uma versão expandida dessa curva, que incorpora os efeitos da inflação na desigualdade, o autor regressa o índice de Gini em relação ao PIB per capita e seu quadrado, emprego estatal, transferências e variáveis binárias. Ele considera diferentes faixas de taxas de inflação: muito baixas (0 a 5% anuais), baixas (5% a 40% anuais), altas (40% a 300% anuais) e hiperinflações (acima de 300% anuais).

Por meio de estimativas OLS e IV (usando transferências governamentais como variável endógena, mas excluindo a inflação), com dados em cross-section, Bulíř conclui que as hiperinflações têm um impacto negativo significativo na distribuição de renda, aumentando o índice de Gini em cerca de oito pontos percentuais. No entanto, alterações na inflação em outros patamares têm efeitos quase negligenciáveis na distribuição de renda.

Uma possível explicação para a diferença entre esses resultados e estudos anteriores é o uso de um maior número de variáveis de controle e de dummies de inflação, em substituição ao foco exclusivo no imposto inflacionário.

Essas descobertas apontam para o fato de que as hiperinflações exercem um impacto significativo e negativo na desigualdade de renda, enquanto as variações de inflação em outras faixas têm efeitos mínimos sobre a desigualdade. Essa evidência adiciona uma perspectiva mais abrangente aos estudos anteriores sobre a relação entre inflação e desigualdade, considerando diferentes níveis de inflação e variáveis adicionais de controle.

Por fim, como os modelos de previsões são parte fundamental dessa monografia, o artigo acadêmico de Barbosa (2019) "Prevendo a Inflação Brasileira: Comparação Entre um Modelo Teórico e um Ateórico de Séries Temporais" serve para debater a eficiência e as aplicações desses modelos, pois aborda a previsão de inflação no contexto brasileiro, considerando o período de instabilidade econômica durante as décadas de 1980 e início dos anos 90, que foi marcado por elevadas pressões inflacionárias. O autor destaca que o Plano Real, implementado em 1994, foi bem-sucedido na redução da inflação no Brasil, e a partir de

março de 1999, o país adotou o regime de metas de inflação, com o Banco Central sendo responsável por controlar os preços na economia. O índice de referência para a meta de inflação é o Índice de Preços ao Consumidor Amplo (IPCA).

O autor enfatiza a importância da previsão da inflação para diversos agentes econômicos, incluindo produtores, que ajustam seus preços levando em consideração a inflação, e detentores de ativos financeiros vinculados ao IPCA. Para melhorar a precisão das previsões de inflação, o autor recorre a modelos baseados em séries temporais, citando a pesquisa de Makridakis et al. (1982) e Makridakis e Hibon (2000) que sugere que esses modelos superaram outras abordagens na previsão de inflação.

O objetivo do artigo é comparar dois modelos de séries temporais para a previsão de inflação de curto prazo no Brasil. O primeiro modelo é "ateórico" e se baseia na metodologia de Box & Jenkins, enquanto o segundo modelo incorpora pressupostos da teoria econômica tradicional. O artigo detalha as fontes de dados utilizadas, incluindo o IPCA, taxa de desemprego, taxa de juros e taxa de câmbio, além da expectativa média de inflação para os próximos 12 meses.

A seção seguinte do artigo se concentra na metodologia de Box & Jenkins, que visa identificar e estimar um modelo estatístico, geralmente um modelo ARIMA, que melhor represente a série temporal de inflação. O procedimento envolve a identificação, estimação e verificação de diagnóstico do modelo, seguido pela previsão da inflação com base no modelo ARIMA.

Na seção subsequente, o autor estende o modelo econômico, considerando a influência de outras variáveis além da inflação defasada. Essas variáveis incluem o hiato do desemprego, a taxa de câmbio, a taxa de juros e as expectativas de inflação. O autor explica como essas variáveis são incorporadas ao modelo e usa uma regressão para estimar a previsão da inflação com base nesses fatores econômicos.

A conclusão do estudo destaca que, embora o modelo ARIMA tenha sido bem-sucedido na previsão da inflação de curto prazo, a abordagem que incorpora variáveis econômicas, fundamentadas na teoria, teve um desempenho superior, especialmente nos meses imediatamente após a pesquisa. O autor argumenta que a inclusão dessas variáveis econômicas resultou em previsões mais precisas da inflação.

No geral, o artigo fornece uma análise detalhada da previsão de inflação no Brasil, comparando duas abordagens diferentes e sugerindo que a inclusão de variáveis econômicas

com base na teoria pode melhorar a precisão das previsões. Isso tem implicações significativas para o planejamento econômico e as políticas monetárias no contexto brasileiro.

O artigo de Baccarin e Oliveira (2021) avalia a relação entre inflação e desigualdade de renda no Brasil. A metodologia utilizada baseia-se em uma análise empírica de dados econômicos, com foco na variação dos índices de inflação e indicadores de desigualdade ao longo do tempo. A qualidade do artigo é um pouco genérica apesar de satisfatória, pois ele utiliza fontes confiáveis de dados e segue uma abordagem metodológica adequada.

No entanto, algumas lacunas podem ser identificadas na revisão da literatura. Embora o artigo forneça uma visão geral sobre a relação entre inflação e desigualdade de renda, não explora profundamente os mecanismos subjacentes que conectam esses dois fenômenos. Além disso, a revisão não considera adequadamente as diferentes perspectivas teóricas e opiniões divergentes sobre o tema.

No entanto, o presente artigo aparenta adotar uma abordagem baseada em um modelo de classificação da origem da desigualdade. Os resultados sugerem que, após a implementação do Plano Real, o efeito da inflação na desigualdade diminuiu significativamente. O estudo destaca a relevância das políticas de distribuição de renda como um fator que contribuiu para a redução do impacto da inflação na distribuição de renda. Além disso, a análise indica que a educação desempenha um papel importante no aumento da desigualdade, não apenas devido às diferenças salariais, mas também devido ao efeito assimétrico da informação, permitindo que os indivíduos mais bem informados se protejam melhor contra os efeitos da inflação.

Os estudos mencionados enfrentam desafios que limitam sua capacidade de identificar o verdadeiro efeito da inflação na desigualdade de renda. Uma das dificuldades diz respeito aos dados de desigualdade de renda utilizados. Embora representem um avanço em relação às bases de dados anteriores, os dados de Deininger e Squire (1996) ainda possuem problemas, conforme observado por Atkinson e Brandolini (2001).

Outro problema é o uso de dados em cross section, em vez de dados em painel. Ao utilizar dados em painel e estimadores de efeitos fixos, é possível mitigar o viés causado pela omissão de variáveis relevantes. Se essas variáveis forem constantes ao longo do tempo, elas podem ser interpretadas como um termo de heterogeneidade não observado para cada país, permitindo a correção desse problema de endogeneidade. Isso significa que estimativas consistentes podem ser obtidas, mesmo que as variáveis explicativas de interesse, como a inflação, estejam correlacionadas com esse termo de efeito fixo. Por exemplo, suponha que

países com instituições herdadas de seus colonizadores que incentivam a apropriação da riqueza pelos governantes tenham níveis mais altos de desigualdade. Essas instituições também podem levar a governos maiores e mais propensos a buscar rendas, que podem financiar excessivamente seus gastos por meio da inflação. Nesse caso, a inflação estaria correlacionada com essas instituições que também afetam a desigualdade de renda, o que enviesaria as estimativas baseadas em dados de cross section devido à presença de variáveis omitidas. Além disso, características geográficas, como a latitude, podem estar incorporadas nesse termo de heterogeneidade. Por exemplo, países com clima e tipos de solo específicos podem ser mais adequados para o cultivo de culturas que exigem mais trabalho. Essa característica geográfica, contida no termo de efeito fixo, aumentaria o índice de Gini das nações e poderia estar correlacionada com a inflação. O uso de dados em painel e estimadores de efeitos fixos aborda esse problema específico, mas torna inconsistentes as estimativas com dados de cross section. Além disso, ao utilizar estimadores de efeitos fixos, a variação dos dados dentro dos países, mas não entre eles, é considerada na obtenção das estimativas.

Uma terceira dificuldade está relacionada ao problema de endogeneidade. Al-Marhubi (1997, 2000) e Dolmas, Huffman e Wynne (2000), em seus estudos baseados em análise de dados de cross section, encontraram uma relação positiva entre desigualdade de renda e inflação, mas interpretaram essa relação de forma oposta. Segundo esses modelos de economia política, uma maior desigualdade exigiria mais distribuição de renda, financiada por meio da inflação. Nesses modelos, a inflação seria causada pela pressão por distribuição, que é maior em sociedades mais desiguais, e não o contrário. No entanto, Desai, Olofsgard e Yousef (2005) demonstraram que, ao usar dados em painel não encontramos evidências estatisticamente significativas da relação entre inflação e desigualdade de renda. Isso sugere que a simples utilização de dados em painel pode corrigir potencialmente o viés na estimação do efeito da inflação na desigualdade de renda. No entanto, se o problema de viés persistir mesmo com essa abordagem, é necessário recorrer a técnicas de variáveis instrumentais para obter resultados mais precisos.

Por fim, vale lembrar que apesar de vários autores comprovarem que políticas de distribuição de renda contribuem para minimizar o efeito da inflação sobre a desigualdade, esse tipo de política tem um efeito nocivo sobre a economia no geral. Isso acontece pois existe um potencial de "efeito preguiça" e a ineficiência de alocação de recursos. Quando a redistribuição de renda é realizada de forma excessiva ou pouco criteriosa, pode ocorrer uma desmotivação para o trabalho e uma menor busca por oportunidades de emprego. O efeito preguiça resulta da

percepção de que parte da renda é garantida independentemente do esforço individual, o que pode levar a uma redução na produtividade e no dinamismo econômico. Além disso, a alocação ineficiente de recursos decorrente das políticas de distribuição de renda pode levar a um desvio de investimentos e capital humano, prejudicando o desenvolvimento econômico a longo prazo. É importante, portanto, buscar um equilíbrio adequado entre a redistribuição de renda e a promoção de incentivos para o trabalho, garantindo que as políticas de distribuição não criem barreiras à mobilidade econômica e não comprometam a eficiência e a competitividade do país, sendo assim, em relação a inflação a melhor política econômica para o combate da desigualdade e um crescimento econômico sustentável será sempre uma política fiscal “coerente”.

3 METODOLOGIA:

O presente estudo se propõe a analisar, modelar e interpretar as flutuações e os picos identificados na variação cumulativa das variáveis ligadas aos setores de Alimentação, Transporte e Habitação. Para tal, um conjunto diversificado de séries temporais foi disponibilizado para inclusão neste documento, as quais foram classificadas em duas categorias distintas: Série Principal e Séries Secundárias, conforme as definições a seguir:

- Série Principal – Refere-se à série temporal que engloba a variação dos preços relacionados à Alimentação, Transporte e Habitação.
- Séries Secundárias – Compreende todos os demais dados fornecidos, destinados a serem testados como potenciais variáveis explicativas da Série Principal, incluindo o M4 em percentual do PIB, Taxa de Câmbio, Dívida Pública de 12 meses, cotação do petróleo, da carne e do trigo.

Para Alcançar esses propósitos, foi adotado o seguinte fluxo metodológico:

- Coleta e Tratamento dos Dados
- Análise Exploratória da Série Principal
- Modelagem da Série Principal
- Análise das Séries Secundárias em Relação à Série Principal
- Modelagem da Série Principal com a Incorporação das Séries Secundárias

É importante ressaltar algumas definições cruciais para a compreensão do estudo:

– Tendência: Este termo refere-se à direção predominante de crescimento ou decrescimento ao longo do tempo. Representa um componente da série temporal que demonstra a mudança sistemática ao longo do tempo, independentemente das flutuações aleatórias e sazonalidades presentes.

– Sazonalidade: Engloba fenômenos que se repetem em intervalos regulares de tempo, ou seja, eventos que ocorrem diariamente a uma determinada hora, todos os dias, ou em um mês específico de cada ano.

Vale mencionar também, que durante a condução da análise e modelagem estatística dos determinantes da inflação de ATH, foram utilizadas as linguagens de programação Python e R. Além disso, no Python, as bibliotecas pandas, seaborn e numpy foram empregadas para o tratamento dos dados, o matplotlib para a plotagem dos gráficos e algumas análises

exploratórias, enquanto a biblioteca statsmodels foi utilizada para a construção do modelo e suas previsões. No R foram utilizadas as bibliotecas fpp3, dplyr, autoplot, seasonal, gg_tsresiduals e algumas outras bibliotecas para funções mais simples como importar dados do Excel e etc. A integração dessas ferramentas possibilitou a aplicação efetiva dos modelos SARIMA (Seasonal AutoRegressive Integrated Moving Average) e TSLM (Time Series Linear Model), ampliando a robustez da investigação. Além disso, a combinação dessas linguagens facilitou a visualização e interpretação dos resultados por meio de gráficos detalhados. Essa estratégia analítica, permeou tanto a análise exploratória quanto a modelagem temporal e a visualização dos resultados por meio dos gráficos.

Enfim, o seguinte tópico tem como objetivo modelar a série, para isso os seguintes passos foram seguidos:

Verificação da Estacionariedade: Primeiramente, avaliamos se a série é estacionária. Caso contrário, aplicamos uma transformação adequada.

Análise de Correlação: Em seguida, examinamos os gráficos de correlação e correlação parcial entre os lags para determinar o modelo mais apropriado.

Seleção do Modelo: Calculamos os critérios de informação AIC (Critério de Informação de Akaike) e BIC (Critério de Informação Bayesiano) para identificar o melhor modelo.

Análise de Resíduos: Por fim, conduzimos uma análise dos resíduos do modelo selecionado.

3.1 COLETA E TRATAMENTO DOS DADOS

A coleta de dados para esta pesquisa foi realizada em fontes oficiais, incluindo sites do Banco Central, Instituto Brasileiro de Geografia e Estatística (IBGE), Ipeadata, Portal da Transparência, Ministério da Economia e Fundo Monetário Internacional/International Financial Statistics (FMI/IFS).

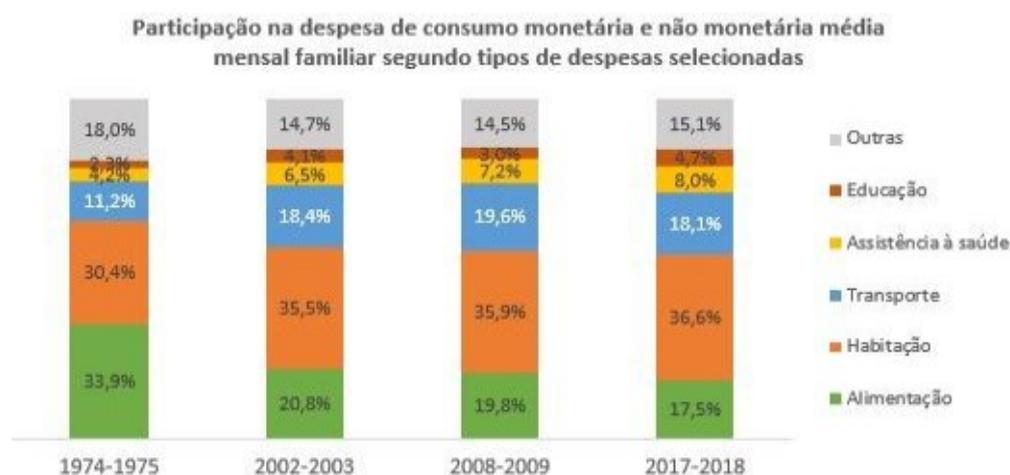
Os dados coletados que compreenderam a variação de Alimentação, Transporte e Habitação (ATH) ao longo do tempo, especificamente, os dados históricos de taxa de variação de Alimentação, Transporte e Habitação foram obtidos a partir do Índice Nacional de Preços ao Consumidor (INPC), que mede a variação dos preços da cesta de consumo das famílias assalariadas com baixa renda. O INPC tem como população-alvo famílias assalariadas

residentes nas áreas urbanas das regiões cobertas pelo Sistema Nacional de Índices de Preços ao Consumidor (SNIPC), com rendimentos de 1 a 5 salários mínimos. O cálculo do INPC é baseado nos resultados dos índices regionais, com uma ponderação baseada na população residente urbana, usando informações da Pesquisa de Orçamentos Familiares (POF) como fonte.

Os preços dos bens e serviços que compõem os grupos Alimentação, Transporte e Habitação, conforme definidos pela POF, são considerados na composição do INPC.

Após a coleta individual dos dados de taxa de variação histórica de Alimentação, Transporte e Habitação, esses dados foram combinados para criar uma única variável capaz de medir a taxa de variação dos três grupos simultaneamente. Para esse cálculo, foi aplicada uma média ponderada, na qual diferentes pesos foram atribuídos com base na estrutura de gastos das famílias, conforme a POF/IBGE de 2018. Foi considerada a composição dos gastos em cada grupo descrita na POF de 2018.

Figura 1 - Gasto médio familiar mensal por tipo de despesa



Para isso foi retirado os outros itens, e consideramos nossos gastos apenas em Alimentação, Habitação e Transporte que são os gastos que mais influenciam na renda. Para isso foi feito o seguinte cálculo:

Tabela 1 – Cálculo ponderado de ATH

Habitación: (36,6%) + Alimentação: (17,5%) + Transporte: (18,1%) = 72,2%			
Categoria	Percentual	Cálculo Individual	Percentual Relativo
Habitación	36.6	$(36.6 / 72.2) * 100\%$	50.69%
Alimentação	17.5	$(17.5 / 72.2) * 100\%$	24.23%
Transporte	18.1	$(18.1 / 72.2) * 100\%$	25.06%

A taxa de variação da Alimentação recebeu um peso de 24,21%, a taxa de variação do Transporte recebeu um peso de 25,10%, e a taxa de variação da Habitação recebeu um peso de 50,69%. Assim, o cálculo da Variação Total de Alimentação, Transporte e Habitação foi realizado da seguinte forma:

Variação Total de ATH = (Taxa de Alimentação * 0,2421) + (Taxa de Transporte * 0,2510) + (Taxa de Habitação * 0,5069).

Posteriormente, foi calculado o acumulado da variação ao longo do tempo, resultando na variável "Variação Acumulada de Alimentação, Transporte e Habitação" para melhor compreensão e análise de suas tendências através dos gráficos. O cálculo foi feito usando as seguintes formulas:

- I. Inicialmente, transformou a variação em porcentagem usando a fórmula:

$$VAR_{\text{percentual}} = \frac{VAR * 1}{100}$$
 Onde VAR representa a variação mensal.
- II. Em seguida, realizou o processo de acumulação com a fórmula:

$$VAR \text{ Acumulada (\%)} = (1 + VAR_{\text{percentual}} \text{ do mês anterior}) \times (1 + VAR_{\text{percentual}} \text{ do mês atual}) - 1.$$

3.2 ANÁLISE EXPLORATÓRIA DA SÉRIE PRINCIPAL:

3.2.1 Estacionariedade:

Embora a série temporal pareça ser estacionária devido à ausência aparente de tendência ao longo do tempo, é necessário realizar um teste de estacionariedade para validar as hipóteses. Mesmo que a série sugira estacionariedade visualmente, a confirmação por meio de testes estatísticos é crucial para garantir a robustez das conclusões e a adequação das análises subsequentes. Dessa forma, será possível verificar se a série atende aos critérios formais de estacionariedade, proporcionando uma base sólida para as inferências realizadas.

Teste de Dickey-Fuller Aumentado

Teste de Kwiatkowski–Phillips–Schmidt–Shin

Teste de Dickey-Fuller aumentado possui as seguintes hipóteses:

H_0 : Série é não estacionária

H_1 : Série é estacionária

Aplicando o teste obtivemos o seguinte resultado:

Tabela 2 – Resultados do Teste de Dickey-Fuller para a Série temporal VAR ATH

Teste	Dados	Dickey-Fuller	Ordem de Atraso (Lag)	Valor-p	Hipótese Alternativa
Augmented Dickey-Fuller Teste	total_var_ath	-4.8725	6	0.01	stationary

Considerando uma significância de 5%, a hipótese nula de não estacionariedade foi rejeitada, o que sugere que a série é estacionária de acordo com o Teste de Dickey-Fuller Aumentado.

Testes de Kwiatkowski–Phillips–Schmidt–Shin (KPSS)

O teste KPSS possui hipóteses invertidas quando comparadas ao teste de Dickey-Fuller aumentado, onde para o teste KPSS as hipóteses são dadas por:

$$H_0: \text{Série é estacionária}$$

$$H_1: \text{Série é não estacionária}$$

Aplicando o teste obtivemos o seguinte resultado:

Tabela 3 - Teste de KPSS para estacionariedade

Teste KPSS para estacionariedade em Nível	
Dados: df_total_var_ath	Nível KPSS = 0,2579, Parâmetro de Atraso de Truncamento = 5, Valor-p = 0,1

Considerando uma significância de 5%, a hipótese nula não é rejeitada, portanto é razoável assumir que a série é estacionária de acordo com o Teste KPSS.

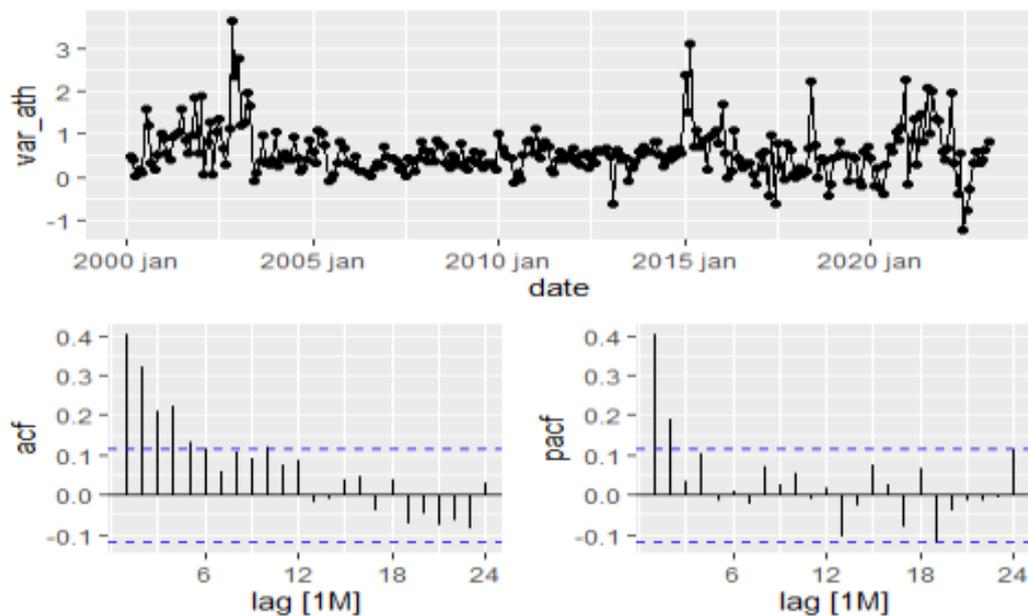
Assim, ambos os testes nos mostram que a série de variância de ATH é estacionária e portanto não é necessário aplicar uma transformação ou diferenciação.

3.3 MODELAGEM DA SÉRIE PRINCIPAL (FAC, FACP E ESCOLHA INICIAL DO MODELO):

A decomposição via SEATS e as Funções de Autocorrelação (FAC) e Autocorrelação Parcial (FACP) desempenham um papel importante na escolha do modelo apropriado. No

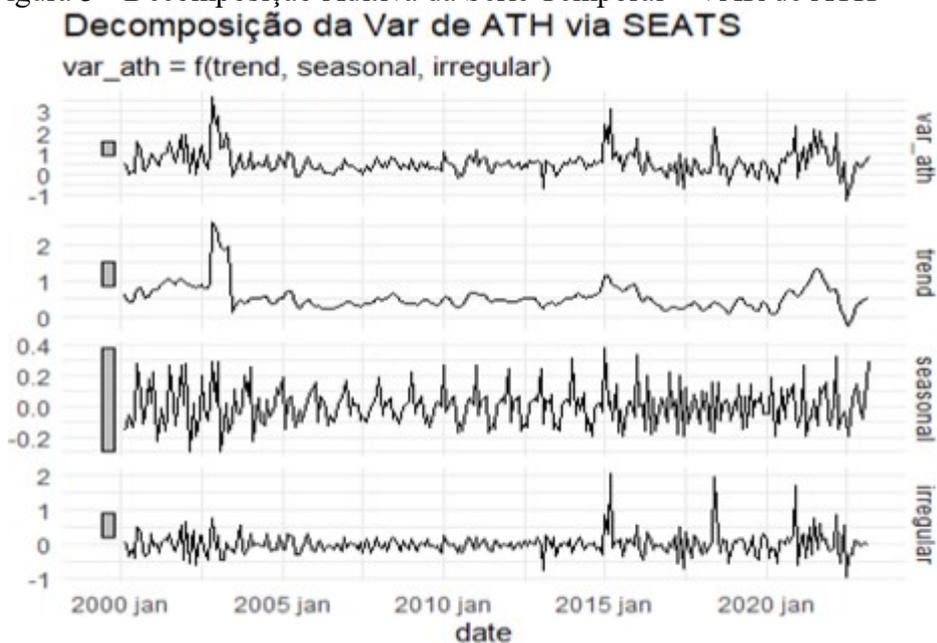
contexto da metodologia, os gráficos de FAC e FACP e a decomposição via SEATS são exibidos abaixo:

Figura 2 - Função de Autocorrelação (FAC) e Função de Autocorrelação Parcial (FACP)



Buscando entender melhor o comportamento das séries, o método de decomposição via SEATS foi utilizado.

Figura 3 - Decomposição Aditiva da Série Temporal – VAR de ATH



Assim, podemos interpretar que a série possui uma forte sazonalidade anual, ausência de uma tendência marcante e com períodos específicos de irregularidades aleatórias, que coincidem com os picos da série durante esses períodos de instabilidade.

A partir do gráfico de FAC, FACP e da análise via SEATS, os seguintes modelos foram testados:

- SARIMA(1,0,1)(P,D,Q)[12]
- SARIMA(1,0,0)(P,D,Q)[12]
- SARIMA(2,0,0)(P,D,Q)[12]
- SARIMA(1,0,1)(1,0,1)[12]

Ou seja modelos AR e ARMA.

Tabela 4 – Resultados dos modelos SARIMA

Modelo	Parâmetros	Coefficientes	Erro padrão	sigma ²	Log likelihood	AIC	AICc	BIC
SARIMA(1,0,1)	ar1, ma1, mean	0.7725, -0.4615, 0.5671	0.0799, 0.1131, 0.0731	0.2731	-212.68	433.36	433.5	447.87
SARIMA(1,0,0)	ar1, mean	0.4010, 0.5682	0.0548, 0.0530	0.2837	-218.41	442.82	442.9	453.7
SARIMA(2,0,0)	ar1, ar2, mean	0.3246, 0.1894, 0.5683	0.0587, 0.0587, 0.0639	0.2743	-213.3	434.6	434.74	449.11
SARIMA(1,0,1) (1,0,1)[12]	ar1, ma1, sar1, sma1, mean	0.7047, -0.5499, 0.7047, -0.5499, 0.5674	NaN, NaN, NaN, NaN, 0.0718	0.2752	-212.72	437.44	437.75	459.21

Modelo	ME	RMSE	MAE	MPE	MAPE	MASE	ACF1
SARIMA(1,0,1)	0.00080 32936	0.5197 612	0.3579 184	-63.60815	723.3327	0.8128666	0.0001459552
SARIMA(1,0,0)	0.00013 96902	0.5306 715	0.3639 262	-66.04963	583.2972	0.8265109	-0.07497678
SARIMA(2,0,0)	0.00032 63003	0.5209 393	0.3607 243	-93.42376	763.9542	0.8192392	-0.005427205
SARIMA(1,0,1) (1,0,1)	0.00073 66527	0.5198 407	0.3581 317	-66.23006	726.7531	0.8133512	0.002021729

Cada modelo foi ajustado aos dados e avaliado quanto às métricas de desempenho, como o Critério de Informação de Akaike (AIC), o AIC corrigido (AICc) e o Critério de Informação Bayesiano (BIC). Os resultados indicaram que os valores dessas métricas eram semelhantes entre os modelos testados.

Após a análise, seguindo a premissa de escolher o modelo mais parcimonioso, que proporciona bom desempenho com o menor número de parâmetros, o modelo selecionado foi o SARIMA(1,0,1)(0,0,0)[12].

Ou seja, durante a análise utilizamos os critérios BIC, AIC e AICc para determinar o melhor modelo. O modelo SARIMA (1, 0, 1)(0, 0, 0)[12] se destacou como a escolha preferencial com base nesses critérios.

Além disso, foi feita uma análise adicional para entender o melhor modelo considerando critérios como Erro Médio (ME), Erro Médio Quadrático (RMSE), Erro Absoluto Médio (MAE), Erro Percentual Absoluto Médio (MAPE) e Erro Médio Absoluto de Escala Média (MASE) que são bastante valiosos em análises de previsões. Foi observado que coincidentemente utilizando esses critérios o modelo (1, 0, 1)(0, 0, 0)[12] também foi que apresentou melhores resultados. Esses resultados reforçam a escolha do modelo para nossa análise.

O modelo final é representado pelos seguintes coeficientes:

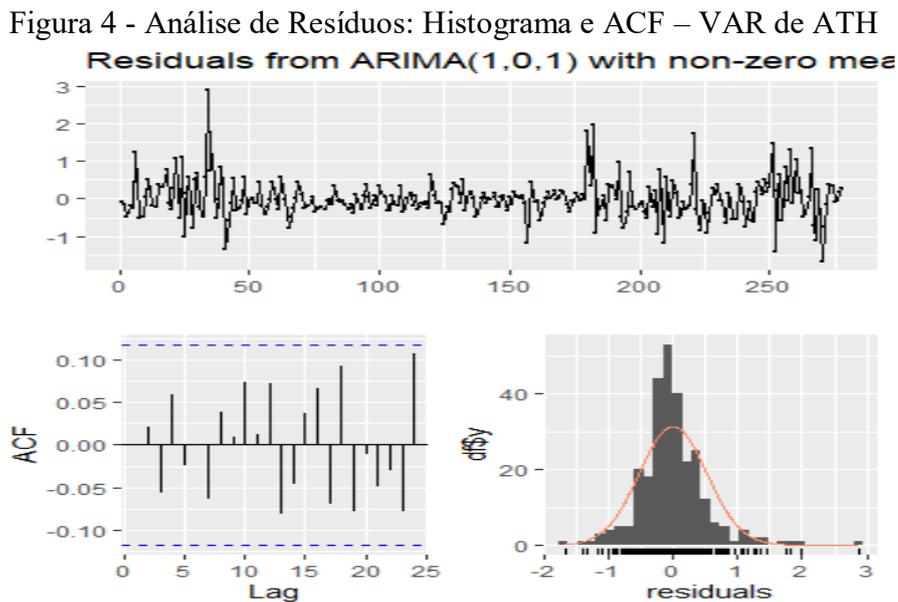
Tabela 5 – Resultado do Modelo SARIMA escolhido

Model	ar1	ma1	mean	s.e.	sigma^2	log likelihood	AIC	AICc	BIC
SARIMA(1,0,1) [12]	0.7725	-0.4615	0.5671	0.0799	0.2731	-212.68	433.36	433.5	447.87

3.3.1 Análise dos Resíduos

A análise de resíduos é essencial para verificar se os resíduos do modelo atendem às suposições de um modelo SARIMA. Os resíduos devem se comportar como um ruído branco,

ou seja, serem normalmente distribuídos com média zero, variância constante e independentes entre si. Abaixo está o gráfico da análise de resíduos:



Analisando o gráfico, podemos constatar que os resíduos seguem uma distribuição normal com média próxima de zero. Além disso, ao observarmos o gráfico de FAC (acf), identificamos que os resíduos não exibem correlações significativas, o que atende às pressuposições do modelo.

Para testar a hipótese de que os resíduos se comportam como ruído branco, foi realizado o Teste de Ljung-Box. As hipóteses foram definidas da seguinte forma:

$$H_0: \text{Resíduos são Ruído Branco}$$

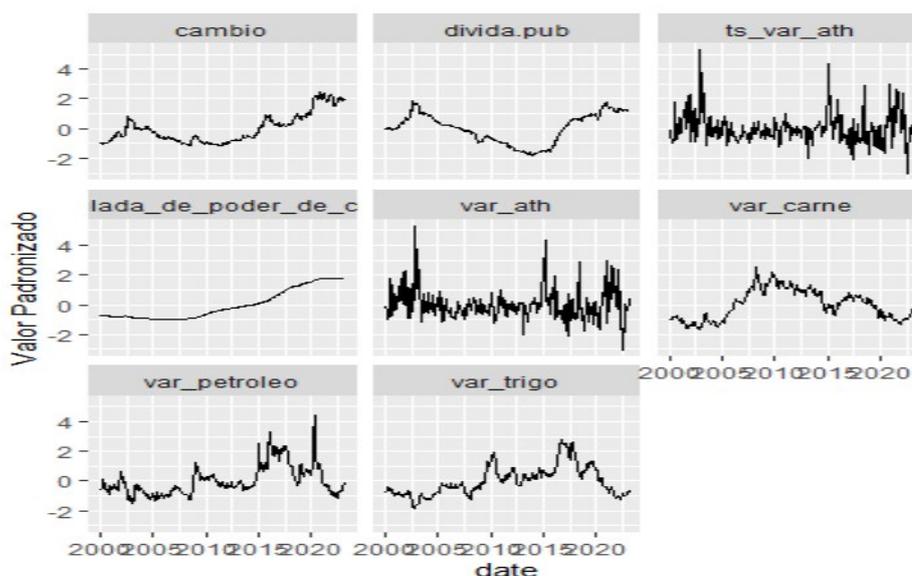
$$H_1: \text{Resíduos não são Ruído Branco}$$

Calculado um p-valor maior que uma significância de 10%, a hipótese nula não é rejeitada e portanto não rejeitamos a hipótese de que os resíduos seja ruído branco. Assim, vemos que os resíduos seguem as pressuposições do modelo.

3.4 ANÁLISE DAS SÉRIES SECUNDÁRIAS:

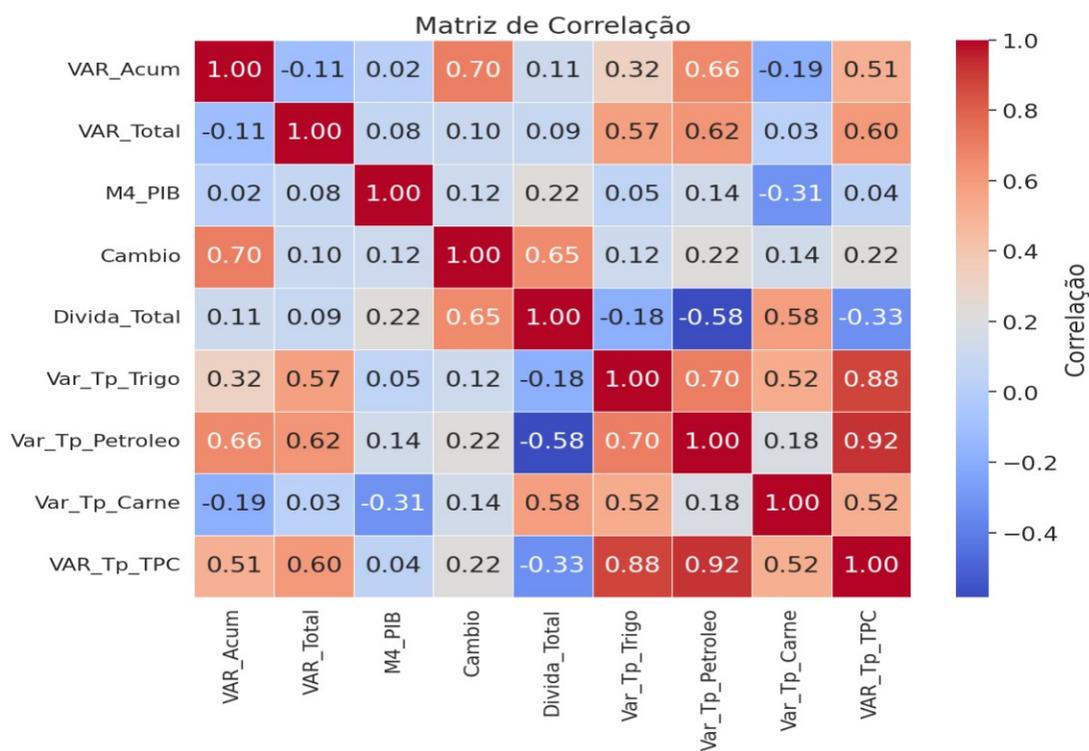
Nesta etapa, realizamos uma análise das séries secundárias em relação à série principal. O gráfico a seguir exibe a estrutura de correlação entre essas séries secundárias e a série principal:

Figura 5 - Gráficos das variáveis secundárias



As séries secundárias apresentaram a seguinte estrutura de correlação com a série principal (Série principal é a segunda linha da matriz de correlação).

Figura 6 - Matriz de Correlação



Analisando a matriz de correlação, observamos que as variáveis secundárias, como "Taxa de Câmbio," "Soma da Variação do Poder de Compra do Trigo e Petróleo," "Variação Total do Poder de Compra (TPC)," e "Variação de Poder de Compra TPC" apresentam diferentes níveis de correlação com a série principal. Além disso, notamos que algumas dessas variáveis são funções uma das outras, como Variação acumulada do Poder de Compra TPC, que é uma soma acumulada das variações do poder de compra do Trigo, da Carne e do Petróleo.

Com o objetivo de evitar problemas de multicolinearidade no modelo, optei por incluir no modelo apenas as variáveis que não podem ser expressas como funções lineares das outras variáveis secundárias.

3.5 MODELAGEM DA SÉRIE PRINCIPAL COM A INCORPORAÇÃO DAS SÉRIES SECUNDÁRIAS

O modelo construído teve o seguinte resultado:

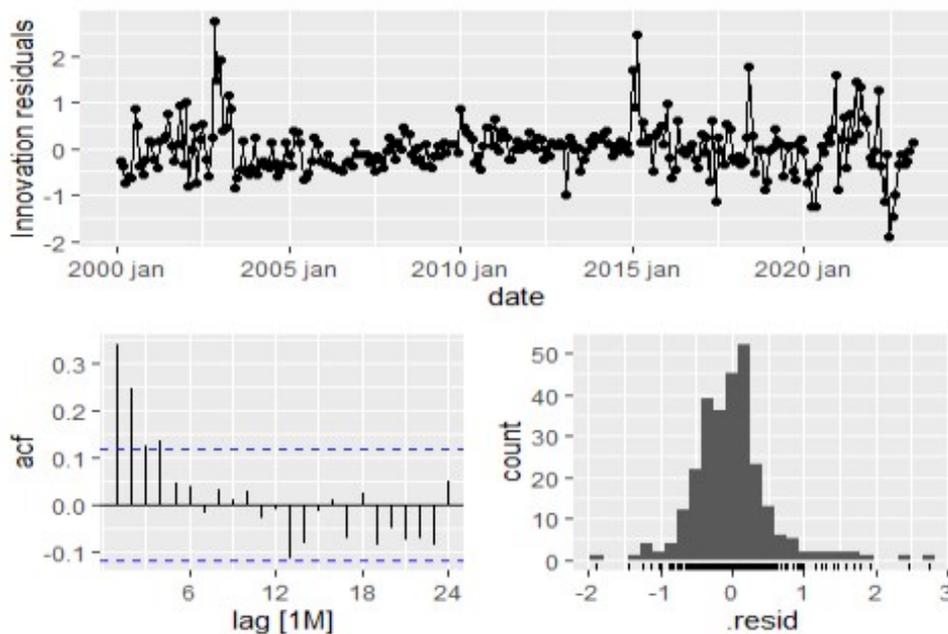
Tabela 6 - Resultados do modelo secundário TSLM (Time Series Linear Model)

Serie:	var_ath			
Model:	TSLM			
Residuals:				
Min	1Q	Median	3Q	Max
-1.88694	-0.32771	-0.01836	0.22955	2.74097
Coefficients:				
	Estimate	Std Error	t value	Pr(> t)
(Intercept)	0.80666	0.13940	5.787	1.97e-08 ***
cambio	-0.02119	0.03723	-0.569	0.56965
var_trigo	-0.39450	0.13505	-2.921	0.00378 **
var_petroleo	0.08372	0.04597	1.821	0.06967 .
var_carne	-0.22906	0.11575	-1.979	0.04883 *
Signif. codes:	0 '***'	0.001 '**'	0.01 '*'	0.05 '.' 0.1 '' 1
Residual standard error:	0.5552 on 273 degrees of freedom			

Multiple R-squared:	0.09913	Adjusted R-squared:	0.08593
F-statistic:	7.51 on 4 and 273 DF	p-value:	9.4169e-06

Com os seguintes resíduos:

Figura 7 - Análise de Resíduos: Histograma e ADC – REG SECUNDÁRIA



3.6 AJUSTE DA VARIÁVEL DE DÍVIDA PÚBLICA

Figura 8 - Gráfico comparativo – VAR ATH e VAR de Dívida Publica

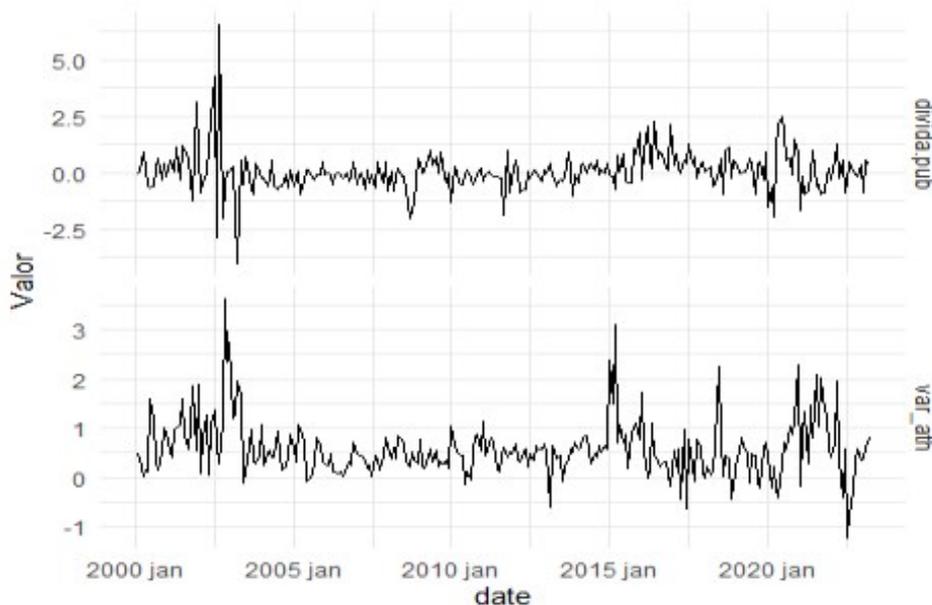


Tabela 7 - Resultado do modelo TSLM (Time Series Linear Model) com a variável de Dívida pública

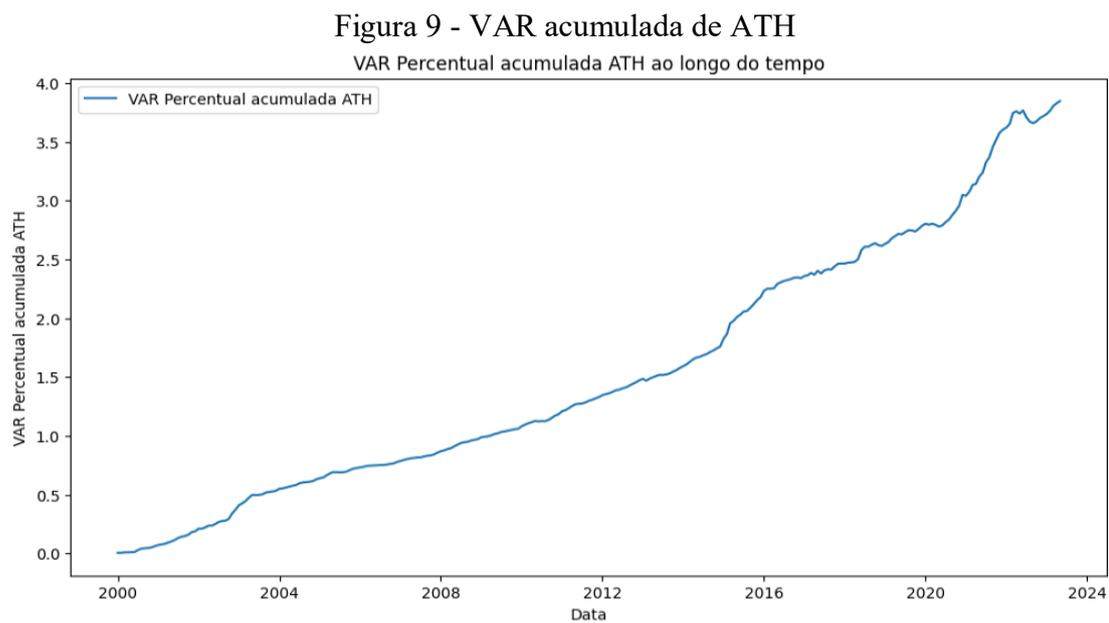
Serie:	var_ath				
Model:	TSLM				
Residuals:					
Min	1Q	Median	3Q	Max	
-1.92172	-0.30427	-0.02934	0.21229	2.79466	
Coefficients:					
	Estimate	Std	Error	t value	Pr(> t)
(Intercept)	1.194053		0.261917	4.559	7.78e-06***
cambio	0.019939		0.043947	-0.454	0.65040
var_trigo	-0.388307		0.134590	-2.885	0.00423**
var_petroleo	0.064805		0.047064	1.377	0.16966
var_carne	-0.302576		0.122775	-2.464	0.01434 *
divida.pub	-0.010250		0.005875	-1.745	0.08220
Signif. codes:	0 '***'		0.001 '**'	0.01 '*'	0.05 '.' 0.1 ' ' 1
Residual standard error:	0.5531 on 272 degrees of freedom				
Multiple R-squared:	0.1091	Adjusted R-squared:	0.09272		
F-statistic:	6.661 on 5 and 272 DF	p-value:	7.1559e-06		

O modelo secundário, utilizando um modelo TSLM (Time Series Linear Model), exibiu coeficientes significativos para algumas variáveis independentes, como var_trigo e var_carne, indicando uma possível relação com a variável de resposta var_ath. No entanto, o R² ajustado foi relativamente baixo (aproximadamente 9.27%), sugerindo que o modelo não conseguiu explicar adequadamente a variabilidade dos dados.

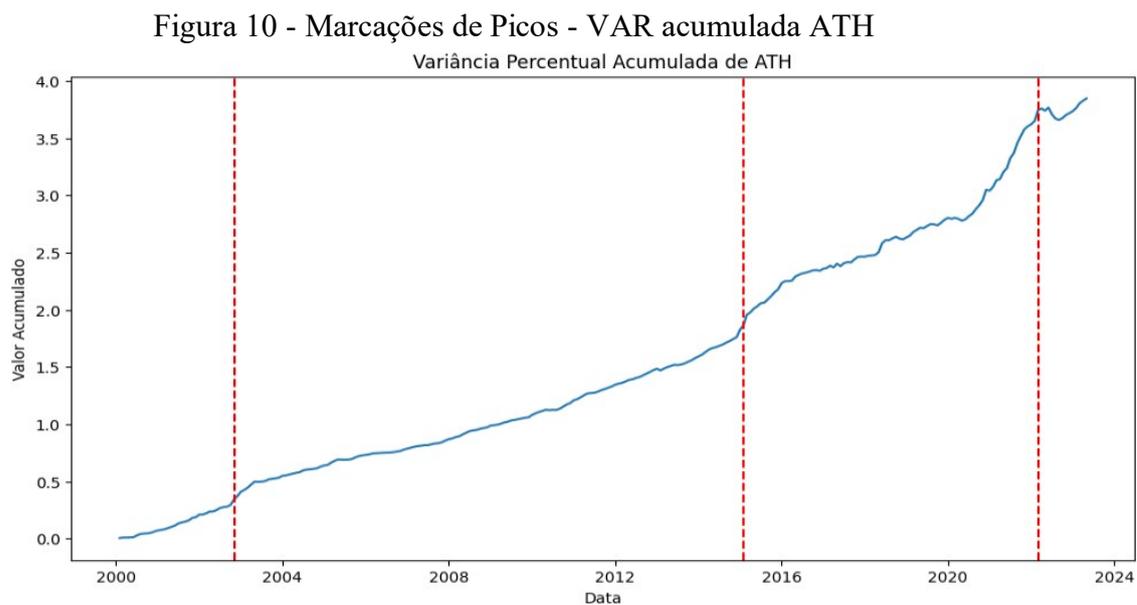
4 RESULTADOS EMPÍRICOS:

4.1 ANÁLISE EXPLORATÓRIA DA SÉRIE PRINCIPAL

A variância acumulada de ATH, é representada pelo seguinte gráfico:

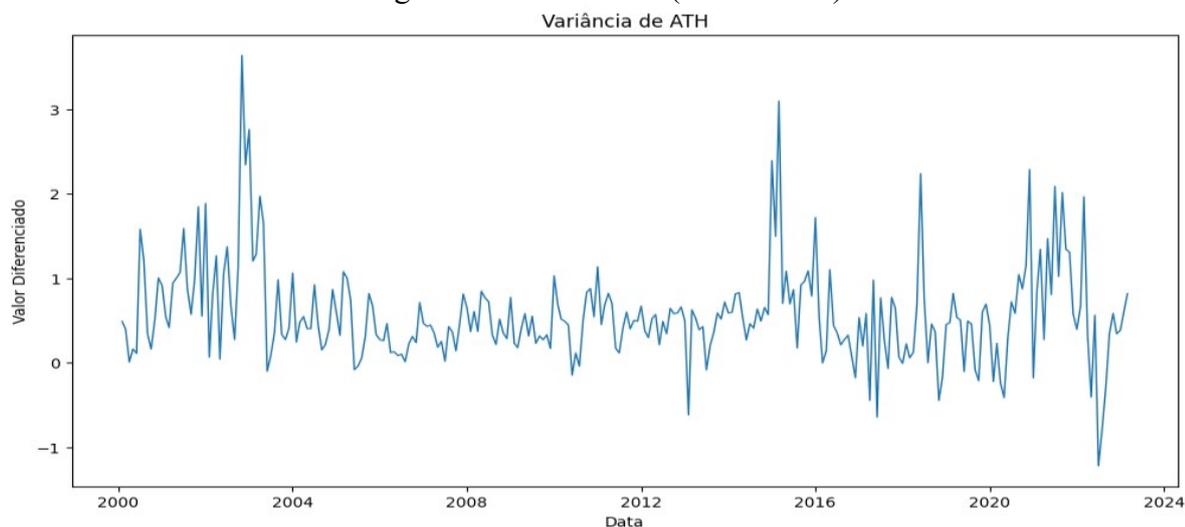


Podemos observar no gráfico abaixo picos distintos nos anos de 2003, 2015 e 2022.



Para aplicação do modelo a série precisa necessariamente ser estacionária, para isso foi plotado o seguinte gráfico para verificar a estacionariedade da série, consideramos seu comportamento, conforme ilustrado no gráfico abaixo:

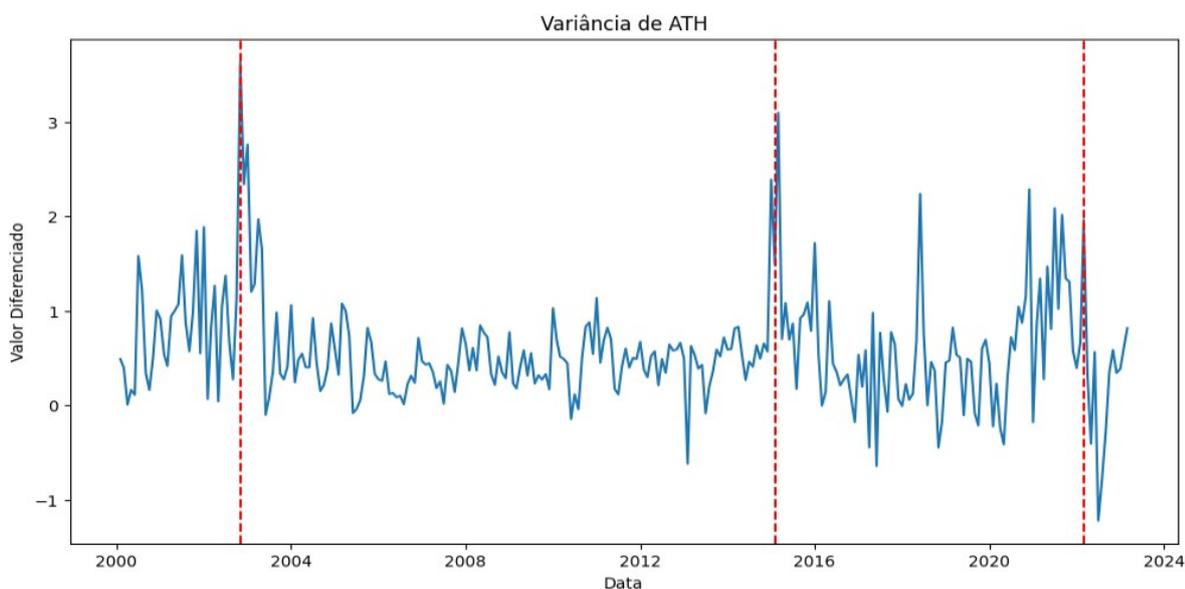
Figura 11 - VAR ATH (estacionária)



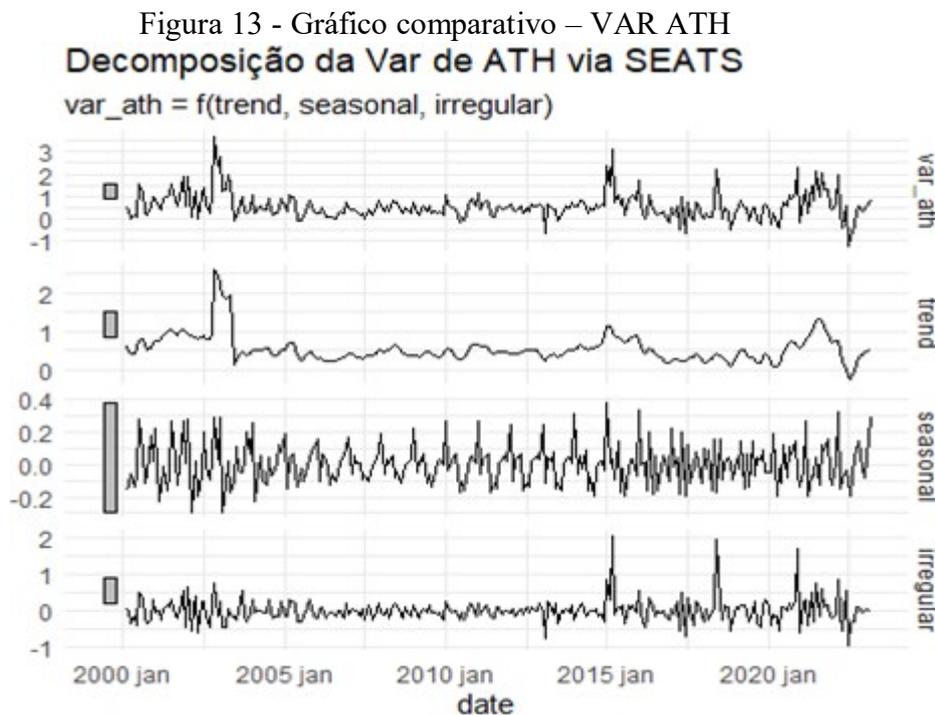
Conforme demonstrado no gráfico acima, observamos que a série parece ser estacionária. Para confirmar essa suposição foram utilizados os testes de Dickey-Fuller e Kwiatkowski–Phillips–Schmidt–Shin, que constatou a estacionariedade.

A partir disso, é possível vermos que a série apresenta uma maior variação exatamente nos picos observados no gráfico de variação acumulada.

Figura 12 - Picos - VAR ATH (estacionária)



Utilizando a decomposição da série via SEATS (Signal Extraction in ARIMA Time Series), podemos ver que os períodos de irregularidades são justamente certos períodos de picos da série, sendo eles em 2003, 2015, 2022.



Assim, podemos interpretar que a série possui uma forte sazonalidade anual, sem uma tendência marcante, e com períodos específicos de irregularidades aleatórias, onde os picos da série ocorrem no mesmo instante desses períodos de instabilidade.

4.2 COMPARAÇÃO ENTRE OS 2 MODELOS

A seguinte seção buscou comparar o modelo $AR(1)(0)(1)[12]$ e o modelo de Regressão Linear Temporal em relação aos seus valores ajustados.

Figura 14 - Modelo Autorregressivo SARIMA (1, 0, 1)[12]
Modelo Autorregressivo Sazonal

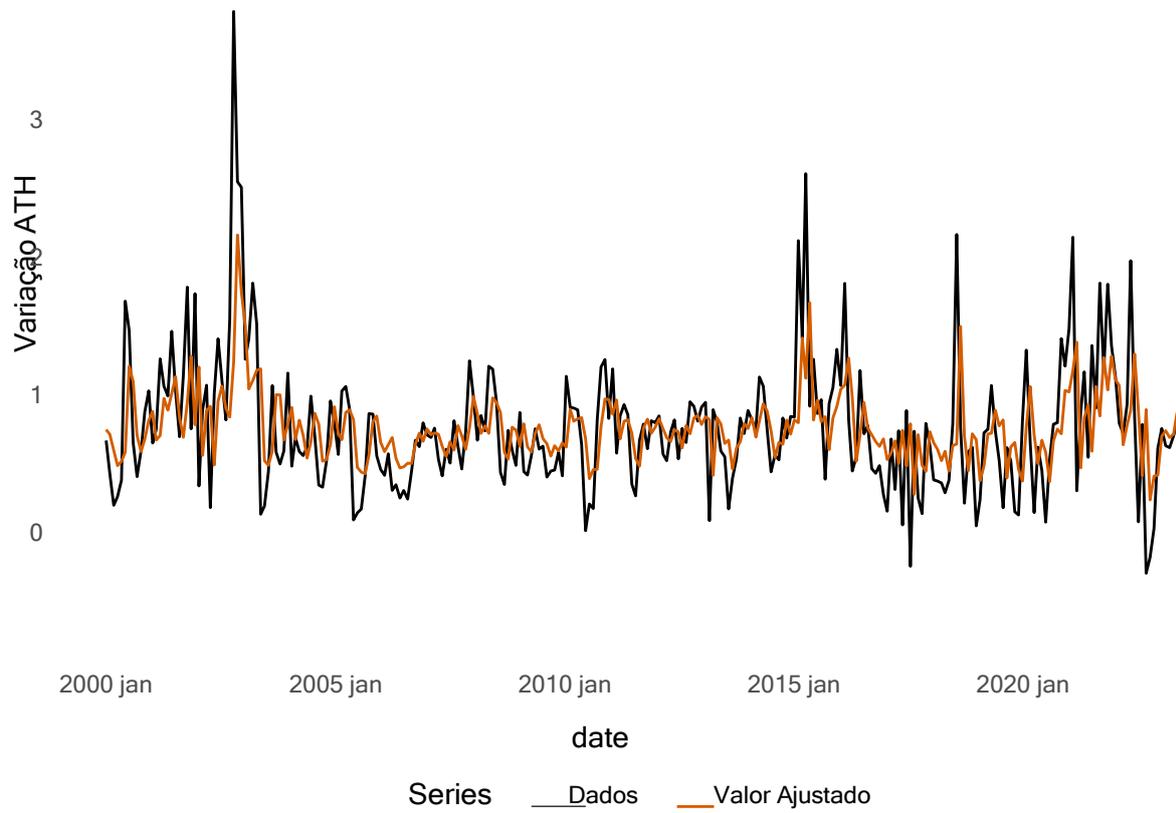
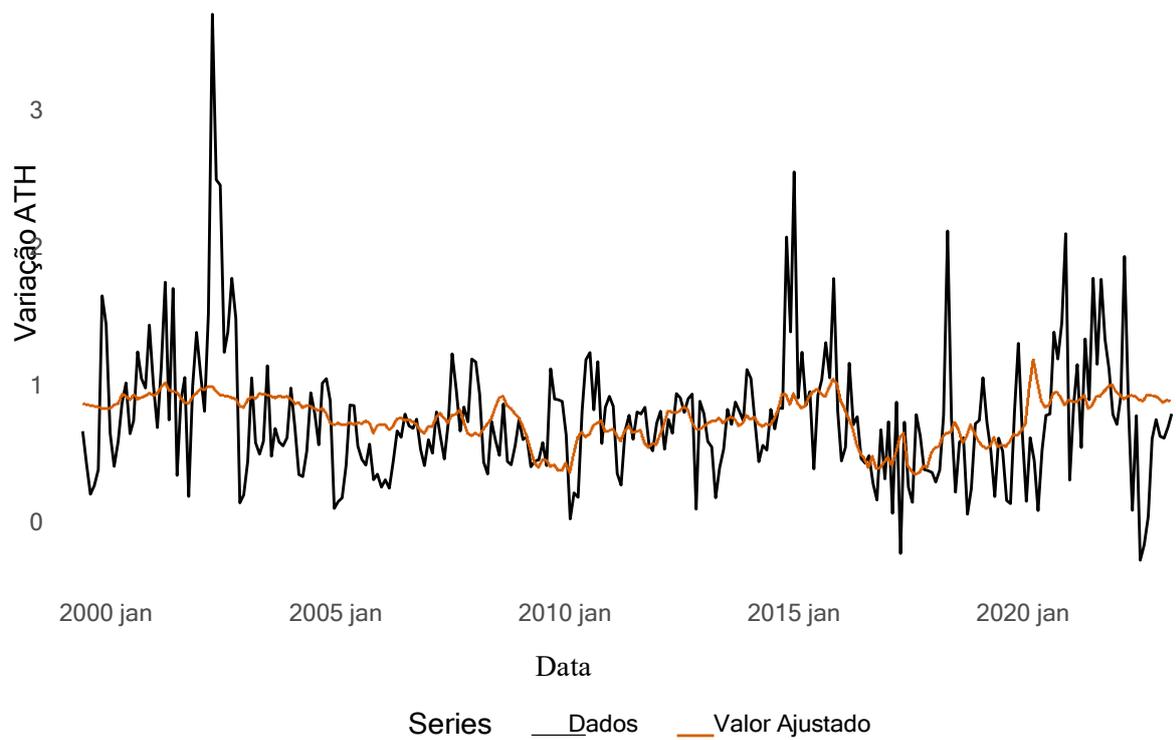


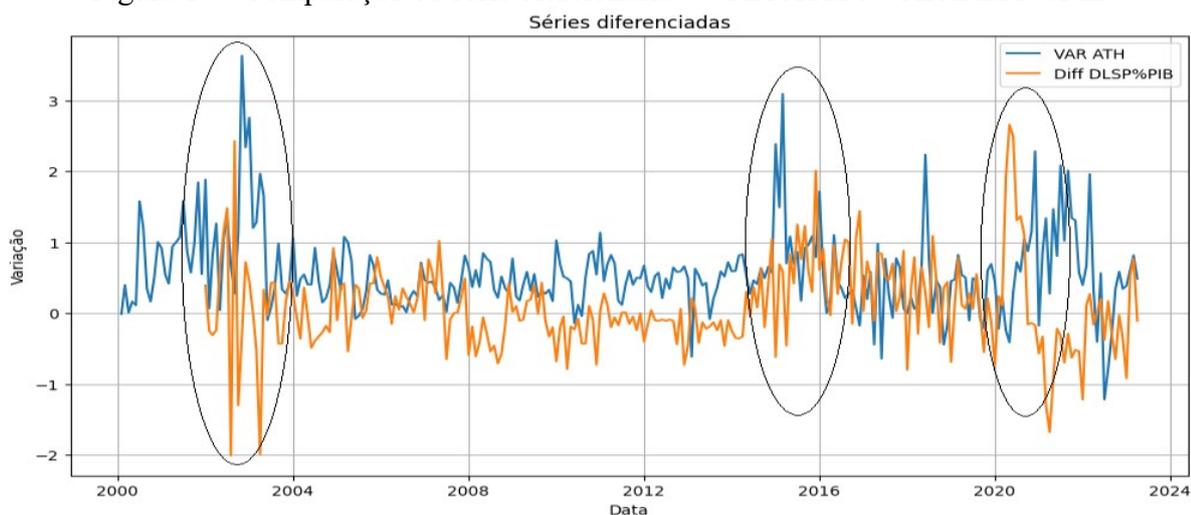
Figura 15 - Modelo (Regressão Linear Temporal)
Modelo de Regressão Linear Temporal



Analisando os valores ajustados, podemos concluir que o modelo SARIMA(1,0,1)[12] supera o modelo de Regressão Linear Temporal na captura de picos e depressões nos dados da série. A precisão do modelo autorregressivo se destaca em relação ao modelo de regressão linear, tornando-o a escolha preferencial para modelar a série de "variação da ATH".

Porém de acordo com a literatura, esse componente contínuo e inercial da inflação brasileira, ou seja, os períodos de normalidade na série de inflação, que não conseguimos correlacionar com variáveis que indicam aumento da base monetária e consequentemente aumento da demanda, pode ser atribuído à chamada inflação de custos, caracterizada por uma dinâmica própria e contínua que incorpora aumentos de preços de insumos internacionais, aumento do preço dos contratos, aumento de salários, produções agrícolas e etc, muito deles puxado exatamente pelo aumento do PIB. Como destacado no trabalho, houve tentativas de explicar a inflação por meio de variáveis tanto de impacto na demanda, como de impacto nos custos como taxa de cambio e cotação de commodities, mas essas variáveis mostraram-se pouco adaptadas à série temporal como um todo, isso pode ser explicado por falta de variáveis como variáveis de expectativas e outras variáveis que impactam os custos, porém se observarmos momentos específicos, podemos notar uma certa semelhança nos gráficos de Variação de (ATH), com a série de Necessidade de Financiamento público em % do PIB ou até mesmo a série da dívida líquida do setor público em % do PIB em momentos de picos.

Figura 16 - Comparação da série estacionária – VAR ATH e VAR DLSP%PIB



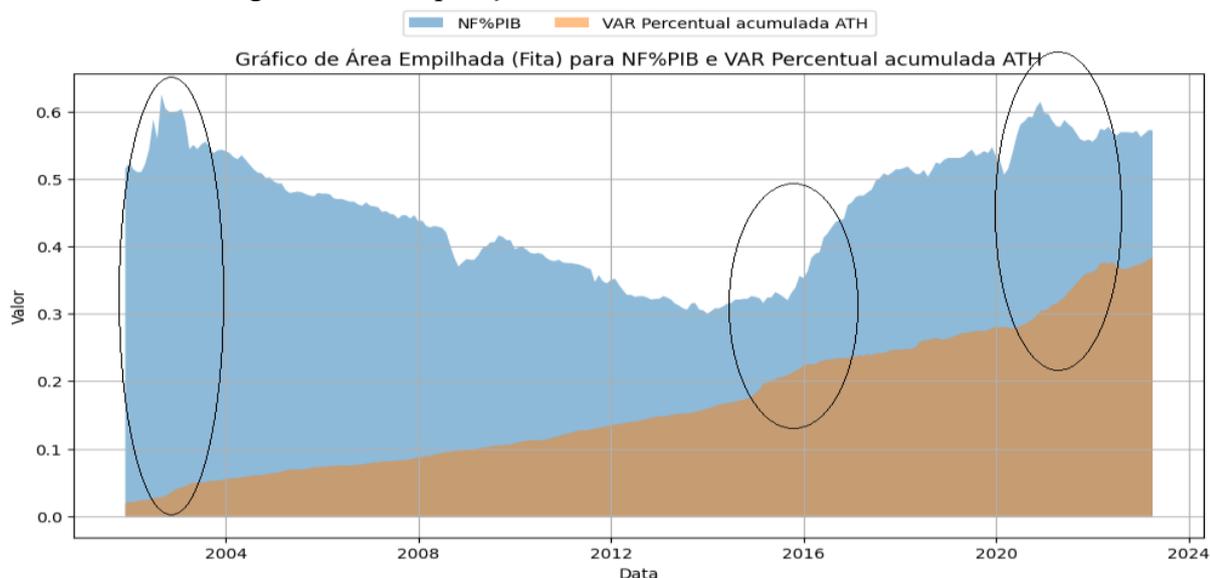
Para a plotagem da Figura 16, foi necessário a aplicação do método de diferenciação, a série de Dívida Líquida do Setor Público em % do PIB apesar de não apresentar uma tendência

definida em seu comportamento ao longo do tempo, também não possuía caráter de estacionariedade. Para lidar com essa característica, foi crucial aplicar uma diferenciação na série, transformando-a em uma forma estacionária. A diferenciação é um processo fundamental na análise de séries temporais, pois busca remover padrões de tendência e sazonalidade, possibilitando uma melhor compreensão dos padrões. Nesse contexto, a diferenciação da série permite explorar as variações puramente associadas às mudanças na variável de interesse, facilitando análises subsequentes e a identificação de padrões mais claros.

- Cálculo de Diferenciação: $\Delta Y_t = Y_t - Y_{t-1}$
- Onde: ΔY_t representa a diferença entre o valor da variável na observação atual (Y_t) e o valor na observação anterior (Y_{t-1}).

Por outro lado, o gráfico abaixo trata da relação da variação de acumulada de ATH com a Necessidade de financiamento do governo em % do PIB, não mais em caráter estacionário. Porém como podemos observar, ambas as variáveis em momentos atípicos apresentam uma certa correlação.

Figura 17 - Comparação – VAR acumulada ATH e NF%PIB



4.3 PROJEÇÕES E ANALISES DE CENÁRIOS

Além da análise e modelagem estatística para compreender a série de Variação Acumulada de ATH (Alimentação, Transporte e Habitação), é possível também através do

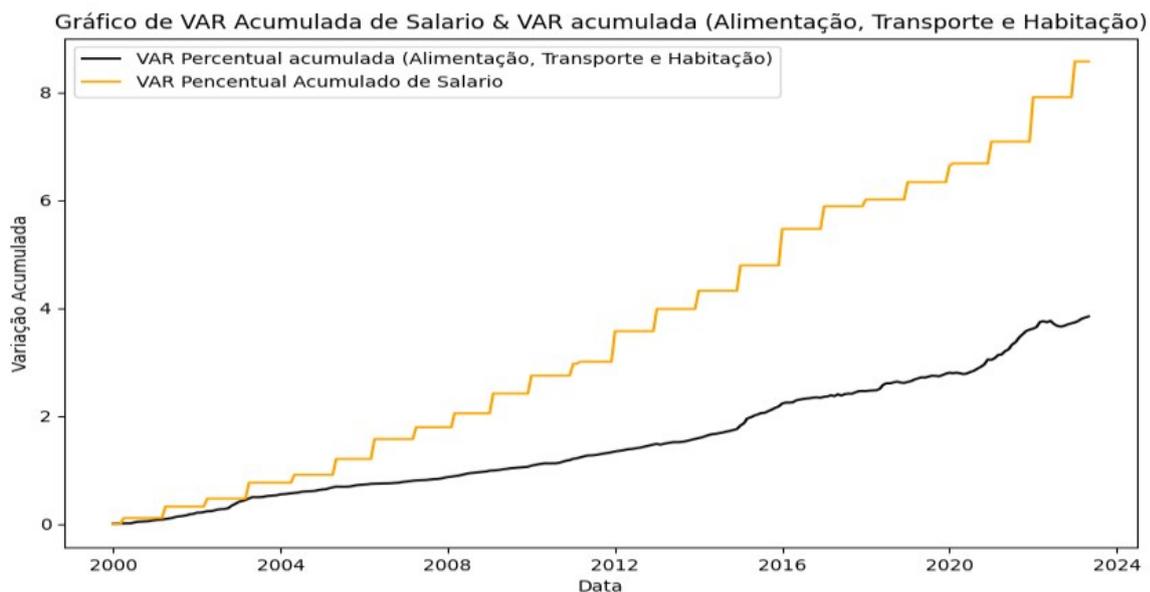
gráfico e da tabela abaixo observar que o salário teve ganhos reais ao longo dos anos se usarmos como critério a Variação Acumulada de (ATH).

Tabela 8 - Ajuste de Salário anual 2000 à 2023

Ano	Salário Mínimo	Reajuste Salário Mínimo
2023	R\$ 1.320,00	1,38%
2023	R\$ 1.302,00	7,43%
2022	R\$ 1.212,00	10,18%
2021	R\$ 1.100,00	5,26%
2020	R\$ 1.045,00	0,58%
2020	R\$ 1.039,00	4,10%
2019	R\$ 998,00	4,61%
2018	R\$ 954,00	1,81%
2017	R\$ 937,00	6,47%
2016	R\$ 880,00	11,67%
2015	R\$ 788,00	8,80%
2014	R\$ 724,00	6,78%
2013	R\$ 678,00	9,00%
2012	R\$ 622,00	14,13%
2011	R\$ 545,00	0,92%
2011	R\$ 540,00	5,88%
2010	R\$ 510,00	9,67%
2009	R\$ 465,00	12,00%
2008	R\$ 415,00	9,21%
2007	R\$ 380,00	8,57%
2006	R\$ 350,00	16,67%
2005	R\$ 300,00	15,38%
05/2004	R\$ 260,00	8,33%
04/2003	R\$ 240,00	20,00%
2002	R\$ 200,00	11,11%
2001	R\$ 180,00	19,21%
2000	R\$ 151,00	11,03%

Também, por meio do gráfico apresentado abaixo, é possível observar o crescimento da variação acumulada dos salários em comparação com o índice agregado que engloba Alimentação, Transporte e Habitação. Constatamos que, no período compreendido entre os anos de 2000 e 2023, os salários experimentaram uma apreciação real. Nesse contexto, os salários atingiram um patamar 472,8% superior à inflação relacionada a Alimentação, Transporte e Habitação. Em termos absolutos, o salário registrou um crescimento de 857,4% ao longo desses anos, enquanto o índice agregado de inflação referente a Alimentação, Transporte e Habitação aumentou em 384,66%.

Figura 18 - Comparação – VAR acumulada de Salário e VAR acumulada ATH



Após isso construímos um gráfico deflacionando o salário em relação a variação percentual de (ATH).

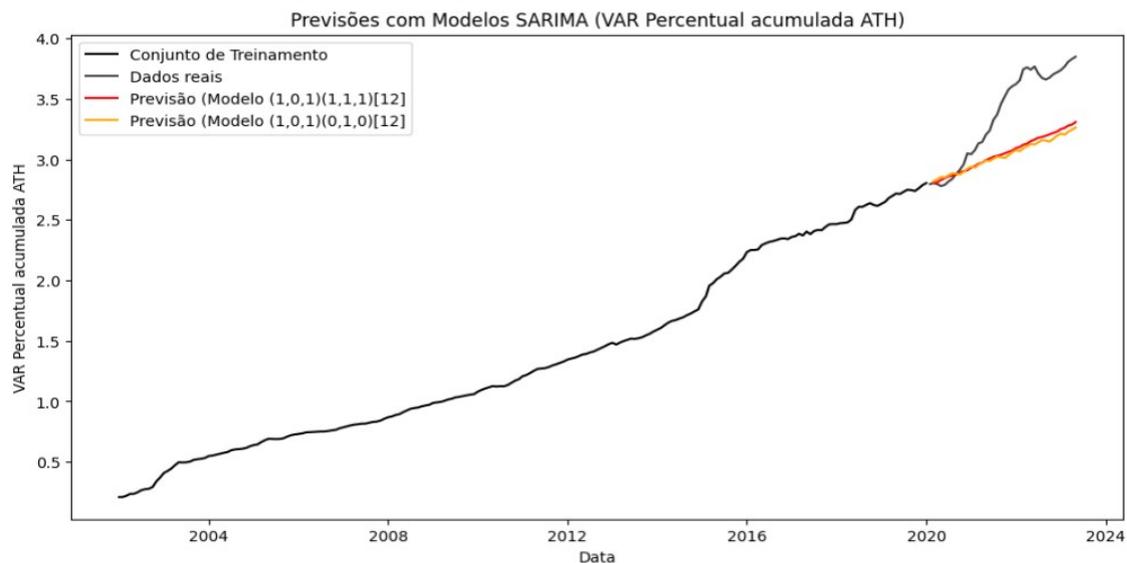
Figura 19 - Salário Real 2000 à 2023



Usando o método de deflacionamento, deflacionamos o salário em relação a variação percentual de (ATH), a partir disso foi construído o gráfico acima que demonstra a trajetória do salário real ao longo de tempo. Onde podemos observar que a partir de 2016 o salário estagnou, não obtendo ganhos reais significativos em relação a inflação.

Por fim, utilizando o modelo SARIMA descrito ao longo deste processo metodológico, realizou-se uma projeção. Foram selecionados parâmetros que buscam otimizar a parcimônia e minimizar o Erro Quadrático Médio (MSE) para a previsão de cenários, levando em consideração a análise exploratória anterior. Os dados utilizados no modelo já encontravam-se estacionários. Com base nisso, os parâmetros escolhidos resultaram em dois modelos SARIMA: $(1, 0, 1)(1, 1, 1)[12]$ e o SARIMA $(1, 0, 1)(0, 1, 0)[12]$.

Figura 20 - Projeção – VAR ATH (Sem Covid)



O modelo $(1, 0, 1)(1, 1, 1)[12]$ foi usado apenas para critério de comparação em relação ao modelo mais parcimonioso. Para isso, utilizamos o modelo ganhador da análise, usando os três critérios de AIC, AICc e BIC. Porém nesse caso foi adicionado uma diferenciação sazonal onde o modelo foi representado pelo SARIMA $(1, 0, 1)(0, 1, 0)[12]$ o uso da diferenciação sazonal nesse caso se deu por conta do ganho da capacidade preditiva demonstrado a partir do R^2 . Nessa etapa foi feita uma “previsão” da Variação Acumulada de (ATH) para os anos de 2020 em diante, ou seja, o objetivo dessa análise era projetar a Variação de (ATH) em um cenário sem a existência da crise de Covid19.

CONCLUSÃO

Ao analisar a série de variação nos setores de Alimentação, Transporte e Habitação, identificaram-se três picos notáveis nos anos de 2003, 2015 e 2022. O objetivo deste estudo foi modelar, compreender o comportamento e explicar esses picos.

Ao empregar o método SEATS para a decomposição de séries temporais, não foi possível identificar sazonalidades, assim como não foi possível enxergar uma tendência clara, porém picos de irregularidades aleatórias foram bem visíveis. Essas irregularidades ocorreram em períodos de tempo semelhantes aos picos.

Para entender melhor a dinâmica da série, foram estimados diversos modelos: SARIMA(1,0,1)[12], SARIMA(1,0,0)[12], SARIMA(2,0,0)[12], SARIMA(1,0,1)(1,0,1)[12] e os modelos TSLM com variáveis exógenas. O modelo que apresentou a melhor adaptação e os melhores valores e métricas de AIC e BIC foi o SARIMA(1,0,1)[12].

Um SARIMA(1,0,1)[12] é representado por: $Z_t = \phi_1 Z_{t-1} + \theta_1 \epsilon_{t-1} + \epsilon_t$, onde $\phi_1 = 0.7725$ e $\theta_1 = 0.4615$. O erro ϵ_t segue uma distribuição normal com média zero e variância constante.

Após a estimação do modelo autorregressivo, foram estimados modelos de regressão linear temporal, incorporando variáveis exógenas para a estimação. O modelo de Regressão Linear Temporal estimado é dado por: $y_t = \beta_0 + \beta_1 X_{1t} + \beta_2 X_{2t} + \beta_3 X_{3t} + \beta_4 X_{4t} + \beta_5 X_{5t} + \beta_6 X_{6t} + \epsilon_t$. O vetor de variáveis explicativas inclui taxa de câmbio, variação na cotação de trigo, variação na cotação de petróleo, variação na cotação carne e dívida pública total. Os betas estimados e suas significâncias podem ser consultados nas seções anteriores.

No entanto, esse modelo não apresentou um bom desempenho, mostrando-se incapaz de captar os picos e depressões da série principal.

Ao comparar os modelos Autoregressivo e Regressão Linear Temporal, observou-se que o modelo autoregressivo apresentou um ajuste superior. Essa constatação sugere que a série de variação nos setores de Alimentação, Transporte e Habitação é mais adequadamente explicada por seus próprios padrões anteriores do que por outras variáveis exógenas.

Esses resultados indicam uma certa aleatoriedade e singularidade dos picos na dinâmica dessa série, reforçando a importância de considerar abordagens mais autoregressivas ao modelar esses fenômenos econômicos em específico.

A constatação de que a série de variação nos setores de Alimentação, Transporte e Habitação é melhor explicada por ela mesma em passos anteriores do que por outras séries

auxiliares sugere que os picos observados nos anos de 2003, 2015 e 2022 representam a parte aleatória do modelo SARIMA(1,0,1)(0,0,0)[12].

A interpretação final da série destaca que a variação nos setores de Alimentação, Transporte e Habitação pode ser significativamente explicada de maneira autoregressiva. Em um dado tempo T , os valores têm um peso de 0.7725 dos valores observados um mês antes ($T-1$) e 0.4615 dos valores observados um ano antes ($T-12$).

Em relação aos trabalhos citados na revisão de literatura que exploram a conexão entre inflação, hiperinflação, desigualdade e pobreza, vale ressaltar que o estudo busca contribuir para o entendimento ao focar nas categorias de despesas que mais afetam as famílias de renda mais baixa. Ao analisar a série de variação de Alimentação, Transporte e Habitação, juntamente com as séries secundárias de variação na Taxa de Câmbio, Dívida Pública e poder de compra das commodities, o trabalho busca compreender de maneira mais abrangente os fatores que podem influenciar a inflação dessas categorias essenciais e mais relevantes nos gastos das populações mais pobres. Dessa forma, a partir das análises, o trabalho busca trazer uma reflexão de como a inflação de Alimentação, Transporte e Habitação afeta os mais pobres e a desigualdade no geral, já que esse tipo de inflação influencia de forma reduzida a renda e os gastos das classes mais elevadas, já que alguns não possuem gastos de habitação, e como vimos, a partir da revisão de literatura, eles possuem meios e informações suficientes para se proteger dessa situação.

5 REFERÊNCIAS:

- ALBANESI, Stefania. **Inflation and inequality**. *Journal of Monetary Economics*. Vol. 54, n. 4, p. 1088- 1114, 2007.
- ATKINSON, Anthony B.; BRANDOLINI, Andrea. **Promise and Pitfalls in the Use of “Secondary” Data-Sets: Income Inequality in OECD Countries as a Case Study**. *Journal of Economic Literature*. Vol. XXXIX, September, p. 771-799, 2001.
- BACCARIN, José G.; OLIVEIRA, Jonatan. A. **Inflação de Alimentos no Brasil em Período da Pandemia da COVID-19: continuidade e mudanças**. *Revista Segurança Alimentar e Nutricional*, v.28, p. 1-14, 2021.
- BARBOSA, Leandro Mendes. **Previendo a Inflação Brasileira: Comparação Entre um Modelo Teórico e um Ateórico de Séries Temporais**. *Boletim Informações Fipe*, p. 44-49, 2019.
- BARROS, G.S.C.; CARRARA, A.F.; SILVA, A.F.; CASTRO, N.R. **A inflação dos alimentos em 2020 e seus gatilhos**.
- BULÍŘ, Aleš. **Income inequality: does inflation matters?** *IMF Staff Papers*. Vol. 48, n. 1, p.139-159, 2001.
- CYSNE, Rubens Penha; MALDONADO, Wilfredo; MONTEIRO, Paulo Klinger. **Inflation and income inequality: a shopping-time approach**. *Journal of Development Economics*. Vol. 78, p. 516-528, 2005.
- DE SOUZA, Luiz Daniel Willcox. **Inflação de custos e inflação de demanda: uma discussão acerca da natureza das causas da inflação**. 2001.
- DOLMAS, Jim; HUFFMAN, Gregory; WYNNE, Mark. **Inflation, inequality and central bank independence**. *The Canadian Journal of Economics*. Vol. 33, n. 1, p. 271-287, 2000.
- EASTERLY, William; FISCHER, Stanley. **Inflation and the poor**. *Journal of Money, Credit and Banking*. Vol. 33, n. 2, p. 160-178, 2001.
- EROSA, Andrés; VENTURA, Gustavo. **On inflation as a regressive consumption tax**. *Journal of Monetary Economics*. Vol. 49, n. 4, p. 761-795, 2002.
- FERREIRA, F. H. G., LEITE, P. G., LITCHFIELD, J. A. e ULYSSEA, G. **Ascensão e queda da desigualdade de renda no Brasil: uma atualização para 2005**. In:

BARROS, R. P. D., FOGUEL, M. N. e ULYSSEA, G. (Eds.). Desigualdade de renda no Brasil: uma análise da queda recente. Brasília: IPEA, 2007. p.359-377.

POF 2017-2018: Brasileiros já gastam mais com transportes do que com alimentação; habitação é a principal despesa das famílias. Disponível em: <<https://www.boavistaservicos.com.br/blog/economia/pof-2017-2018-brasileiros-ja-gastam-mais-com-transportes-do-que-com-alimentacao-habitacao-e-a-principal-despesa-das-familias/>>. Acesso em: 9 nov. 2023.

ROMER, Christina; ROMER, David. **Monetary policy and the well-being of the poor.** NBER Working Paper Series. N. 6793, 1998.