

UNIVERSIDADE FEDERAL DE JUIZ DE FORA
FACULDADE DE ECONOMIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ECONOMIA

Paulo Roberto Betbeder Gonçalves

Uma medida de NAIRU para o Brasil utilizando a PNAD Contínua

Juiz de Fora

2024

Paulo Roberto Betbeder Gonçalves

Uma medida de NAIRU para o Brasil utilizando a PNAD Contínua

Dissertação apresentada ao Programa de Pós-Graduação em Economia da Universidade Federal de Juiz de Fora como requisito parcial à obtenção do título de Mestre em Economia Aplicada:

Orientador: Professor Wilson Corrêa

Coorientador: Professor Rafael Souza

Juiz de Fora

2024

Betbeder, Paulo.

Uma medida de NAIRU para o Brasil utilizando a PNAD Contínua / Paulo Betbeder. -- 2024.
116 f.

Orientador: Wilson Corrêa

Coorientador: Rafael Souza

Dissertação (mestrado acadêmico) - Universidade Federal de Juiz de Fora, Faculdade de Economia. Programa de Pós-Graduação em Economia, 2024.

1. NAIRU. 2. Taxa de desemprego. 3. Singular Spectrum Analysis.
4. Decomposição de séries temporais. I. Corrêa, Wilson, orient. II. Souza, Rafael, coorient. III. Título.

Paulo Roberto Betbeder Gonçalves

Uma medida de NAIRU para o Brasil utilizando a PNAD Contínua

Dissertação apresentada ao Programa de Pós-graduação em Economia da Universidade Federal de Juiz de Fora como requisito parcial à obtenção do título de Mestre em Economia Aplicada. Área de concentração: Economia

Aprovada em 19 de agosto de 2024.

BANCA EXAMINADORA

Dr. Rafael Morais de Souza - Coorientador

Universidade Federal de Juiz de Fora

Dr. José Simão Filho

Universidade Federal de Juiz de Fora

Dr. Michel Candido de Souza

Universidade Federal dos Vales Jequitinhonha e Mucuri

Juiz de Fora, 27/08/2024.



Documento assinado eletronicamente por **Jose Simao Filho, Professor(a)**, em 27/08/2024, às 11:14, 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 **Rafael Morais de Souza, Professor(a)**, em 27/08/2024, às 14:16, 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 **Michel Candido de Souza, Usuário Externo**, em 28/08/2024, às 17:42, 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 **1947811** e o código CRC **C23C8B0B**.

RESUMO

A taxa de desemprego não acelerante da inflação – referida pela sua sigla em inglês: NAIRU – é definida como o nível de desemprego que não afeta o comportamento da inflação. Assim sendo, a NAIRU é uma variável não observável cuja utilidade, dentre outras, está no acompanhamento e/ou previsão da inflação (Gordon, 1997; Grant, 2000). Dessa maneira, o objetivo deste trabalho foi apresentar uma medida da NAIRU para a economia brasileira utilizando a série trimestral da taxa de desemprego da PNAD Contínua do primeiro trimestre de 2012 até o terceiro trimestre de 2023. Estabelecida como a tendência da taxa de desemprego, quatro modelos foram utilizados para mensurar a NAIRU: componentes não observados; filtro HP; *Singular Spectrum Analysis* (SSA); *Multivariate Singular Spectrum Analysis* (MSSA). Considerando todos os modelos, a NAIRU média para todo o período amostral foi de 10,5%, em que, exceto para o filtro HP, a variável evoluiu próxima à série – o que resultou em um hiato do desemprego periódico. Ademais, as avaliações das mensurações apontaram que as tendências que evoluíram próximas à série apontaram melhor o comportamento do IPCA acumulado no trimestre, enquanto as NAIRUs suavizadas corresponderam melhor ao IPCA acumulado em 4 trimestres. Dentre os modelos utilizados, o SSA foi único capaz de fornecer as NAIRUs adequadas para os dois horizontes da inflação, demonstrando a capacidade do método não paramétrico para a análise de séries econômicas.

Palavras-chave: NAIRU; Taxa de Desemprego; *Singular Spectrum Analysis*; Decomposição de Séries Temporais, Filtro HP; Modelo de Componentes não Observados.

ABSTRACT

The Non-Accelerating Inflation Rate of Unemployment – NAIRU – is defined as the level of unemployment that does not affect the behavior of inflation, therefore, the NAIRU is an unobservable variable whose usefulness, among others, lies in monitoring and forecasting inflation (Gordon, 1997; Grant, 2000). Then, the objective of this work was to present a NAIRU for the Brazilian economy using the quarterly series of PNAD Contínua unemployment rate from the first quarter of 2012 to the third quarter of 2023. Established as the trend of the unemployment rate, four models were employed to measure the NAIRU: unobserved components, HP filter, Singular Spectrum Analysis (SSA); Multivariate Singular Spectrum Analysis (MSSA). Considering all models, the average NAIRU for the entire sample period was 10.5%, where, except for the HP filter, the variable evolved closed to the series – which resulted in periodic unemployment gap. Furthermore, the measurement evaluations showed that the trends that evolved closed to the unemployment series better indicated the behavior of the IPCA accumulated in the quarter, while the smoothed NAIRUs corresponded better to the IPCA accumulated in four quarters. Among the models used, the SSA was the only capable of providing adequate NAIRUs for both inflation horizons, demonstrating the capacity of the non-parametric method for analyzing economic series.

Key-words: NAIRU; Unemployment Rate; Singular Spectrum Analysis; Time Series Decomposition; HP Filter; Unobserved Components Model.

LISTA DE TABELAS

Tabela 1 - Posição da taxa de desemprego em relação às NAIRUs mensuradas	85
Tabela 2 - Resultados dos testes das mensurações da NAIRU para o horizonte acumulado no trimestre.....	88
Tabela 3 - Resultados dos testes das mensurações da NAIRU para o horizonte acumulado em 4 trimestres	88
Tabela 4 - Posição ABAIXO/ACIMA da taxa de desemprego frente às NAIRUs selecionadas e NAIRU SSA 1 autotripla.....	95
Tabela 5 - Resultados dos testes da NAIRU SSA 1 autotripla e NAIRUs selecionadas para as séries acumuladas no trimestre	98
Tabela 6 - Resultados dos testes da NAIRU SSA 1 autotripla e NAIRUs selecionadas para as séries acumuladas em 4 trimestres.....	98

LISTA DE FIGURAS

Figura 1 - Log dos autovalores de 1 a 12 (SSA)	61
Figura 2 - Traçado dos autovetores de 1 a 12 (SSA)	62
Figura 3 - Traçado dos pares dos autovetores de 1 a 12 (SSA).....	63
Figura 4 - Matriz de w-correlação dos componentes (SSA)	64
Figura 5 - Log dos autovalores de 1 a 12 (MSSA)	69
Figura 6 - Traçado dos autovetores de 1 a 12 (MSSA).....	70
Figura 7 - Traçado dos pares dos autovetores de 1 a 12 (MSSA)	71
Figura 8 - Matriz de w-correlação dos componentes (MSSA).....	71

LISTA DE GRÁFICOS

Gráfico 1 - Evolução da taxa de desemprego.....	52
Gráfico 2 - Taxa de desemprego e NAIRU estimada via UCM.....	54
Gráfico 3 - Hiato do desemprego (UCM)	55
Gráfico 4 - Termo irregular do modelo UCM.....	56
Gráfico 5 - Função de autocorrelação dos resíduos.....	56
Gráfico 6 - Histograma dos resíduos	57
Gráfico 7 - Densidade kernel dos resíduos.....	57
Gráfico 8 - QQ plot dos resíduos.....	58
Gráfico 9 - Taxa de desemprego e NAIRU mensurada via filtro HP.....	59
Gráfico 10 - Hiato do desemprego (HP)	59
Gráfico 11 - Reconstrução da tendência para a série de taxa de desemprego (SSA)	65
Gráfico 12 - Reconstrução da sazonalidade para a série de taxa de desemprego (SSA)	66
Gráfico 13 - Reconstrução do ruído para a série de taxa de desemprego (SSA).....	66
Gráfico 14 - Taxa de desemprego e NAIRU (SSA)	67
Gráfico 15 - Hiato do desemprego (SSA)	67
Gráfico 16 - Evolução da taxa de inflação dos salários	68
Gráfico 17 - Reconstrução da tendência para as séries de taxa de desemprego e inflação dos salários.....	72
Gráfico 18 - Reconstrução da sazonalidade para as séries de taxa de desemprego e inflação dos salários.....	73
Gráfico 19 - Ruídos resultantes da etapa de reconstrução para as séries de taxa de desemprego e inflação dos salários	73
Gráfico 20 - Taxa de desemprego e NAIRU (MSSA).....	74
Gráfico 21 - Hiato do Desemprego (MSSA).....	74
Gráfico 22 - Evolução da taxa do desemprego com detalhamento para trimestres selecionados	77
Gráfico 23 - Evolução do IPCA acumulado em 3 meses com detalhamento para trimestres selecionados.....	78
Gráfico 24 - Evolução do IPCA acumulado em 4 trimestres com detalhamento para trimestres selecionados.....	78
Gráfico 25 - Hiato UCM e IPCA acumulado no trimestre.....	86
Gráfico 26 - Hiato UCM e IPCA acumulado em 4 trimestres	87

Gráfico 27 - Hiato SSA e IPCA acumulado no trimestre	89
Gráfico 28 - Hiato MSSA e IPCA acumulado no trimestre	89
Gráfico 29 - Hiato SSA e IPCA acumulado em 4 trimestres	90
Gráfico 30 - Hiato HP e IPCA acumulado no trimestre	92
Gráfico 31 - Hiato HP e IPCA acumulado em 4 trimestres	93
Gráfico 32 - Taxa de desemprego e NAIRU SSA 1 autotripla	94
Gráfico 33 - Hiato SSA 1 autotripla e IPCA acumulado no trimestre.....	96
Gráfico 34 - Hiato SSA 1 autotripla e IPCA acumulado em 4 trimestres.....	97
Gráfico B1 - Evolução da média trimestral do IIE-Br	116

LISTA DE QUADROS

Quadro 1 - Exemplos de trabalhos que apresentam estimativas da NAIRU utilizando métodos estatísticos	22
Quadro 2 - Descrição sucinta das séries utilizadas para teste da NAIRU.....	50

LISTA DE ABREVIATURAS E SIGLAS

1D-SSA	One Dimensional Singular Spectrum Analysis
ARCH	Autoregressive Conditional Heteroskedasticity
CPNKA	Curva de Phillips Novo-Keynesiana Aumentada
DIEESE	Departamento Intersindical de Estatística e Estudos Socioeconômicos
FED	Federal Reserve
HMSSA	Horizontal Multivariate Singular Spectrum Analysis
HP	Hodrick Prescott
IBGE	Instituto Brasileiro de Geografia e Estatística
IPCA	Índice de Preços do Consumidor Amplo
IPEA	Instituto de Pesquisa Econômica Aplicada
MQO	Mínimos Quadrados Ordinários
MSSA	Multivariate Singular Spectrum Analysis
NAIRU	NonAccelerating-Inflation Rate of Unemployment
NRU	Natural Rate of Unemployment
PME	Pesquisa Mensal do Emprego
PNAD	Pesquisa Nacional por Amostra de Domicílios
PIB	Produto Interno Bruto
SIDRA	Sistema IBGE de Recuperação Automática
SPF	Survey of Professional Forecasters
SSA	Singular Spectrum Analysis
TND	Taxa Natural de Desemprego
VMSSA	Vertical Multivariate Singular Spectrum Analysis

SUMÁRIO

1	INTRODUÇÃO.....	11
2	REVISÃO DE LITERATURA	15
2.1	O SURGIMENTO DO TERMO “TAXA NATURAL DE DESEMPREGO”	15
2.2	O DEBATE DA TAXA NATURAL DE DESEMPREGO	17
2.3	A NAIRU COMO MEDIDA.....	19
2.4	A NAIRU PARA A ECONOMIA BRASILEIRA	24
3	METODOLOGIA E BASE DE DADOS	29
3.1	O MODELO DE COMPONENTES NÃO OBSERVADOS	30
3.1.1	O espaço de estados e o filtro de Kalman	32
3.2	O FILTRO HODRICK-PRESCOTT	34
3.3	O QUE É O SINGULAR SPECTRUM ANALYSIS?	34
3.4	O MULTIVARIATE SINGULAR SPECTRUM ANALYSIS (MSSA):	38
3.4.1	1º Passo: Incorporação.....	39
3.4.2	2º Passo: Decomposição de Valor Singular	41
3.4.3	3º Passo: Agrupamento	42
3.4.4	4º Passo: Diagonalização Média.....	42
3.4.5	A escolha do tamanho da janela e da quantidade de autotriplas.....	43
3.4.6	Correspondência e separabilidade no MSSA	44
3.4.7	A operacionalização da escolha das autotriplas	47
3.5	BASE DE DADOS	49
4	RESULTADOS	52
4.1	NAIRU ESTIMADA UTILIZANDO O UCM.....	52
4.1.1	Diagnóstico do componente irregular (ϵt).....	55
4.2	NAIRU OBTIDA UTILIZANDO O FILTRO HP	58
4.3	NAIRU MENSURADA A PARTIR DO SSA.....	60

4.3.1	Etapa da decomposição e análise das autotriplas do modelo SSA univariado	60
4.3.2	Etapa de reconstrução e análise dos resultados do modelo SSA univariado.....	65
4.4	NAIRU MENSURADA A PARTIR DO MSSA.....	68
4.4.1	Etapa da decomposição e análise das autotriplas	68
4.4.2	Etapa de reconstrução e análise dos resultados do modelo MSSA	72
5	ANÁLISE DE CONJUNTURA E VERIFICAÇÃO DAS MENSURAÇÕES OBTIDAS	76
5.1	DISCUSSÃO DO COMPORTAMENTO DO DESEMPREGO E DA INFLAÇÃO DE PREÇOS ENTRE O 1T2012 E O 3T2023	76
5.2	AVALIAÇÃO DAS MENSURAÇÕES DA NAIRU	83
6	CONCLUSÃO.....	101
	REFERÊNCIAS.....	104
	APÊNDICE A – TESTES DE RAÍZ UNITÁRIA PARA AS SÉRIES RELACIONADAS À INFLAÇÃO	113
	APÊNDICE B – ANÁLISE DO INDICADOR DE INCERTEZA DA ECONOMIA BRASIL ENTRE O 1T2012 E O 3T2023	116

1 INTRODUÇÃO

O Brasil é um país em desenvolvimento que possui elevadas taxas de desemprego em seu histórico, como os 13,9% no primeiro trimestre de 2017 (IBGE, 2023b), assim, o desemprego se mostra um importante objeto de estudo em diversas áreas de conhecimento, principalmente para as ciências econômicas com o acompanhamento de outras variáveis macroeconômicas, como a inflação. Ademais, o estudo do comportamento do desemprego também se faz útil no estudo das políticas monetária e fiscal, e na formulação de políticas públicas.

O trabalho de Friedman (1968) exemplificou a importância do acompanhamento do desemprego para a política monetária. Tal autor, em sua discussão sobre a efetividade da política monetária dos Estados Unidos, argumentou que existiria um nível para a taxa de desemprego que fosse o ponto de equilíbrio do mercado de trabalho. Esse ponto poderia ser utilizado como meta para a política monetária. Friedman (1968), então, nomeou o nível em questão como a taxa natural de desemprego.

Além de introduzir o conceito da taxa natural, a discussão de Friedman (1968) abriu caminho para que trabalhos posteriores pesquisassem, e aprofundassem, o conceito da taxa natural de desemprego. Com isso, a literatura evoluiu ao ponto de discutir não somente uma taxa de equilíbrio do desemprego, mas também uma taxa de desemprego que não pressionasse a inflação – a taxa de desemprego não acelerante da inflação, nomeada conforme sua sigla em inglês: NAIRU (Gordon, 1997).

Agora, o conceito da NAIRU estaria apoiado não somente na ideia de Friedman (1968), mas também no *tradeoff* entre inflação e desemprego introduzida na literatura por Phillips (1958). Dessa forma, o comportamento entre a NAIRU e a taxa de desemprego seria indicativo de aumento ou redução da inflação, isso porque se a NAIRU estiver acima (abaixo) do desemprego corrente existe uma pressão para o (a) aumento (redução) da inflação. Contudo, por ser uma variável não observável, a mensuração da NAIRU se mostra um desafio empírico.

Uma solução encontrada, e que pode ser observada nos trabalhos de Grant (2002) e de Logeay e Tober (2006), é definir a NAIRU como a tendência da variável do desemprego. Para obter o componente de tendência, tais trabalhos se utilizam de algum filtro estatístico, como o filtro de Kalman, para decompor a variável do desemprego. Assim, é possível apresentar estimativas tempo-variante da NAIRU que podem ser úteis em outros objetos de estudo, como na previsão de inflação.

Na literatura, considerando especificamente a economia brasileira, também existem trabalhos que objetivaram a estimação da NAIRU, tais como, Palma e Ferreira (2017) e Nobrega, Besarria e Oliveira (2020). Para compor seu modelo de componentes não observáveis, a série de desemprego utilizada por Palma e Ferreira (2017) possuía periodicidade mensal e foi retirada da Pesquisa Mensal do Emprego (PME) - se estendendo de março de 2002 a outubro de 2015. Já Nobrega, Besarria e Oliveira (2020), a partir de um modelo de função de transferência, utilizaram uma série do desemprego trimestral que se estendeu entre o primeiro trimestre de 2000 até o quarto trimestre de 2016 – retirada da pesquisa do Departamento Intersindical de Estatística e Estudos Socioeconômicos (DIEESE) (DIEESE, 2023).

No entanto, tanto o trabalho de Palma e Ferreira (2017) quanto o trabalho de Nobrega, Besarria e Oliveira (2020) possuem limitações em relação aos dados empregados. A PME utilizada por Palma e Ferreira (2017) foi descontinuada pelo IBGE em março de 2016 (IBGE, 2023c) – sendo os dados do desemprego divulgados atualmente através da PNAD Contínua. Já os dados de desemprego da DIEESE, fonte de Nobrega, Besarria e Oliveira (2020), foram descontinuados e retomados em diferentes períodos, além de atualmente possuir a série de desemprego atualizada somente para o Distrito Federal, a Área Metropolitana de Brasília e para a Periferia Metropolitana de Brasília (DIEESE, 2023).

Outra limitação que ocorre no trabalho de Palma e Ferreira (2017) diz respeito aos resultados obtidos. Em determinados períodos da amostra, a NAIRU mensurada não apresentou uma diferença estatisticamente significativa frente ao desemprego. Com relação ao trabalho de Nobrega, Besarria e Oliveira (2020), a sobre identificação do modelo que estimou a NAIRU e o emprego de apenas um teste para a variável não observável são fatores que podem ser citados.

Portanto, no contexto da busca pela NAIRU como variável não observável do desemprego corrente, da utilidade da variável como ferramenta de análise na macroeconomia e na formulação de políticas públicas, o objetivo deste trabalho é apresentar uma mensuração da NAIRU para o Brasil que se estende do primeiro trimestre de 2012 até o terceiro trimestre de 2023 (47 observações) utilizando os dados da PNAD Contínua.

O trabalho, então, contribui para a literatura e se destaca com relação aos trabalhos de Palma e Ferreira (2017) e Nobrega, Besarria e Oliveira (2020), em três pontos relevantes. O primeiro diz respeito à aplicação de três métodos diferentes para a mensuração da NAIRU, com a verificação se as medidas são condizentes com o *tradeoff* da Curva de Phillips. O segundo diz respeito a mensuração de uma NAIRU brasileira, em que utiliza os dados trimestrais da PNAD

Contínua, exibindo que já é possível obter uma mensuração recorrendo aos dados da pesquisa que substituiu a PME na divulgação da taxa de desemprego. Por fim, o terceiro ponto refere-se à aplicação de um método não paramétrico, o *Singular Spectrum Analysis* (SSA), promissor no emprego de séries econômicas - visto que comporta séries curtas, séries com tendências complexas e não exige modificação prévia dessas para seu uso.

Conforme a proposta do trabalho, quatro modelos foram utilizados para mensurar a NAIRU brasileira: componentes não observados, filtro HP, *Singular Spectrum Analysis* (SSA) e *Multivariate Singular Spectrum Analysis* (MSSA). A escolha dos dois primeiros métodos foi baseada no uso deles em trabalhos que buscaram a NAIRU como tendência da variável do desemprego, e foram modelos univariados. Quanto aos dois últimos, o SSA também é um modelo univariado e o MSSA é multivariado – ambos não paramétricos.

De acordo com Golyandina *et al.* (2015), o SSA é uma técnica capaz de realizar a decomposição de uma, ou mais, séries temporais em componentes de interesse: tendência e sazonalidade, além de ser capaz de realizar também a filtragem dos ruídos dessas séries. Tanto o SSA quanto o MSSA já possuem aplicações para séries econômicas e se mostram como opções viáveis para a utilização em séries temporais curtas (Hassani e Thomakos, 2010).

Os quatro modelos foram capazes de extrair a tendência da série de desemprego e, portanto, fornecer uma mensuração da NAIRU. Em suma, para todo o período amostral, os modelos registraram uma NAIRU em torno de 10,5% alternando ciclicamente com o desemprego e resultando em um hiato periódico, com exceção do filtro HP.

Como forma de estabelecer uma comparação entre os modelos utilizados e verificar a adequação dos resultados aos pressupostos teóricos, utilizou-se a análise gráfica do comportamento do hiato do desemprego e da inflação para todo o período da amostra, junto com o teste proposto em Portugal e Madalozzo (2000). As séries de inflação utilizadas nessa seção de avaliação foram incorporadas em dois horizontes: acumulado no trimestre e acumulado em 4 trimestres.

Os resultados indicaram que as medidas utilizadas acompanharam consistentemente a inflação no período estudado, isto é, corresponderam ao pressuposto teórico da relação entre taxa de desemprego, NAIRU e inflação de preços. Ademais, foi observado que a característica da tendência – se ela evolui próxima à série de desemprego, ou se é suavizada – interfere na qualidade da ferramenta em acompanhar o IPCA. Assim, as variáveis que evoluíram próximas à série de desemprego foram capazes de indicar o comportamento do IPCA acumulado no

trimestre, enquanto as NAIRUs suavizadas corresponderam melhor ao comportamento do IPCA acumulado em 4 trimestres. Finalmente, o modelo SSA univariado destacou-se por conseguir mensurar a NAIRU adequada para cada um desses dois horizontes da inflação.

Além deste capítulo introdutório, esta dissertação está dividida em mais outros quatro capítulos. O capítulo 2 trata da revisão de literatura, internacional e nacional, a respeito da taxa natural de desemprego e da NAIRU. O capítulo 3 apresenta a metodologia dos modelos utilizados e explicita a base de dados utilizada. O capítulo 4 expõe os resultados das mensurações da NAIRU de cada modelo. O capítulo 5 discute a conjuntura das variáveis de taxa de desemprego e inflação para o período amostral do trabalho, realiza a análise gráfica e os testes das mensurações obtidas no capítulo 4. Por fim, o capítulo 6 apresenta a conclusão desta dissertação.

2 REVISÃO DE LITERATURA

O presente capítulo está dividido em quatro partes e objetiva apresentar uma revisão de literatura a respeito da taxa natural do desemprego não acelerada pela inflação como variável não observável da taxa de desemprego. É importante ressaltar que tanto a taxa natural de desemprego, quanto a taxa natural de desemprego não acelerada pela inflação são referidas ao longo do trabalho por suas siglas em inglês, respectivamente, NRU (*Natural Rate of Unemployment*) e NAIRU (*NonAccelerating-Inflation Rate of Unemployment*).

Portanto, a seção 2.1 discute o surgimento do conceito de taxa natural de desemprego na literatura; a seção 2.2 apresenta o debate das definições, diferenças e/ou similaridades entre as taxas e a evolução de seus conceitos, a seção 2.3 trata dos meios empíricos de elaboração da NAIRU e, finalmente, a seção 2.4 é dedicada para apresentar trabalhos brasileiros que buscaram uma estimativa da NAIRU nacional.

2.1 O SURGIMENTO DO TERMO “TAXA NATURAL DE DESEMPREGO”

A cunhagem do termo Taxa Natural de Desemprego (TND) – em inglês: *Natural Rate of Unemployment* (NRU) - foi atribuída a Milton Friedman após seus discursos e trabalhos na década de 1960 (Salop, 1979; Blanchard e Katz, 1997; Da Silva, 2011; Capehart, 2019). Segundo Da Silva (2011), apesar de Friedman já comentar em alguns discursos ao longo da década de 1960, como no discurso de presidência de 1967 para a American Economic Association, o termo surgiu inicialmente em sua discussão de 1968 sobre a efetividade da política monetária (Friedman, 1968). Contudo, independentemente do batismo do termo ser atribuído a Friedman, outros autores já reuniam debates semelhantes na literatura, como no trabalho de Wicksell (1936) com sua discussão a respeito da taxa de juros natural¹, e Phelps (1967) que abordou um equilíbrio do nível de emprego (Da Silva, 2011).

De acordo com Friedman (1968), a taxa natural de desemprego seria o nível de desemprego garantido pelo equilíbrio Walrasiano, de forma que essa taxa considere características estruturais do mercado de trabalho e do mercado de bens². Tais características afetam o nível de trabalho e englobam, por exemplo, as imperfeições do mercado de trabalho,

¹ A ideia de Wicksell (1936) a respeito de uma taxa de juros natural foi citada por Friedman (1968) ao tratar da Taxa Natural de Desemprego.

² O termo “mercado de bens” foi utilizado como tradução do termo: *commodities market*.

as questões friccionais³ e o comportamento estocástico das forças de demanda e oferta desses mercados.

Apesar do trabalho de Friedman (1968) debater sobre uma taxa natural, no ano anterior a obra de Phelps (1967) propôs uma discussão sobre um controle fiscal da demanda agregada, empregando um modelo macroeconômico dinâmico que permite a derivação de um ponto ótimo do emprego agregado. Em seu modelo, o autor considerou a aplicação de uma Curva de Phillips, incorporando no modelo o *trade-off* entre inflação e desemprego – ponto que já havia sido abordado por Phillips (1958). Portanto, dada a incorporação da Curva de Phillips no modelo, o nível do desemprego se adapta até que o equilíbrio na curva seja atingido (inflação atual correspondendo à expectativa de inflação), em que o nível de desemprego de equilíbrio também pode ser chamado de taxa natural de desemprego (Da Silva, 2011). Tal equilíbrio pode ser referido como taxa natural de desemprego porque Phelps (1967) já argumentava que um estímulo da demanda agregada não teria efeito de longo prazo no nível de emprego – apenas geraria um maior nível de inflação.

Além das contribuições de Phelps (1967) e Friedman (1968), Da Silva (2011) também destacou a contribuição do trabalho de Lucas (1972) na expansão do conceito de taxa natural de desemprego na literatura. Isso porque a aplicação de equilíbrio geral que Lucas (1972) efetuou incorporando expectativas racionais, ao invés de adaptativas, resultou em um modelo para a hipótese da Taxa Natural de Desemprego. Com isso, Lucas (1972) contribuiu também para a formalização do termo na literatura, ampliando o escopo da discussão como ressalta Da Silva (2011).

Para além da ampliação do estudo da taxa natural de desemprego proporcionada pelo trabalho de Lucas (1972), o trabalho de Modigliani e Papademos (1975)⁴ também foi responsável por estender o debate em torno da Taxa Natural de Desemprego ao diferenciar o que foi discutido por Friedman (1968), tratando, então, de uma taxa de desemprego que fosse consistente com a inflação. O objetivo do trabalho de Modigliani e Papademos (1975) consistiu em propor estratégias para a política monetária dos Estados Unidos para os anos de 1976 e 1977. Assim sendo, os autores argumentaram que para reduzir a taxa de inflação o desemprego deveria ficar abaixo de sua taxa natural durante o período proposto. A questão é que Modigliani

³ No que diz respeito a questões friccionais, Friedman (1968) citou custos de informação e de mobilidade para se preencher as vagas no mercado de trabalho.

⁴ Caphart (2019) associou à Modigliani e Papademos (1975) o ponto de partida para a definição da taxa de desemprego como uma taxa natural não inflacionária, o que posteriormente ficaria conhecida como NAIRU, termo que se popularizou nas discussões posteriores acerca da Taxa Natural de Desemprego.

e Papademos (1975) classificaram a taxa natural de desemprego como a taxa de desemprego não-inflacionária – utilizando o acrônimo em inglês NIRU.

De acordo com Capehart (2019), o termo NIRU evoluiu para o que passou a ser chamado na literatura de NAIRU, ou seja, ao invés de uma taxa de desemprego não-inflacionária, o debate evoluiu para a ideia de uma taxa de desemprego a tal nível que não acelerasse a inflação. Contudo, as contribuições citadas de Phelps (1967); Friedman (1968); Lucas (1972); e Modigliani e Papademos (1975) não resultaram em um consenso de como a taxa natural poderia ser definida, e sim, como já ressaltado, em uma ampliação no debate do que é a TND (ou a NAIRU) e como pode ser definida.

2.2 O DEBATE DA TAXA NATURAL DE DESEMPREGO

Após o surgimento do conceito de uma taxa natural para o desemprego, discussões teóricas e empíricas se voltaram para verificar a existência dessa taxa ou de uma taxa natural de desemprego consistente com o crescimento da inflação, permitindo a expansão da discussão iniciada, principalmente, por Friedman (1968) e Phelps (1967). Em sua maioria, tais trabalhos tiveram como objeto de estudo a economia dos Estados Unidos (Salemi, 1999; Claar, 2006; King e Morley, 2007; Mohebi e Komijani, 2018) e a economia europeia (Logeay e Tober, 2006; Heimberger, Kapeller e Schutz, 2017; Bell e Blanchflower, 2018).

Salop (1979)⁵ abordou um modelo micro fundamentado na qual o ponto de equilíbrio do emprego corresponde à taxa natural – semelhante à discussão feita por Phelps (1967), ademais, o autor foi de encontro à proposta de Friedman (1968) de que a NRU seria uma taxa de equilíbrio que correspondesse com a fricção e a informação imperfeita presentes no mercado de trabalho. Em suma, a contribuição do modelo de Salop (1979) residiu em permitir um mercado de trabalho a parte⁶ para trabalhadores experientes, já pelo lado da firma contratante, ela estaria sujeita à informação imperfeita para precificação dos salários de seus trabalhadores. O modelo, portanto, proporcionou um resultado em que nenhum dos lados, trabalhadores ou firmas, conseguiriam atingir um equilíbrio perfeito, visto que ambos estariam sujeitos às imperfeições do mercado⁷. Com isso, Salop (1979) incorporou os efeitos dos desempregos

⁵ Para mais detalhes do modelo desenvolvido, ver Salop (1979).

⁶ Trabalhadores mais experientes, poderiam ofertar sua mão de obra a níveis salariais maiores do que trabalhadores entrando no mercado de trabalho.

⁷ Segundo o autor, os trabalhadores, principalmente os mais experientes, também podem sair de seus postos de trabalho para procurar outros empregos, contudo, farão isso apenas em períodos de baixo nível de desemprego.

voluntário e involuntário em sua modelagem da NRU, realçando o fato de que o desemprego voluntário não poderia ser extinguido através de política fiscal ou monetária.

Já Gordon (1997) ressaltou que a ideia de Friedman da taxa natural de desemprego, com o passar dos anos e com a evolução da discussão na literatura, ficou conhecida por NAIRU. Isso porque, se existisse um ponto único que representasse a NAIRU, o *tradeoff* da Curva de Phillips nesse ponto seria vertical.

Portanto, a NAIRU pode ser definida como a taxa de desemprego que é consistente com o crescimento inflacionário, assim sendo, quando o desemprego corrente (observável) está abaixo da NAIRU deve existir uma pressão para aumento da inflação, e quando o desemprego corrente está acima da NAIRU deve existir uma pressão para a queda da inflação (Stiglitz, 1997; Gordon, 1997; Salemi, 1999; Grant, 2002).

Grant (2002) foi além e enfatizou a diferença entre NRU e a NAIRU. A NRU, portanto, refletiria as imperfeições do mercado de trabalho enquanto a NAIRU seria, majoritariamente, uma relação macroeconômica que espelhasse as relações de oferta e demanda da economia, além da condução da política monetária.

Contudo, é necessário ressaltar que essa visão não é unanimemente aceita na literatura. Para Ball e Mankiw (2002) (visão também assumida por Bell e Blanchflower, 2018) a NRU e a NAIRU são medidas próximas – tratando a NRU não como um equilíbrio micro fundamentado, mas sim como um nível de desemprego consistente com uma inflação estável. Já para Blanchard e Katz (1997), e King e Morley (2007), a taxa natural de desemprego é a taxa de equilíbrio de longo prazo do mercado de trabalho, em que os autores seguem uma definição baseada nos trabalhos de Friedman e Phelps. Em seus respectivos trabalhos, os autores classificaram a NRU não como uma constante, mas sim como uma variável tempo-variante, porém, sem abordar uma igualdade entre NRU e NAIRU – apesar de tratarem a discussão do *tradeoff* entre inflação e desemprego.

A diversidade de definições já era ressaltada por Rogerson (1997), que tratou em seu trabalho sobre a ambiguidade da definição dada por Friedman em seu discurso e trabalho de 1968. Conforme o autor, no final da década de 1990 a NRU era definida de diversas maneiras, podendo ser definida como o nível de desemprego médio, a taxa de desemprego eficiente, a menor taxa de desemprego que seja sustentável, e até mesmo como o componente de tendência da variável de desemprego retirado utilizando o Filtro HP.

Vale ressaltar que a NAIRU possui utilidade não somente para acompanhar o comportamento da inflação, mas também para a sua previsão (Grant, 2002; Claar, 2006). Ademais, outros autores utilizaram a NAIRU para investigar a relação entre os componentes cíclicos do produto e do desemprego, com o objetivo de investigar a relação proposta na Lei de Okun (Grant, 2002; Doménech e Gómez, 2006; Jašová, Kadeřábková, Čermáková, 2017). A Lei de Okun ficou conhecida a partir do trabalho de Okun (1962), na qual o autor discute que a taxa natural de desemprego seria uma taxa que fosse consistente com um nível de desempenho econômico pleno e sustentável, associando o comportamento e o nível de desemprego com o produto.

Capchart (2019) realizou uma revisão das edições trimestrais da *Survey of Professional Forecasters* (SPF). A SPF é uma pesquisa trimestral do *Federal Reserve (FED)* que, a partir do 3º trimestre 1996 (3T1996) e em todos os 3º trimestres dos anos seguintes, perguntou para os profissionais pesquisados se eles utilizavam a NRU/NAIRU em suas previsões. Capchart (2019) identificou que, entre 1996 e 2016, em média, 92% dos painelistas pesquisados responderam que utilizam o conceito de NRU/NAIRU de alguma forma em suas previsões, enquanto 46% realizaram uma estimação própria da variável não observável. Para o autor, a NRU e a NAIRU são sinônimos.

Por fim, o presente trabalho considera a NRU e a NAIRU como definições diferentes, utilizando as definições de Gordon (1997), Salemi (1999) e Grant (2002) para a NAIRU. Isto posto, este trabalho busca então uma medida para a NAIRU enquanto variável não observável.

2.3 A NAIRU COMO MEDIDA

Tendo em vista que a NAIRU é uma variável não observável, se faz necessário investigar as propostas de estimação da variável na literatura. Jašová, Kadeřábková e Čermáková (2017) afirmaram que as estimações para a NAIRU são feitas utilizando métodos estatísticos (Filtro HP, Filtro de Kalman etc.). Já Lang, Setterfield e Shikaki (2020), criticaram a obtenção da NAIRU através de métodos estatísticos tanto em forma – em como os filtros são utilizados – quanto na qualidade dos resultados. No entanto, os autores também ressaltaram que os filtros podem apresentar resultados robustos, especialmente os obtidos utilizando o filtro de Kalman.

De acordo com Grant (2002); Claar (2006); Logeay e Tober (2006); Doménech e Gómez (2006); Constantinescu e Nguyen (2018); a variável observada do desemprego (u_t) pode ser definida como:

$$u_t = u_t^N + \hat{u}_t \quad (2.1)$$

Logo, o desemprego (u_t) é estabelecido como a soma entre o seu componente de tendência (u_t^N) – que corresponde à NAIRU, e seu componente cíclico (\hat{u}_t).

Grant (2002) explorou a relação estabelecida pela Lei de Okun entre produto e desemprego para encontrar uma estimativa da NAIRU utilizando dados dos Estados Unidos do 1T1959 até 4T1998. No trabalho o autor decompôs o desemprego utilizando o Filtro HP e o Filtro de Beveridge-Nelson, além dos modelos de tendência linear e tendência com quebra estrutural – ambos estimados utilizando o filtro de Kalman - para robustez⁸. Com isso, foi possível obter uma NAIRU tempo variante que fosse consistente com as medidas dos ciclos de negócios e útil para a previsão da inflação.

Já Logeay e Tober (2006), com o objetivo de investigar o efeito de histerese⁹ da NAIRU e, conseqüentemente, da taxa de desemprego para países da zona do euro, também empregaram o filtro de Kalman para obter a NAIRU. Para tal, os autores modelaram a NAIRU como uma tendência não estacionária e a estimaram simultaneamente com uma Curva de Phillips – especificando a relação entre inflação e o hiato do desemprego. Os dados são trimestrais para a união europeia e se estenderam de 1970 até 2002¹⁰. As estimativas da NAIRU foram estatisticamente significantes, o que indicou a presença de histerese no comportamento da taxa de desemprego em determinados países da União Europeia.

No que diz respeito ao trabalho de Claar (2006), o autor – a partir de dados anuais para os Estados Unidos de 1947 a 1998 – utilizou três abordagens para a estimação da NAIRU: Filtro HP, Filtro de Kalman e determinantes estruturais¹¹. Com o objetivo de verificar se existem ganhos no poder de previsão da inflação empregando a NAIRU ao invés da NRU, o autor utilizou as estimativas obtidas para realizar a previsão da inflação – seguindo o que foi

⁸ Grant (2002) também apresentou resultados para diferentes valores do parâmetro λ do Filtro HP. A tendência com quebra estrutural se refere à tendência linear simples com quebra estrutural de Perron.

⁹ Conforme Logeay e Tober (2006), histerese é um termo emprestado da física e corresponde à condição de que o equilíbrio é caminho-dependente. Logeay e Tober (2006) realizam uma revisão de literatura em torno da investigação da histerese ao decorrer dos anos, além de elencar possíveis causas para o fenômeno.

¹⁰ Para algumas variáveis, os dados vão até 2003.

¹¹ Ao especificar a abordagem de determinantes estruturais, Claar (2006) reporta que o resultado é uma NRU, e não uma NAIRU. Logo, a NAIRU seria obtida apenas utilizando os métodos estatísticos.

apresentado por Grant (2002). Contudo, ao serem utilizadas para a previsão, as duas “NAIRUs” - obtidas através dos filtros estatísticos - e a NRU - obtida através do modelo estrutural - apresentaram, estatisticamente, o mesmo poder de previsão da inflação americana.

Doménech e Gómez (2006) formularam um modelo de componentes não observados composto por quatro variáveis: log do PIB real; taxa de desemprego; inflação; nível de investimento – sendo os dados para os Estados Unidos de 1T1946 até 1T2003. Os autores realizaram a estimação do modelo utilizando o filtro de Kalman e apresentaram valores para NAIRU – tendo a decomposição da variável de desemprego como base, para o núcleo de inflação e para o componente de tendência das outras duas variáveis – estes que foram úteis para calcular os hiatos utilizados ao decorrer da discussão.

Assim sendo, com os componentes de tendência, os autores verificaram a correlação negativa entre o hiato do desemprego e do produto e argumentaram a favor da utilidade de suas estimações para esses dois componentes (Doménech e Gomez, 2006). A metodologia de Doménech e Gómez (2006) também foi utilizada por Rodríguez (2010) para o caso do Peru, contudo, apenas a inflação apresentou resultados consistentes conforme os fatos estilizados. Segundo Rodríguez (2010), a qualidade de construção das variáveis selecionadas para o modelo poderia estar comprometendo os resultados.

Tendo em vista tal potencial da aplicação dos filtros estatísticos para realizar a decomposição das variáveis em componentes de tendência e sazonalidade, o Quadro 1 apresenta uma síntese de outros trabalhos referenciados.

Quadro 1 - Exemplos de trabalhos que apresentam estimativas da NAIRU utilizando métodos estatísticos

Autor(es)	Data de publicação	Principal método utilizado	Escopo do trabalho
Basistha e Nelson	2007	Filtro de Kalman (também são utilizados outros métodos estatísticos para comparação, como o Filtro HP)	A partir de dados dos Estados Unidos (1T1960 – 1T2003), o objetivo do trabalho é estimar o hiato do produto a partir de uma abordagem da Curva de Phillips Nova Keynesiana.
Napolitano e Montagnoli	2010	Filtro de Kalman (Modelo de Componentes não Observáveis)	Investigar se a política monetária europeia é responsável pelos hiatos no desemprego e se a taxa de juros é transmitida assimetricamente pelos países europeus. Dados para França, Alemanha e Itália (1T1972 – 1T2007).
Marjanovic, Maksimovic e Stanisic	2015	Filtro de Kalman	Analisar a hipótese de histerese do desemprego para cinco países selecionados da Europa Central (República Tcheca; Romênia, Polônia, Eslovênia; Bulgária) utilizando dados trimestrais de 2000 a 2012.
Heimberger, Kapeller e Schutz	2017	Filtro de Kalman.	Analisar os determinantes da estimação da NAIRU que é realizada pela Comissão Europeia. Os dados envolvem 14 países europeus e se estendem de 1985 até 2012.
Constantinescu e Nguyen	2018	Estimação Bayesiana para o modelo; variáveis não observáveis extraídas via Filtro de Kalman	Utilizando dados para a Lituânia (1T1998 – 3T2016), investigar a importância do desemprego frente ao crédito para determinar o potencial produtivo da economia.

Fonte: Elaboração própria.

Ball e Mankiw (2002) indagaram o conceito da NAIRU com o objetivo de analisar a mudança da NAIRU para os Estados Unidos ao longo dos anos¹². Para tal, os autores propuseram uma alternativa à estimação do componente não observável do desemprego utilizando uma Curva de Phillips Aceleracionista (equação 2.2) que incorpora o hiato do desemprego¹³:

$$\Delta\pi_t = \alpha u_t^N - \alpha u_t + v_t \quad (2.2)$$

¹² Para tal, os autores utilizam dados anuais para os Estados Unidos entre 1960 e 2000.

¹³ A equação 2.2 foi exposta de forma reordenada conforme Ball e Mankiw (2002) apresentaram, na qual esta parte da seguinte equação: $\pi_t = \pi_t^e - \alpha(U_t - U_t^{NAIRU}) + v_t$, em que π_t^e representa a expectativa de inflação (sendo $\pi_t^e = \pi_{t-1}$);

Onde π_t representa a inflação (nesse caso sendo exposta em primeira diferença); u_t a taxa de desemprego; u_t^N a NAIRU; e v_t seriam os choques de oferta que representariam mudanças no *trade-off* entre inflação e desemprego. A estimação da equação 2.2 bastaria para obter uma medida para uma NAIRU constante, porém, dadas as críticas acerca da NAIRU constante¹⁴, Ball e Mankiw (2002) reorganizam a equação 2.2 em:

$$u_t^N + \frac{v_t}{\alpha} = u_t + \frac{\Delta\pi_t}{\alpha} \quad (2.3)$$

Tendo em vista que o α pode ser obtido via estimação do Método Generalizado de Momentos (com sigla GMM em inglês) da equação 2.2; que a inflação e o desemprego são variáveis observáveis; e a relação de igualdade da equação 2.3, é possível conhecer o lado esquerdo da equação 2.3. Portanto, para encontrar uma estimativa tempo-variante da NAIRU, Ball e Mankiw (2002) optaram por aplicar o Filtro HP no lado observável da equação – obtendo uma estimativa da NAIRU a partir da decomposição da equação (2.3) em componentes cíclicos e de tendência.

A metodologia de Ball e Mankiw (2002) também foi utilizada por Loría, Valdez e Tirado (2019) e por Andrei (2014). Loría, Valdéz e Tirado (2019) se basearam na metodologia para obter uma estimação tempo variante da NAIRU para o México a partir de dados do 1T2002 até o 2T2018. O objetivo dos autores era investigar se a metodologia proposta por Ball e Mankiw (2002) seria mais eficiente do que a aplicação direta do Filtro HP¹⁵. Já Andrei (2014) incorporou em seu trabalho a estimação GMM dos autores da Curva de Phillips Aceleracionista, contudo, ao invés do Filtro HP, foi feito o uso do Filtro de Kalman para obter as variáveis não observáveis.

Por fim, e com base em Grant (2002); Claar (2006); Logeay e Tober (2006); Doménech e Gómez (2006); Constantinescu e Nguyen (2018), a NAIRU como relação macroeconômica (u_t^N) é obtida através da extração do componente de tendência da variável desemprego corrente, sendo a abordagem adotada no presente trabalho. Ademais, mesmo que não tenha sido

¹⁴ Conforme Ball e Mankiw (2002), uma fonte de críticas para a NAIRU constante é a sua aparente queda no final dos anos 90 nos Estados Unidos. Com isso, a NAIRU constante cedeu espaço para estimações de uma NAIRU tempo-variante.

¹⁵ É importante ressaltar que existem diversas críticas metodológicas em torno da utilização do Filtro HP para a decomposição de séries temporais. Hamilton (2018), por exemplo, argumenta que o Filtro HP produziria séries que apresentassem relações espúrias - na qual esses comportamentos espúrios destoariam os valores da série filtrada; que o valor $\lambda = 1600$ não seria o mais adequado para a filtragem em séries trimestrais, dentre outros pontos.

escolhida para as estimações desta dissertação, a exposição da metodologia de Ball e Mankiw (2002) se fez necessária por terem proposto uma alternativa à obtenção da NAIRU que se tornou influente na literatura.

2.4 A NAIRU PARA A ECONOMIA BRASILEIRA

Com a maioria dos trabalhos que buscam a estimativa da NAIRU utilizando como base as economias dos Estados Unidos e União Europeia, é necessário discutir como a literatura brasileira estudou – e está estudando - a estimação da variável para a economia nacional.

Portugal e Madalozzo (2000), a partir de dados trimestrais entre 1982 e 1997, estimaram a NAIRU utilizando dois modelos diferentes: um modelo de função de transferência e um modelo de decomposição da variável de desemprego. Para o primeiro modelo, uma Curva de Phillips Aceleracionista foi empregada como base para a obtenção da NAIRU, tendo como variável exógena a diferença da inflação no período t com a expectativa de inflação no mesmo período¹⁶. Nesta abordagem, a NAIRU foi determinada como o ponto onde a taxa de inflação esperada se iguala à taxa de inflação do período, sendo calculada após a obtenção dos coeficientes. Já no segundo modelo proposto, os autores realizaram a decomposição¹⁷ da variável de desemprego em quatro componentes: tendência, sazonalidade, ciclo e irregular, sendo a NAIRU retirada a partir do componente de tendência da série. Dentre os dois modelos, Portugal e Madalozzo (2000) consideraram que somente o modelo de função de transferência apresentou um resultado consistente¹⁸ com o comportamento da inflação e desemprego da época.

No que diz respeito a Lima (2003), a partir de representação da relação entre inflação e desemprego: $\Delta\pi_t = \mu_t + \sum_{s=1}^3 \beta_{st}(u_{t-s} - u_{t-s}^N) + \mathbf{Z}_t\boldsymbol{\gamma}_t + \epsilon_t$ ¹⁹, o autor também aplicou dois modelos distintos para a estimação da NAIRU, foram estes: um modelo de espaço-estado que permite resíduos ARCH (modelo TVP) estimado via filtro de Kalman; e um modelo de espaço-

¹⁶ O desemprego foi tido como variável endógena do modelo. Para mais detalhes da abordagem, ver Portugal e Madalozzo (2000).

¹⁷ Conforme Portugal e Madalozzo (2000), a decomposição utilizou máxima verossimilhança para a estimação da variância dos resíduos e Filtro de Kalman para o vetor de estados.

¹⁸ Como os autores utilizam duas séries diferentes para o desemprego, uma do IBGE e outra da Dieese, a NAIRU estimada foi de 5,66% para os dados do IBGE e 10,30% para os dados da Dieese. Portugal e Madalozzo (2000) argumentaram que, mesmo tendo uma diferença nesta NAIRU constante conforme os dados dos institutos, estes continuariam consistentes com a relação dos comportamentos do hiato do desemprego com a inflação.

¹⁹ Em que π_t representa a inflação; u_t é a variável de desemprego; u_t^N é a NAIRU e \mathbf{Z}_t é um vetor de variáveis de controle.

estado com regime de mudança markoviana estimado via filtro de Kim²⁰ (modelo MSR). Empregando uma série que vai do 1T1982 até 4T2001 (80 observações), o autor constatou a NAIRU dentro da margem de erro dos modelos, sendo assim, não foi possível rejeitar a hipótese de que a NAIRU encontrada seja estatisticamente diferente do desemprego observado.

Já Silva Filho (2008) estimou tanto uma NAIRU constante quanto uma NAIRU tempo-variante a partir de uma Curva de Phillips vertical com expectativas seguindo um passeio aleatório. Para a NAIRU constante, a Curva de Phillips foi estimada via Mínimos Quadrados Ordinários (MQO) – sendo a NAIRU calculada como a razão do termo constante da soma dos coeficientes da variável de desemprego. No que diz respeito a NAIRU tempo-variante, o autor optou por um modelo de componentes não observados estimado via filtro de Kalman. Baseado em uma amostra entre 2T1996 até o 4T2006, o autor, para ambas as estimativas, encontrou uma NAIRU entre 7,4% e 8,5% - o que apontou para uma NAIRU constante.

Os últimos três trabalhos expostos utilizaram dados que englobam desde a década de 1980 até o início dos anos 2000. Diante disso, as séries dos autores passaram por planos econômicos que visaram estabilizar a inflação no país e/ou atravessaram crises externas, como as crises de México e Rússia nos anos 1990 (Portugal e Madalozzo, 2000; Lima, 2003). De acordo com Dutra (2011), esses períodos contribuíram para a distorção e baixa confiabilidade dos resultados expostos. Contudo, tais trabalhos auxiliaram a pavimentar um caminho para que novos modelos (ou os já propostos) fossem aplicados (replicados) com dados mais recentes.

Um exemplo de trabalho que realizou essa atualização é o de Oliveira, Portugal e Abrita (2016). Os autores partiram da metodologia proposta por Portugal e Madalozzo (2000) de utilizar uma função de transferência para estimar a Curva de Phillips Aceleracionista, contudo, para a filtragem da série de desemprego, os autores optaram por seguir a metodologia de Ball e Mankiw (2002) – escolha diferente do filtro de Kalman utilizado por Portugal e Madalozzo (2000). Assim sendo, com base em uma amostra que se estende do 1T2000 até o 2T2013, foi verificado que a NAIRU estimada a partir de 2004 permaneceu constantemente acima da taxa de desemprego observada. Segundo Oliveira, Portugal e Abrita (2016), como as séries de desemprego e inflação apresentaram tendências semelhantes após os anos 2000, não foi possível concluir que ocorreu uma aceleração da inflação brasileira ao longo dos anos que abrangem a amostra.

²⁰ O Filtro de Kim utilizado pelos autores é baseado no livro de Kim e Nelson (1999).

Já Palma e Ferreira (2017), sob o objetivo de estimar uma NAIRU tempo-variante, optaram por um modelo bivariado de componentes não observados estimado por MCMC – método bayesiano – alimentado com dados mensais de março de 2002 a outubro de 2015. Neste modelo a Curva de Phillips é especificada utilizando a diferença da inflação e do desemprego para suas respectivas tendências (equação 2.4), e, para além da Curva Phillips, os autores também especificam o comportamento das variáveis não observáveis²¹.

$$(\pi_t - \tau_t^\pi) = \rho_t^\pi(\pi_{t-1} - \tau_{t-1}^\pi) + \lambda_t(u_t - \tau_t^u) + \varepsilon_t^\pi \quad (2.4)$$

Em que π_t representa a inflação; u_t representa o desemprego; e τ representa o respectivo componente de tendências das variáveis.

Tendo em vista que a NAIRU foi modelada como a tendência da variável de desemprego (τ_t^u), Palma e Ferreira (2017) apresentaram uma NAIRU média de 7,48% para o período da amostra, sendo esta de 8,13% até 2003 e de 6,9% de 2010 a 2015. Ademais, o hiato do desemprego calculado a partir da NAIRU obtida foi consistente com a desaceleração inflacionária que ocorreu de 2002 a 2008 e com a aceleração apresentada a partir de 2012. No entanto, é preciso ressaltar que, entre 2008 e o final de 2011, e depois para o ano de 2015, a NAIRU não pôde ser considerada estatisticamente diferente do desemprego observável.

Para além da abordagem de estimação da NAIRU incorporando a discussão da inflação baseada na cesta de bens através da Curva de Phillips, outros autores optaram por adentrar no debate da inflação dos salários - este é o caso dos trabalhos de Fernando dos Santos (2014); e Nobrega, Besarria e Oliveira (2020).

Fernando dos Santos (2014) propôs uma análise do comportamento do desemprego brasileiro para os anos de 1998 até 2012. Com essa finalidade, o autor complementou sua discussão²² com uma estimação da NAIRU realizada a partir de um modelo de componentes não observáveis estimado via filtro de Kalman. O modelo do autor foi composto por cinco equações, sendo duas as principais (equações 2.5 e 2.6).

$$y_t = \mu_t + \beta(u_t - u_t^N) + \varepsilon_{1,t} \quad (2.5)$$

²¹ No total 14 equações incorporam o modelo de Palma e Ferreira (2017), sendo a Curva de Phillips a principal. Portanto, para mais detalhes acerca da especificação do comportamento de cada variável, ver Palma e Ferreira (2017).

²² A análise do comportamento da NAIRU estimada é apenas um dos pontos complementares da discussão de discussão de Fernando dos Santos (2014), sendo os outros tópicos: o efeito populacional na redução do desemprego; o efeito do crescimento econômico; e os impactos da oferta e demanda por trabalho. Portanto, recomenda-se a leitura completa do trabalho de Fernando dos Santos (2014).

$$\pi_t = a\pi_{t-1} + b(u_t - u_t^N) + \varepsilon_{2,t} \quad (2.6)$$

Em que y_t é a variável de salários; π_t representa a inflação dos salários; u_t o desemprego; u_t^N a NAIRU (tendência da variável de desemprego). As outras três equações do modelo descreveram, respectivamente: o comportamento do nível do modelo estrutural (μ_t); da inclinação estocástica; e o comportamento da NAIRU.

Fernando dos Santos (2014) justificou que a estimação via equação dos salários (baseada em Blanchard e Katz, 1997) a partir da simplicidade do modelo frente ao modelo com a Curva de Phillips, outro argumento apresentado é de que os autores constataram, com base em uma regressão simples entre as duas variáveis, uma relação negativa entre a inflação dos salários e a variável de desemprego. Quanto à NAIRU estimada pelo autor, foi possível identificar uma queda da mesma a partir de 2002, contudo, Fernando dos Santos (2014) ressaltou que a incerteza na determinação da NAIRU foi elevada no modelo.

No que diz respeito ao trabalho de Nobrega, Besarria e Oliveira (2020), o objetivo foi verificar o vínculo entre o crescimento dos salários brasileiros e o comportamento do desemprego. A partir das séries reunidas que abrangem desde o 1T2000 até o 4T2016, o modelo utilizado para verificar a relação entre inflação dos salários e desemprego foi um modelo de regressão de mudança markoviana, o qual foi incorporada uma Curva de Phillips Novo-Keynesiana Aumentada (CPNKA) discutida por Galí (2011) (equação 2.7).

$$\pi_t^w = \alpha + \gamma\bar{\pi}_{t-1}^p + \beta E_t\{\pi_{t+1}^w - \gamma\bar{\pi}_t^p\} - \lambda_w\varphi(u_t - u^N) \quad (2.7)$$

Em que π^w é a inflação dos salários; π^p é a inflação baseada no índice de preços; u_t é o desemprego; u^N é a NAIRU; α , γ , β , e λ_w são os parâmetros estruturais. Como a NAIRU está presente na equação, foi preciso obtê-la antes de realizar a estimação do modelo. Com isso, os autores se basearam no modelo de função de transferência²³ de Portugal e Madalozzo (2000) e Oliveira, Portugal e Abrita (2016). A partir do teste empírico realizado pelos autores²⁴, estes argumentaram que a NAIRU estimada foi consistente para a economia brasileira.

²³ Nobrega, Besarria e Oliveira (2020) utilizam o Método Generalizado de Momentos para estimar as funções de transferência.

²⁴ Conforme Nobrega, Besarria e Oliveira (2020), o teste empírico consiste em regredir o hiato do desemprego frente a inflação corrente utilizando Mínimos Quadrados Robustos ($u_t - u_t^N = \beta_0 + \beta_1\pi_t + \varepsilon_t$). Os autores argumentaram que o sinal negativo e a significância estatística do coeficiente de π_t corrobora com o argumento teórico da relação entre hiato do desemprego e inflação (preços).

Obtida a variável não-observada, Nobrega, Besarria e Oliveira (2020) destacaram que o modelo de regressão de mudança markoviana foi estimado com dois regimes: o primeiro que verifica a relação da Curva de Phillips (inflação a partir do índice de preços) com o desemprego, e o segundo que testa a relação proposta pela CPNKA. Conforme os autores, os resultados indicaram que esses dois regimes são bem definidos, logo, o primeiro regime não validou a existência da relação, enquanto o segundo regime sugeriu a ocorrência do *trade-off* entre inflação dos salários e desemprego²⁵.

Portanto, com base nos trabalhos evidenciados, a presente dissertação visa contribuir com a literatura ao apresentar a estimação da NAIRU atualizada utilizando os dados da PNAD Contínua que abrangem do 1T2012 até o 3T2023. Para isso, quatro modelos foram empregados: componentes não observados; filtro HP, SSA e MSSA - sendo os dois últimos uma proposta de modelos não paramétricos capazes de decompor séries temporais.

²⁵ Os autores também constaram a baixa probabilidade de mudança de um regime para o outro.

3 METODOLOGIA E BASE DE DADOS

Conforme o capítulo de revisão da literatura, tanto o modelo de componentes não observados quanto o filtro HP são ferramentas que buscam uma mensuração da NAIRU. Tendo em vista essa utilização, este trabalho propõe quatro modelos para a mensuração da NAIRU brasileira. O primeiro e o segundo são univariados e utilizam as ferramentas citadas já estabelecidas na literatura. Quanto aos dois últimos, estes foram feitos com base na metodologia não paramétrica *Singular Spectrum Analysis* (SSA) – ferramenta de destaque para a análise de séries temporais (Golyandina, Korobeynikov e Zhigljavsky, 2010; Hassani e Thomakos, 2010). Com isso, o terceiro modelo apresenta o caso univariado (SSA)²⁶ e o quarto o caso multivariado da metodologia, o *Multivariate Singular Spectrum Analysis* (MSSA).

Por ser um método não paramétrico e com aplicação diferente dos restantes, o SSA carece de uma apresentação inicial, e posteriormente de um detalhamento da sua aplicação. Segundo Golyandina, Nekrutkin e Zhigljasky (2001), o propósito principal do SSA é a decomposição da série temporal escolhida em uma soma de séries, de tal forma que cada componente dessa soma possa ser identificado como tendência, sazonalidade (periódico ou quase-periódico) ou ruído. O motivo do emprego de um método não paramétrico decorreu da característica das séries trabalhadas, como número de observações e comportamento da tendência. Este capítulo, então, apresenta o modelo de componentes não observados, o filtro HP e a metodologia SSA.

No total cinco seções compõem a discussão proposta pelo capítulo. A seção 3.1 explicita o modelo de componentes não observados. A seção 3.2 apresenta o filtro HP. Já a seção 3.3 elucida o que é o SSA e para quais problemas a metodologia pode ser aplicada, fornecendo também exemplos aplicados da literatura. Quanto à seção 3.4, e suas respectivas subseções, esta expõe como o MSSA realiza a decomposição e a reconstrução das séries, ademais, é feita a discussão do tamanho de janela (L) e número de autotriplas (r) apropriados – ambos parâmetros que determinam os passos de decomposição e reconstrução. Por fim, a seção 3.5 explicita a base de dados utilizada no trabalho.

²⁶ O modelo univariado do *Singular Spectrum Analysis* é referido na literatura como 1D-SSA (*One Dimensional Singular Spectrum Analysis*) (Golyandina, Nekrutkin e Zhigljasky, 2001). Contudo, para evitar confusões ao longo do texto, ao longo deste trabalho o modelo univariado que parte da metodologia *Singular Spectrum Analysis* será referido apenas como SSA.

3.1 O MODELO DE COMPONENTES NÃO OBSERVADOS

O UCM²⁷ (*Unobserved Components Model*) é um método capaz de extrair as características não observáveis de uma série temporal, permitindo a análise dos componentes que constituem o sinal da série – como tendência e sazonalidade (Harvey e Koopman, 2000; Pelagatti, 2016).

De forma geral, no UCM a série temporal Y_t pode ser escrita como a soma dos componentes de tendência (μ_t), ciclo (ψ_t), sazonalidade (γ_t) e ruído (ε_t) (Equação 3.1). Conforme Pelagatti (2016), a especificação representada Equação 3.1 é versátil, visto que pode ser empregada – e se necessário modificada – para descrever o comportamento de diferentes séries econômicas²⁸. O UCM também permite ao pesquisador adicionar ou retirar componentes da fórmula geral, contudo, é preciso especificar o comportamento destes termos.

$$Y_t = \mu_t + \psi_t + \gamma_t + \varepsilon_t \quad (3.1)$$

Neste trabalho a especificação do Modelo Básico Estrutural (BSM – *Basic Structural Model*) apresentada em Harvey e Koopman (1992, 2009) foi a utilizada para estimar a NAIRU em um modelo univariado. O Modelo Básico Estrutural discrimina a série como uma soma de tendência, sazonalidade e o termo de erro ($Y_t = \mu_t + \gamma_t + \varepsilon_t$)²⁹.

O comportamento da tendência foi descrito utilizando o modelo LLT (*Local Linear Trend*), que descreve a tendência tempo variante como o nível da série em t adicionada de uma inclinação estocástica β_t (Harvey e Koopman, 2009) (Equação 3.2).

$$\begin{aligned} \mu_t &= \mu_{t-1} + \beta_{t-1} + \eta_t, & \eta_t &\sim NID(0, \sigma_\eta^2) \\ \beta_t &= \beta_{t-1} + \zeta_t, & \zeta_t &\sim NID(0, \sigma_\zeta^2) \end{aligned} \quad (3.2)$$

Conforme Pelagatti (2016), a tendência no LLT pode ter seu comportamento caracterizado conforme os valores das variâncias dos ruídos ($\sigma_\eta^2, \sigma_\zeta^2$) são fixados e/ou a inclinação inicial (β_0) é igual a 0. Assim, o autor destacou quatro possibilidades para o

²⁷ Sigla em inglês para: Modelo de Componentes não Observados,

²⁸ Alguns exemplos de séries utilizadas por Pelagatti (2016) ao longo de seu texto são: série mensal do logaritmo do número de passageiros de companhias aéreas entre 1949 e 1960; PIB da União Europeia – a preços de 2010 – para o período entre 1995 e 2015 com periodicidade trimestral.

²⁹ Pelagatti (2016) faz uma extensa discussão de quando o termo cíclico pode ser empregado e modelado dentro do modelo UCM.

comportamento da tendência: tendência linear; *random Walk*; *random walk com drift*; *random walk* integrado.

A tendência linear pode ser alcançada ao igualar ambas as variâncias do ruído a 0. Já no *random walk*, $\sigma_{\zeta}^2 = 0$ e a inclinação é constante e igual a 0 ($\beta_0 = 0$). Quanto ao *random walk com drift*, para este basta que $\sigma_{\zeta}^2 = 0$ e que β_0 seja fixado como constante. Por fim, para o *random walk* integrado, o valor de variância igual a zero será estabelecido na variância do termo de erro do nível (σ_{η}^2) (Pelagatti, 2016). Neste trabalho, a tendência no LLT segue um *random walk com drift*, visto que, conforme Pelagatti (2016), esse comportamento é uma boa adequação para séries econômicas não-estacionárias que seguem um comportamento I(1) ou I(2)³⁰.

Prosseguindo com a especificação do BSM, o termo de sazonalidade é modelado na forma estocástica através de *dummies*³¹, em que, sendo s definido como a periodicidade da sazonalidade (ex: se trimestral, $s = 4$), o termo sazonal é dado conforme a equação 3.3 (Pelagatti, 2016):

$$\gamma_t = - \sum_{i=1}^{s-1} \gamma_{t-i} + \omega_t, \quad \omega_t \sim WN(0, \sigma_{\omega}^2) \quad (3.3)$$

Por fim, o termo de ruído ε_t do modelo BSM é caracterizado conforme a forma geral (eq. 3.1), como uma sequência de ruído branco.

Apresentado o método UCM, o modelo de escolha e o comportamento de seus componentes, se faz necessário entender como é realizada a estimação do método. A próxima subseção apresenta o que é a forma de espaço de estados (em inglês, *state space form* - SSF), como o UCM pode ser representado nessa forma e o que é o algoritmo filtro de Kalman que é utilizado para a sua estimação.

³⁰ A partir do teste ADF (*Augmented Dickey-Fuller*) (Dickey e Fuller, 1979) não foi possível rejeitar a hipótese nula para raiz unitária para a série de desemprego utilizada. Testando para a primeira diferença da série, foi possível rejeitar a hipótese a um nível de confiança de 10%. Com isso, evidencia-se que a série segue um processo I(1).

³¹ Segundo Pelagatti (2016), no UCM a sazonalidade também pode ser modelada na forma trigonométrica. Já Harvey e Koopman (2009) relataram que a sazonalidade também pode ser descrita sob um padrão sazonal fixo.

3.1.1 O espaço de estados e o filtro de Kalman

De acordo com Harvey (1989) e Pelagatti (2016), a forma de estado de espaços é um sistema de equações que comporta uma ou mais séries, que estão linearmente relacionadas via um vetor $m \times 1$, e um vetor de estado α_t , com um conjunto de variáveis não observáveis. Esse sistema é representado por duas equações: a equação de medida (Equação 3.4) e a equação de transição (equação 3.5).

$$Y_t = c_t + Z_t \alpha_t + \epsilon_t \quad (3.4)$$

$$\alpha_{t+1} = d_t + T_t \alpha_t + v_t \quad (3.5)$$

Em que Y_t é uma série de N elementos; Z_t é uma matriz $N \times m$; c_t é um vetor $N \times 1$; ϵ_t é um vetor $N \times 1$ de uma sequência de distúrbios aleatórios de média zero e covariância H_t ; T_t é uma matriz $m \times m$; d_t é um vetor $m \times 1$; v_t é um vetor $g \times 1$ de uma sequência de distúrbios aleatórios de média zero e covariância Q_t .

Conforme Harvey (1989), o sistema é linear e Y_t pode ser expresso como uma combinação linear das observações passadas, e presentes, de ϵ_t , v_t e α_0 - o vetor de estado inicial. Harvey (1989) também destacou as premissas que devem ser assumidas para o sistema de espaço de estados:

- $E(\alpha_0) = a_0; Var(\alpha_0) = P_0;$
- $E(\epsilon_t v_t') = 0 \forall s, t = 1, \dots, T;$
- $E(\epsilon_t \alpha_0') = 0 \forall t = 1, \dots, T; E(v_t \alpha_0') = 0 \forall t = 1, \dots, T;$

De forma complementar, em sua discussão de espaço de estados Pelagatti (2016) ressaltou que se α_1 e os distúrbios ϵ_t e v_t são normalmente distribuídos, então o sistema é chamado de Espaço de Estados Gaussiano.

Pelagatti (2016) demonstrou que a elaboração do UCM no SSF é direta considerando os pressupostos expostos por Harvey (1989). Com isso, as covariâncias entre os distúrbios dentro e entre os componentes são zero, assim como as correlações entre o erro de observação e os distúrbios. A matriz de transição do UCM (T_t) é obtida a partir das matrizes de transição dos componentes escolhidos para o modelo – o que também acontece para a matriz Q_t (Pelagatti, 2016).

As equações (3.6), (3.7) e (3.8) são a representação de um modelo BSM trimestral ($s = 4$) no estado de espaços (Pelagatti, 2016). Em especial, a equação (3.6) é obtida a partir da incorporação dos componentes de tendência, sazonalidade e erro na equação de estados (3.5).

$$\begin{bmatrix} \mu_{t+1} \\ \beta_{t+1} \\ \gamma_{t+1} \\ \gamma_t \\ \gamma_{t-1} \end{bmatrix} = \begin{bmatrix} 1 & 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & -1 & -1 & -1 \\ 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 \end{bmatrix} \begin{bmatrix} \mu_t \\ \beta_t \\ \gamma_t \\ \gamma_{t-1} \\ \gamma_{t-2} \end{bmatrix} + \begin{bmatrix} \eta_t \\ \zeta_t \\ \omega_t \\ 0 \\ 0 \end{bmatrix} \quad (3.6)$$

$$\mathbf{Q} = \begin{bmatrix} \sigma_\eta^2 & 0 & 0 & 0 & 0 \\ 0 & \sigma_\zeta^2 & 0 & 0 & 0 \\ 0 & 0 & \sigma_\omega^2 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \end{bmatrix}; \mathbf{H} = \sigma_\epsilon^2; \mathbf{G} = 0 \quad (3.7)$$

$$\mathbf{Y}_t = [1 \ 0 \ 0 \ 1 \ 0 \ 0] \boldsymbol{\alpha}_t + \epsilon_t \quad (3.8)$$

O filtro de Kalman foi o algoritmo de escolha para realizar a estimação do estado de espaços neste trabalho. De acordo com Harvey (1989) e Harvey e Koopman (2009), o filtro de Kalman é um algoritmo recursivo que calcula o estimador ótimo do vetor de estados no tempo t , baseado nas informações disponíveis até o tempo t . Ademais, Harvey e Koopman (2009) ressaltaram que o filtro calcula a estimativa quadrática média mínima das observações passadas.

Considerando as definições de Harvey (1989) e Harvey e Koopman (2009), Pelagatti (2016) definiu o filtro de Kalman utilizando a notação do espaço de estados, isto é, o filtro calcula o par $\{\mathbf{a}_{t|t-1}, \mathbf{P}_{t|t-1}\}$ a partir de $\{\mathbf{a}_{t-1|t-1}, \mathbf{P}_{t-1|t-1}\}$, e computa $\{\mathbf{a}_{t|t}, \mathbf{P}_{t|t}\}$ a partir de $\{\mathbf{a}_{t|t-1}, \mathbf{P}_{t|t-1}\}$. Pelagatti (2016) demonstrou que, dessa forma, ao fornecer o valor inicial para $\{\mathbf{a}_{1|0}, \mathbf{P}_{1|0}\}$, as equações do SST podem ser iteradas para calcular $\{\mathbf{a}_{t|t}, \mathbf{P}_{t|t}\}$ e $\{\mathbf{a}_{t+1|t}, \mathbf{P}_{t+1|t}\}$ para todos os períodos em t .

Portanto, especificando o UCM, sua forma no estado de espaços e utilizando o filtro de Kalman como algoritmo recursivo para estimação, é possível decompor a série de interesse nos componentes que compõem o sinal da série, dando ao pesquisador uma série de opções de modelagem para as séries trabalhadas.

3.2 O FILTRO HODRICK-PRESCOTT

Segundo de Jong e Sakarya (2016), o filtro HP se tornou uma ferramenta amplamente utilizada na literatura econômica, sendo um instrumento comum para aplicações macroeconômicas. O filtro foi proposto por Hodrick e Prescott (1997) como um método para decompor séries temporais em componentes de tendência e cíclicos, sob o pretexto de que esses termos variam suavemente no tempo.

Conforme Hodrick e Prescott (1997), uma série temporal (y_t), de N observações, pode ser escrita como uma soma de um componente de crescimento (τ_t) e cíclico (c_t) (Hodrick e Prescott, 1997) (Equação 3.9).

$$y_t = \tau_t + c_t \quad \forall t = 1, \dots, N \quad (3.9)$$

Sendo que τ_t é denotado como o termo de tendência (De Jong e Sakarya, 2016).

Estabelecida a definição dos termos da série, o filtro HP produz a série de tendência suavizada ($\hat{\tau}_T$) a partir da minimização da equação (3.10) (Hodrick e Prescott, 1997; De Jong e Sakarya, 2016):

$$\sum_{t=1}^T (y_t - \tau_t)^2 + \lambda \sum_{t=2}^{T-1} (\tau_{t+1} - 2\tau_t + \tau_{t-1})^2 \quad (3.10)$$

Hodrick e Prescott (1997) explicaram que o parâmetro de suavização λ é um número positivo que penaliza a variabilidade do termo de crescimento da série (τ_t), sendo que, quanto maior for o valor de λ , mais suavizada será a série resultante da minimização de (3.10). Para uma periodicidade trimestral, os autores recomendaram $\lambda = 1600$.

3.3 O QUE É O SINGULAR SPECTRUM ANALYSIS?

O *Singular Spectrum Analysis*, ou SSA, é um método não paramétrico que pode ser empregado para análise de séries temporais. Além da ausência de parâmetros, o método também não exige a estacionariedade nem a normalização da(s) série(s) utilizada(s) (Hassani e Mahmoudvand, 2018; Rodrigues e Mahmoudvand, 2018; Golyandina, Nekrutkin e Zhigljavsky, 2001; Golyandina *et al.*, 2015).

Como ressaltaram Golyandina *et al.* (2015); e Hassani e Mahmoudvand (2018), o SSA pode ser empregado para: decomposição de séries temporais, extração de tendência, extração de sazonalidade, extração dos ruídos de uma série³², previsão, entre outros.³³ (Golyandina *et al.*, 2015; Hassani e Mahmoudvand, 2018). Dois pontos também indicam o SSA como uma ferramenta viável na análise de séries temporais, são eles: a possibilidade de empregá-lo com a série em nível, comportando tendências complexas e até mesmo quebras estruturais; e a viabilidade de empregar essa classe de modelos em séries curtas (Hassani e Thomakos, 2010; Hassani e Mahmoudvand, 2013; Golyandina *et al.* 2015).

Hassani e Thomakos (2010) argumentaram que os pressupostos de estacionariedade, linearidade e normalidade podem não ser as melhores aproximações para descrever o comportamento de séries econômicas no mundo real – logo, a característica de não exigência destes pressupostos se configura como uma das principais vantagens da metodologia. Ademais, os autores discutiram que os modelos da classe SSA podem lidar com séries que apresentam raiz unitária e/ou diferentes comportamentos de tendência, porque os autovalores (e seus respectivos autovetores) obtidos na etapa de decomposição irão conter a informação dos diferentes comportamentos dos termos de tendência³⁴.

Golyandina, Nekrutkin e Zhigljavsky (2001) demonstraram a capacidade da metodologia em extrair tendências de diferentes direções e intensidades utilizando uma série de produção de óleo com 321 observações. Os autores ressaltaram a capacidade do SSA em fornecer tanto uma representação geral da tendência da série quanto uma representação mais precisa de seu comportamento, para isso, é necessário que o pesquisador utilize todas as informações que representam a tendência na etapa de decomposição. Golyandina, Nekrutkin e Zhigljavsky (2001) também exemplificaram a possibilidade do SSA de extração de tendências complexas utilizando a série de desemprego da Alemanha Ocidental de 356 observações³⁵. Conforme os autores, a extração de tendências complexas exigirá que o pesquisador escolha

³²A extração de ruídos da série, permite a reconstrução da série original em uma série menos ruidosa (Golyandina, Korobeynikov e Zhigljavsky, 2001).

³³ Para mais exemplos de quais tipos de problema a aplicação do SSA se faz eficiente, ver Hassani e Mahmoudvand (2018).

³⁴ Para a formalização da proposição feita pelos autores, ver Hassani e Thomakos (2010).

³⁵ Dados mensais de abril de 1950 até dezembro de 1980.

mais elementos³⁶ que representem o comportamento de tendência da série na etapa da reconstrução, caso contrário, o pesquisador obterá uma tendência suavizada.

Hassani e Zhigljavsky (2009) utilizaram o SSA para modelar 16 séries³⁷ extraídas das contas nacionais do Irã, contudo, como foram organizadas tanto em dados trimestrais quanto anuais, os autores modelaram 32 séries. Os autores classificaram as séries empregadas como curtas, visto que as séries trimestrais apresentaram 68 observações enquanto as séries anuais totalizavam 45 observações. Não obstante, Hassani e Zhigljavsky (2009) não somente retiraram os componentes de tendência e oscilatórios das séries para a sua reconstrução, como também realizaram suas previsões. A partir da computação do erro médio relativo da previsão³⁸ feita para cada uma das séries, os autores afirmaram, com base nos erros relativos médios obtidos, que a metodologia SSA apresentou resultados eficientes para a decomposição e previsão de séries curtas. Hassani e Zhigljavsky (2009), inclusive, relataram que a aplicação do logaritmo nas séries prejudicou a maioria dos resultados das previsões das séries.

No que diz respeito à extração do sinal da série, agora para séries com maiores observações, Santos (2022) utilizou o SSA para retirar o componente de tendência da série do IPCA (Índice de Preços do Consumidor Amplo) com o objetivo de obter uma mensuração do núcleo de inflação. A série utilizada pelo autor possuía 262 observações e abrangeu o período de agosto de 1999 até maio de 2021. Baseado nos testes de capacidade preditiva utilizados³⁹, além das propriedades de ausência de viés e de dinâmica de ajustamento, a mensuração do núcleo de inflação obtida via SSA apresentou melhores resultados do que as medidas de núcleo já utilizadas pelo Banco Central. Sendo assim, o SSA se apresentou como um método eficiente na extração do componente de tendência da série de inflação (Santos, 2022).

³⁶ Na próxima seção será elucidado que esses elementos são denominados como autotriplas. As autotriplas são parte fundamental da etapa de reconstrução do modelo, e a escolha de quais serão utilizadas afeta diretamente os resultados.

³⁷ Conforme Hassani e Zhigljavsky (2009), as 16 séries utilizadas foram: agricultura; óleo e gás; indústrias e minas; manufatura; mineração; suprimento de eletricidade, gás e água; construção; serviços; comércio, restaurantes e hotéis; transporte; armazenamento e comunicações; serviços financeiros; serviços profissionais e imobiliários; serviços públicos; serviços sociais, pessoais e domésticos; taxa imputada de serviços bancários; produto interno bruto nominal. Todas as séries se estenderam de 1988 a 2004 e estavam medidas em milhões de reais iranianos.

³⁸ Para realizar a previsão e computar o erro relativo médio, Hassani e Zhigljavsky (2009) retiraram 4 observações das séries trimestrais e 3 observações das séries anuais, logo, as séries incorporadas para previsão possuíam, respectivamente, 64 e 42 observações.

³⁹ Santos (2022) aplicou os seguintes testes: Diebold e Mariano (1995); e Marcellino, Stock e Watson (2006) para avaliar a capacidade preditiva do núcleo mensurado e dos núcleos utilizados pelo Banco Central na previsão do IPCA.

Já Carvalho, Rodrigues e Rua (2012) empregaram um filtro baseado na metodologia SSA, chamado de *CRR-filter*, para decompor o PIB dos Estados Unidos em componentes de tendência, sazonalidade e ruído. O foco dos autores se fez na análise da performance do filtro ao extrair o ciclo de negócios da série do PIB, que foi definido pelos mesmos como um componente cíclico cuja periodicidade varia de 6 a 32 trimestres. Carvalho, Rodrigues e Rua (2012) compararam os resultados do *CRR-filter* com os resultados obtidos utilizando o Filtro HP e o Filtro Christhiano-Fitzgerald. Assim sendo, o filtro proposto apresentou resultados superiores em relação aos outros dois métodos nas estatísticas de correlação com a série original, de concordância do sinal e na razão ruído-sinal.

O SSA apresenta outras aplicações consolidadas também na versão multivariada. Silva, Hassani e Heravi (2017) utilizaram o MSSA para investigar como as relações interindustriais influenciam no poder de previsão das séries de oito setores industriais da Alemanha, França e Reino Unido⁴⁰, portanto, o MSSA permitiu a modelagem e a previsão simultânea de 8 séries temporais para cada um dos três países selecionados. Quanto ao número de observações, as séries da Alemanha, França e Reino Unido possuíam periodicidade mensal e apresentaram, respectivamente: 278, 266 e 170 observações, e, conforme Silva, Hassani e Heravi (2017), as previsões do MSSA foram comparadas ao modelo univariado (SSA) utilizando as medidas do erro médio absoluto e da raiz quadrada do erro médio MSSA para previsão *out-of-sample*. De acordo com os autores, o MSSA apresentou uma melhor previsão em 70% dos casos.

Para Kapl e Müller (2010) o MSSA foi empregado com o objetivo de prever o preço da bobina de aço para a Alemanha. Nesse trabalho, o modelo foi composto por oito séries⁴², que possuíam periodicidade trimestral e abrangiam o período do 2T1991 até 1T2009 (72 observações). Conforme os autores, quando comparado com o modelo ARIMA⁴³, a performance preditiva do MSSA ficou indistinguível em relação ao ARIMA, contudo, Kapl e

⁴⁰ De acordo com Silva, Hassani e Heravi (2017), as séries obtidas para cada país corresponderam a produção real de: eletricidade/gás, químicos, metais manufaturados, veículos, produtos alimentícios, metais básicos, maquinário elétrico e maquinários.

⁴¹ O trabalho dos autores tem como base o artigo de Hassani, Heravi e Zhigljavsky (2009) que utilizaram o SSA para realizar a previsão de 24 séries temporais de produção industrial desses mesmos três países. Em suma, Hassani, Heravi e Zhigljavsky (2009) ressaltaram que o SSA apresentou um poder de previsão melhor do que os métodos Holt-Winters e ARIMA para horizontes mais longos.

⁴² Conforme Kapl e Müller (2010), as séries utilizadas foram: o preço do rolo de aço para a Alemanha e para os EUA; o PIB real para a União Europeia e para os EUA; o índice de produção industrial para a União Europeia e para os EUA; o preço do petróleo; o índice Dow Jones de Média Industrial.

⁴³ Para mais detalhes da especificação utilizada, ver Kapl e Müller (2010).

Müller (2010) constataram que o MSSA se mostrou uma técnica mais robusta para modelos que lidam com altos níveis de ruídos nas séries.

Para além do poder preditivo, o MSSA também pode ser aplicado para encontrar indicadores de atividade econômica. Emmanuel Silva *et al.* (2017) usaram o MSSA para mensurar se os dados de chegada de turistas em um país europeu podem servir de indicador para a demanda turística em outro, avaliando, assim, a relação entre países de chegadas de turistas. No total, os autores utilizaram a série mensal de chegada de turistas internacionais para 10 países europeus⁴⁴, cada uma contendo 144 observações cada (janeiro de 2000 até dezembro de 2012) e apresentando pelo menos uma quebra estrutural cada – exceto para Chipre e Suécia. Conforme Emmanuel Silva *et al.* (2017), o MSSA foi capaz identificar indicadores de demanda visto que o modelo multivariado melhorou a performance da previsão da demanda turística para países europeus.

Portanto, a metodologia SSA, tanto no ambiente univariado quanto no multivariado, se coloca na literatura como uma ferramenta disponível para a aplicação em diversos problemas empíricos, se destacando pela versatilidade que apresenta. Por fim, tendo em vista que os passos para a aplicação do SSA e do MSSA são semelhantes, a próxima seção expõe uma descrição da aplicação da metodologia SSA utilizando as notações do MSSA, sendo que para a aplicação univariado basta considerar o número de séries igual a 1 ($Y_t = y_t^{(1)}$).

3.4 O MULTIVARIATE SINGULAR SPECTRUM ANALYSIS (MSSA):

O MSSA é aplicado com base em dois passos principais: decomposição e reconstrução. Cada um desses dois grandes passos pode ser dividido em dois, logo, quatro passos são necessários para desenvolver o MSSA, sendo estes: incorporação, decomposição de valor singular, agrupamento e diagonalização média⁴⁵ (Hassani e Mahmoudvand, 2018; Rodrigues e Mahmoudvand, 2018; Golyandina *et al.*, 2015).

O MSSA, e modelos SSA em geral, apesar de não paramétrico também precisa que dois “parâmetros” sejam escolhidos: o tamanho da janela (L) e a quantidade de autotriplas (r). Estes dois “parâmetros” determinam cada uma das duas partes de aplicação do MSSA, logo, a janela

⁴⁴ Conforme Emmanuel Silva *et al.* (2017) os países selecionados foram: Alemanha, Grécia, Espanha, Itália, Chipre, Holanda, Áustria, Portugal, Suécia e Reino Unido.

⁴⁵ Os termos foram diretamente traduzidos do inglês, na qual são chamados, respectivamente, de: *embedding*, *singular value decomposition*, *grouping* e *diagonal averaging*.

(L) determina o passo de decomposição e a quantidade de autotriplas (r) a reconstrução (Rodrigues e Mahmoudvand, 2018). A extensão da janela L^{46} , determinará a quantidade de vetores de defasados (K) que serão gerados no modelo, já a quantidade de autotriplas r serão utilizadas na reconstrução das séries incorporadas no modelo.

Tendo em vista uma melhor apresentação do método, cada um dos passos citados e a escolha dos parâmetros L e r serão abordados nas seguintes subseções de 1 a 6. Por fim, a sétima subseção visa elucidar a operacionalização do MSSA, esta que exige interpretação gráfica para reconstrução dos componentes.

3.4.1 1º Passo: Incorporação

Defina Y_t como uma amostra de M séries de tamanho N^{47} , logo $Y_t = [y_t^{(1)}, \dots, y_t^{(M)}]$ com $t = 1, \dots, N$. De acordo com Rodrigues e Mahmoudvand (2018), o conjunto de séries Y_t pode ser escrito em termos de uma soma do sinal (\mathbf{S}_T) mais o ruído (\mathbf{C}_T): $\mathbf{Y}_T = \mathbf{S}_T + \mathbf{C}_T$. Com isso, os autores ressaltaram que o intuito da aplicação do método é obter uma série menos ruidosa que a original.

Definido o conjunto de séries a ser utilizado, considere também L como sendo um integral de tamanho $1 < L < N$. Então, o primeiro passo da incorporação consiste em passar uma matriz unidimensional (Y_t) para uma matriz multidimensional $[X_1^{(i)}, \dots, X_{K_i}^{(i)}]$ que será constituída por $K = N - L + 1$ vetores $X_j^i = [y_j^i, \dots, y_{j+L_i+1}^i]^T \in \mathbf{R}^{L_i}$. X_j^i são os vetores L -defasados formados para cada série temporal trabalhada (Hassani e Mahmoudvand, 2013; Golyandina, Korobeynikov e Zhigljavsky, 2010).

O objetivo final do passo de incorporação é obter a matriz trajetória $\mathbf{X} = (X_1^{(i)}, \dots, X_{K_i}^{(i)})$. A matriz trajetória (Equação 3.11) alcançada é uma matriz de Hankel, portanto, os elementos da diagonal $i + j$ serão iguais (Menezes, 2014). Hassani e Mahmoudvand (2013), ressaltaram que no passo da incorporação são formadas M ($i = 1, \dots, M$) matrizes trajetórias – uma para

⁴⁶ Em inglês, o termo utilizado é “*window length*”.

⁴⁷ Aqui estão sendo consideradas N séries de tamanho iguais. Para mais detalhes sobre as notações da metodologia a respeito de séries de tamanhos diferentes, ver Hassani e Mahmoudvand (2013).

cada série – de tamanho $L_i \times K_i$. Tais matrizes são necessárias para formar o bloco da matriz de Hankel do passo de incorporação.

$$\mathbf{X} = \begin{bmatrix} y_1^{(i)} & y_2^{(i)} & \cdots & y_K^{(i)} \\ y_2^{(i)} & y_3^{(i)} & \cdots & y_{K+1}^{(i)} \\ \vdots & \vdots & \ddots & \vdots \\ y_L^{(i)} & y_{L+1}^{(i)} & \cdots & y_N^{(i)} \end{bmatrix} \quad (3.11)$$

Obtida a matriz trajetória, a mesma pode ser organizada de duas formas: vertical (eq. 3.12) ou horizontal (eq. 3.13). Caso o MSSA seja construído com a matriz trajetória vertical, será chamado de VMSSA (*Vertical MSSA*), agora, caso seja construído com a matriz trajetória na horizontal, será HMSSA (*Horizontal MSSA*) (Golyandina, Korobeynikov e Zhigljavsky, 2010; Hassani e Mahmoudvand, 2018; Rodrigues e Mahmoudvand, 2018). Ademais, a escolha entre VMSSA e HMSSA pode resultar em dimensões diferentes para a matriz trajetória visto que se a matriz for organizada verticalmente o K permanecerá fixo e L poderá variar ($L_M \times K$), agora, se a matriz for organizada horizontalmente tem-se que o L permanecerá fixo e K poderá variar ($L \times K_M$) (Hassani e Mahmoudvand, 2013; Menezes, 2014).

$$\mathbf{X}_V = \begin{bmatrix} \mathbf{X}^{(1)} \\ \vdots \\ \mathbf{X}^{(M)} \end{bmatrix} \quad (3.12)$$

$$\mathbf{X}_H = [\mathbf{X}^{(1)}, \dots, \mathbf{X}^{(M)}] \quad (3.13)$$

Considerando o L fixo na dimensão da matriz trajetória para o HMSSA, Golyandina, Korobeynikov e Zhigljavsky (2010) evidenciaram que, diferente do caso vertical, a organização horizontal da matriz é consistente com a continuação das séries temporais, visto que o aumento do tamanho das séries altera o número de vetores defasados (K) da matriz, porém, não altera sua dimensão.

A organização horizontal para a matriz do MSSA também proporciona a mesma organização espaço trajetória coluna⁴⁸⁴⁹ do SSA univariado (Golyandina, Korobeynikov e Zhigljavsky, 2010). Menezes (2014) também ressaltou que o segundo passo da Decomposição

⁴⁸ O espaço trajetória é definido como um espaço linear gerado pelos vetores defasados – que são as colunas da matriz trajetória (Golyandina e Stepanov, 2005).

⁴⁹ Golyandina *et al.* (2015) afirmam que os termos “espaço trajetória” e “espaço trajetória coluna” geralmente podem ser lidos da mesma forma e, portanto, possuem o mesmo significado. Isso porque o espaço trajetória coluna é um subespaço de R^L e o espaço trajetória linha é um subespaço de R^K .

de Valor Singular também será o mesmo entre HMSSA e o SSA univariado, visto que, como \mathbf{X}_H possui dimensão $(L \times K_M)$, $\mathbf{X}_H \mathbf{X}_H^T$ terá dimensão $L \times L$.

Por fim, neste trabalho será utilizada a matriz trajetória horizontal seguindo a formulação do pacote RSSA (Korobeynikov *et al.*, 2023), pacote do programa Rstudio utilizado para a operacionalização dos modelos SSA. Portanto, tendo em vista a utilização do pacote Rssa⁵⁰ (Korobeynikov *et al.*, 2023) do programa Rstudio para a operacionalização do MSSA no presente trabalho, a partir deste ponto será considerado um HMSSA em todos os passos de aplicação do MSSA, isso porque o algoritmo do pacote realiza a execução, e obtenção, de uma matriz trajetória horizontal.

3.4.2 2º Passo: Decomposição de Valor Singular

No 2º passo é realizada a decomposição de valor singular (DVS) da matriz trajetória (\mathbf{X}_H). A DVS retorna os autovalores $\lambda_{H_1}, \dots, \lambda_{H_L}$ (com $\lambda_{H_1} \geq \dots \geq \lambda_{H_L} \geq 0$), e seus respectivos autovetores V_{H_1}, \dots, V_{H_L} , de $\mathbf{X}_H \mathbf{X}_H^T$. Portanto, pode-se representar a DVS de \mathbf{X}_H como $\mathbf{X}_H = \mathbf{X}_{H_1} + \dots + \mathbf{X}_{H_L}$ (Hassani e Mahmoudvand, 2013; Golyandina *et al.*, 2015; Hassani e Mahmoudvand, 2018). O resultado da decomposição de \mathbf{X}_H também pode ser escrito da seguinte forma:

$$\mathbf{X}_{H_i} = \sqrt{\lambda_i} V_{H_i} P_{H_i}^T \quad (3.14)$$

em que $P_{H_i}^T = \mathbf{X}_H^T V_{H_i} / \sqrt{\lambda_i}$ e $\sqrt{\lambda_i}$ são os valores singulares de \mathbf{X}_H .

A equação 3.14 é justamente a já citada autotripla. Tais autotriplas contêm informações dos sinais (tendência ou sazonalidade) ou dos ruídos das séries incorporadas no modelo. Por isso a necessidade de seleção tanto da janela – importante para a decomposição das séries, quanto das autotriplas – essenciais para a reconstrução de uma série menos ruidosa.

Apresentadas as autotriplas, é preciso ressaltar como o MSSA considera a covariância da matriz trajetória. Pegando o caso deste trabalho para o modelo multivariado, em que $M = 2$ (duas séries temporais: desemprego e inflação) \mathbf{U} e $\mathbf{\Pi}$, a matriz trajetória no MSSA será $\mathbf{X} = [\mathbf{U}; \mathbf{\Pi}]$, com $\mathbf{X} = \sum_i \sqrt{\lambda_i} V_i P_i^T$ e, portanto, λ_i e V_i são os autovalores e autovetores de

⁵⁰ O pacote Rssa é de autoria de Korobeynikov *et al.* (2023) e foi desenvolvido com o intuito de reunir, e permitir, as aplicações dos métodos baseados no SSA na programação R (R foundation, 2023).

$\mathbf{S}_{MSSA}^{Horizontal} = \mathbf{X}\mathbf{X}^T = \mathbf{U}\mathbf{U}^T + \mathbf{\Pi}\mathbf{\Pi}^T$, assim sendo, o MSSA analisa a estrutura média dessas duas séries temporais (Golyandina *et al.*, 2015).

3.4.3 3º Passo: Agrupamento

O agrupamento é o primeiro passo da etapa de reconstrução das séries e é neste passo que ocorre a separação entre o sinal e o ruído da série utilizando as autotriplas (podendo agora chamá-las de r) decorrentes do passo anterior.

Considere então as autotriplas $\mathbf{X}_{H_1} + \dots + \mathbf{X}_{H_L}$ resultantes da etapa DVS, neste passo o objetivo é separar as L matrizes obtidas em m subconjuntos disjuntos $\mathbf{I}_1, \dots, \mathbf{I}_m$ que condizem com a representação já obtida anteriormente: $\mathbf{X}_H = \mathbf{X}_{I_1} + \dots + \mathbf{X}_{I_m}$ (Golyandina e Stepanov, 2005; Hassani e Mahmoudvand, 2018).

Ademais, conforme Hassani e Mahmoudvand (2018), vale ressaltar que cada subgrupo \mathbf{I} é constituído por um conjunto de autotriplas $\mathbf{I}_1 = \{1, \dots, r\}$, com isso, é possível obter a contribuição de cada \mathbf{X}_{H_1} através da quota de cada autovalor correspondente: $\sum_{i \in \mathbf{I}} \lambda_{H_i} / \sum_{i=1}^{d_H} \lambda_{H_i}$, na qual d_H é o posto da matriz \mathbf{X}_H e $\mathbf{I} \subset \{1, \dots, L\}$

3.4.4 4º Passo: Diagonalização Média

O último passo para a reconstrução do MSSA realiza o caminho oposto do passo de incorporação. Assim, o último passo consiste em realizar a diagonalização média em cada matriz resultante do processo de agrupamento (\mathbf{X}_{I_j}) para obter uma nova matriz de Hankel, de forma que, após obtida, seja possível utilizar essa nova matriz para transformá-la em um sistema de novas séries reconstruídas de tamanho N (Golyandina e Stepanov, 2005; Hassani e Mahmoudvand, 2013).

É importante ressaltar que a matriz de Hankel resultante deste quarto passo não é igual a matriz obtida no passo de incorporação, e sim uma matriz de Hankel aproximada da primeira. Ressalta-se que esta segunda matriz é aproximada porque, durante o passo de agrupamento, devem ser escolhidas as autotriplas que representam as informações do sinal das séries e retiradas as que correspondem ao comportamento de ruído. Portanto, a realização do método se inicia com uma matriz trajetória e se encerra com uma outra matriz trajetória, esta última

modificada e que permitirá a reconstrução das séries para a análise e/ou previsão conforme os objetivos do pesquisador.

Considere $\tilde{\mathbf{X}}^{(i)}$ como a matriz de Hankel, ou matriz trajetória, decorrente do processo de diagonalização, em que $\tilde{\mathbf{X}}^{(i)}$ é uma aproximação de $\mathbf{X}^{(i)}$ e possui os respectivos elementos $\tilde{x}_{mn}^{(i)}$. Portanto, a partir da realização da média aritmética de $\tilde{x}_{mn}^{(i)}$ por todo espaço $(m, n) | m + n = j$, é possível obter o j -ésimo termo da série reconstruída $\tilde{Y}_{N_i}^{(i)} = (\tilde{y}_1^{(i)}, \dots, \tilde{y}_j^{(i)}, \dots, \tilde{y}_{N_i}^{(i)})$ (Hassani e Mahmoudvand, 2018).

3.4.5 A escolha do tamanho da janela e da quantidade de autotriplas

A extensão da janela é ponto de debate dentro da metodologia SSA e sua escolha para o MSSA se torna ainda mais complicada, visto que, no primeiro passo do MSSA, deve-se lidar com uma matriz de Hankel agrupada – e não somente com uma única matriz trajetória como é o caso do ambiente univariado. Conforme ressaltado na subseção 3.4.1, o tamanho da janela (L) irá determinar a estrutura e a quantidade de autovalores obtidos a partir da matriz trajetória, influenciando diretamente na qualidade do modelo como um todo.

Para o HMSSA, Hassani e Mahmoudvand (2013) argumentaram⁵¹ que o tamanho ótimo da janela, ou próximo do ótimo, pode ser obtido a partir da seguinte fórmula:

$$\frac{M}{M+1}(N+1) \quad (3.15)$$

Golyandina *et al.* (2015) também ressaltaram que a fórmula (3.15) pode fornecer uma janela próxima do ótimo, contudo, os autores salientaram que a escolha da janela pode depender do objetivo do pesquisador e das características das séries utilizadas. Por exemplo, uma maior janela pode ser utilizada para melhorar a extração de tendência das séries, assim como, no caso de séries com tendências complexas, uma menor janela pode proporcionar uma similaridade dos autovalores da matriz trajetória e, portanto, melhorar a separabilidade dos componentes. Outro ponto de destaque de Golyandina *et al.* (2015) é que a fórmula (3.15) pode não funcionar em modelos que apresentem séries curtas, visto que o K seria pequeno demais para fornecer a separabilidade dos componentes – situação que favoreceria um tamanho de janela menor. De

⁵¹ Para mais detalhes a respeito da prova do teorema que resulta na equação (3.5), tanto para o HMSSA quanto para o VMSSA, ver Hassani e Mahmoudvand (2013).

forma geral, os autores recomendaram como referência inicial uma janela que equivalha à metade da série ($L = N/2$) – justamente para realizar os testes iniciais.

Entendida a estrutura da covariância para o HMSSA, é preciso lembrar que cada autotripla representa uma quantidade de informação das séries, seja do sinal ou do ruído. Hassani e Mahmoudvand (2013) salientaram que os componentes correspondentes⁵² (R_c) configuram a parte do sinal das séries, enquanto os componentes não correspondentes entre si provavelmente estariam representando o comportamento de ruído⁵³. Com isso, uma reconstrução que leva em consideração todas as autotriplas disponíveis ($r = R_c + R_{nc}$) é desfavorável para o MSSA – visto que a etapa da reconstrução poderia estar incorporando os ruídos na série reconstruída, sem realizar uma filtragem dos mesmos (Golyandina, Korobeynikov e Zhigljavsky, 2010; Hassani e Mahmoudvand, 2018). Hassani e Mahmoudvand (2018) ainda destacaram que a reconstrução que considere $r < R_c$ está perdendo precisão, dado que parte da informação do sinal das séries estaria sendo perdida.

Portanto, a quantidade ideal de autotriplas para a reconstrução das séries que compartilham componentes correspondentes no HMSSA deve seguir $r \cong R_c$ (mantendo $r > R_c$) (Hassani e Mahmoudvand, 2013; Hassani e Mahmoudvand, 2018). Dessa forma, o MSSA leva vantagem na análise frente ao modelo unidimensional⁵⁴. No presente trabalho a reconstrução é feita buscando a incorporação aproximada das autotriplas que indicam comportamentos de tendência e sazonais, filtrando o ruído das séries ($r \cong R_c$).

3.4.6 Correspondência e separabilidade no MSSA

Durante a aplicação do MSSA o pesquisador também deve se atentar em alguns pontos que podem auxiliar na escolha das séries que serão incorporadas ao modelo, assim como sua realização durante o passo a passo - principalmente nos passos SVD e agrupamento, são estes:

⁵² Como primeira intuição, por componentes correspondentes entenda como uma autotripla capturando um mesmo comportamento de tendência entre as séries, ou até mesmo um comportamento sazonal em comum.

⁵³ Sem a análise gráfica do comportamento dos autovetores não é possível afirmar que um R_{nc} se trata de um ruído. Contudo, a não correspondência do componente em relação aos restantes já é uma das pistas para identificar um ruído na aplicação do MSSA.

⁵⁴ Segundo Golyandina, Korobeynikov e Zhigljavsky (2010), o MSSA poderia ser aplicado mesmo em um caso onde não existem componentes correspondentes entre si, porém, a análise do MSSA irá equivaler a um modelo unidimensional onde cada série estivesse sendo avaliada por vez. Isso acontece porque o posto do MSSA, para um caso de séries correspondentes, irá ser menor que o posto do SSA unidimensional, logo, caso as séries não tenham correspondência, esse posto irá se equivaler ao SSA univariado.

o posto do sinal; a forma recorrente linear; a correspondência entre as séries utilizadas; e a separabilidade dos componentes⁵⁵.

Golyandina, Korobeynikov e Zhigljavsky (2010) ressaltaram que entender a noção de posto para os métodos baseados no SSA se faz importante porque o posto do sinal reflete a sua complexidade e, conseqüentemente, a dificuldade de sua extração. A análise do posto do sinal, portanto, é uma das formas de identificar a presença (ou ausência) de componentes correspondentes obtidos na decomposição. Conforme Golyandina, Nekrutkin e Zhigljavsky (2001), o posto de uma matriz é definido como o número de colunas linearmente independentes de uma matriz. Considere uma coleção de m sinais de tamanho N : $\mathbb{H}^{(q)} = \left(h_j^{(q)} \right)_{j=1}^N$, $q = 1, \dots, m$, admita também que p_q é o posto⁵⁶ de $\mathbb{H}^{(q)}$ para o SSA, p é o posto de $(\mathbb{H}^{(1)}, \dots, \mathbb{H}^{(m)})$ para o MSSA, e que $p_{min} = \max\{p_q, p = 1, \dots, m\}$ e $p_{max} = \sum_{q=1}^m p_q$. Golyandina *et al.* (2015) ressaltaram que o caso em que $p = p_{max}$ é desfavorável para a metodologia MSSA, visto que as séries incorporadas não teriam componentes correspondentes. Com isso, os autores destacaram que o caso em que $p < p_{max}$ indica a presença destes⁵⁷.

Quanto à questão da Forma Recorrente Linear (FRL), Golyandina, Nekrutkin e Zhigljavsky (2001) salientaram que se uma série infinita é governada por uma FRL, então a série pode ser representada por uma combinação linear de séries exponenciais, harmônicas e polinomiais – logo, a série pode ser representada por um polinômio característico. As raízes do polinômio característico, chamadas de raízes características, determinam o comportamento das séries⁵⁸. Com isso, a análise das raízes características do MSSA é também uma opção para analisar a similaridade entre as séries do modelo, visto que refletem o seu comportamento (Golyandina, Korobeynikov e Zhigljavsky, 2010).

No que diz respeito à correspondência das séries, na subseção 3.4.2 já foi apresentado que a correspondência afeta a quantidade de componentes correspondentes como resultado da etapa da decomposição do modelo – dado que as autotriplas irão refletir o comportamento de

⁵⁵ Além dos pontos citados, recomenda-se a leitura dos trabalhos de Golyandina, Korobeynikov e Zhigljavsky (2010) e Golyandina *et al.* (2015) que apresentam detalhes adicionais sobre a aplicação do MSSA, como período das séries utilizadas e até mesmo uma discussão a respeito da escala dos dados das séries do modelo.

⁵⁶ De acordo com Golyandina *et al.* (2015), o posto SSA equivale à dimensão dos espaços trajetória gerado no passo da incorporação do SSA.

⁵⁷ Para o caso $p = p_{max}$, o MSSA não leva vantagem em precisão e previsão frente ao SSA univariado, visto que os resultados se equivaleriam à análise de cada série em um ambiente univariado.

⁵⁸ A série seguir uma FRL também se faz necessário para realizar a sua previsão. Para mais detalhes, ver Golyandina, Nekrutkin e Zhigljavsky (2001).

sinal e ruído das séries. Ao se tratar de MSSA, duas séries possuem a mesma estrutura caso seus espaços trajetória se equipararem. Se essas duas séries forem totalmente correspondentes, uma série poderia ser utilizada para a reconstrução e previsão da outra, porém, caso sejam totalmente diferentes, a análise e a previsão da primeira não seriam de utilidade para a segunda⁵⁹ - o que não corrobora com a análise simultânea das séries⁶⁰ (Golyandina *et al.*, 2015). Como exemplo de espaços que se coincidem, Golyandina *et al.* (2015) exemplificaram que o espaço trajetória de duas ondas senoidais de períodos iguais coincidiriam independentemente de sua fase ou amplitude.

Finalmente, considere a decomposição da matriz trajetória no segundo passo como sendo $\mathbb{X} = \mathbb{X}_1 + \mathbb{X}_2$. Então, a separabilidade entre os componentes expressa que existe um agrupamento de autotriplos tal que (na etapa da reconstrução) a matriz trajetória reconstruída seja igual a matriz trajetória inicial $\tilde{\mathbb{X}}_1 = \mathbb{X}_1$ (Golyandina *et al.*, 2015). Tendo em vista a presença de ruídos nas séries, a separabilidade também pode ser aproximada, logo a série reconstruída (isto é, a matriz trajetória) deverá ser aproximadamente igual ($\tilde{\mathbb{X}}_1 \cong \mathbb{X}_1$). Segundo Golyandina *et al.* (2015), a separabilidade reflete também a capacidade de extração de \mathbb{X}_1 em \mathbb{X} através do método aplicado, logo, uma separabilidade fraca⁶¹ não é suficiente para a extração dos componentes das séries.

Ainda quanto à separabilidade, Golyandina *et al.* (2015) discutiram como checar a separabilidade dos componentes⁶² $\tilde{\mathbb{X}}_1$ e $\tilde{\mathbb{X}}_2$ a partir da medida de w-correlação desses componentes (equação 3.16).

$$\rho_w(\tilde{\mathbb{X}}_1, \tilde{\mathbb{X}}_2) = \rho(\tilde{\mathbb{X}}_1, \tilde{\mathbb{X}}_2) = \frac{(\tilde{\mathbb{X}}_1, \tilde{\mathbb{X}}_2)_w}{\|\tilde{\mathbb{X}}_1\|_w \|\tilde{\mathbb{X}}_2\|_w} \quad (3.16)$$

⁵⁹ Os dois últimos casos extremos não correspondem, normalmente, aos casos encontrados no mundo real. Golyandina, Korobeynikov e Zhigljavsky (2010) afirmaram que os casos reais geralmente se encontram no meio desses dois mundos, na qual o ruído presente nas séries também é responsável pela sua correspondência.

⁶⁰ A interpretação é similar ao caso da interpretação estatística de correlação (agora paramétrica porque depende da covariância e variância) entre as séries, na qual a correspondência perfeita entre elas permitiria justamente a utilização de qualquer uma das séries para reconstrução e previsão da outra, enquanto a diferença total de uma série não seria útil na previsão da outra.

⁶¹ Para mais detalhes e definições adicionais sobre separabilidade, Golyandina, Nekrutkin e Zhigljavsky (2001) discutem a separabilidade entre as séries em termos de ortogonalidade do espaço trajetória que é obtido no passo da incorporação.

⁶² Lembrando que esses componentes reconstruídos também podem ser chamados de séries reconstruídas, já que na metodologia SSA a série é decomposta em uma soma de séries (Golyandina, Nekrutkin e Zhigljavsky, 2001).

Em que \tilde{X}_1 e \tilde{X}_2 são as matrizes trajetórias reconstruídas e w é a w -correlação. Sendo \tilde{X}_j o componente reconstruído produzido pelo agrupamento $I_j = \{j\}$ no terceiro passo, então $\rho_{ij}^{(w)} = \rho_w(\tilde{X}_i, \tilde{X}_j)$ é a matriz de w -correlação (Golyandina, Nekrutkin e Zhigljavsky, 2001; Golyandina *et al.*, 2015).

A partir da construção da matriz dos componentes da matriz trajetória é possível visualizar a separabilidade dos componentes da série e sua correspondência também – como componentes que representam comportamento de tendência das séries originais. Quanto menor o valor da w -correlação entre os componentes, melhor a sua separabilidade, por outro lado, quanto maior essa correlação, pior a separabilidade entre esses componentes (Golyandina, Nekrutkin e Zhigljavsky, 2001; Rodrigues e Mahmoudvand, 2018).

Por fim, o pacote Rssa fornece o *plot* da matriz de w -correlação e é através deste, junto com análise gráfica visual dos autovalores e autovetores, que as questões de correspondência e separabilidade são checadas durante a aplicação do MSSA.

3.4.7 A operacionalização da escolha das autotriplas

O presente trabalho faz uso da análise gráfica dos autovalores e autovetores para escolher as autotriplas que representam os comportamentos de sinal das séries no passo de agrupamento da reconstrução⁶³. Portanto, quatro figuras foram utilizadas como base da análise para o agrupamento das autotriplas, são estes: o log dos autovalores; a matriz de w -correlação; as figuras unidimensionais dos autovetores U_i (*plot* dos autovetores); e as figuras bidimensionais dos autovetores (U_i, U_{i+1}) (*plot* dos pares de autovetores)⁶⁴ (Golyandina, Korobeynikov e Zhigljavsky, 2010; Hassani e Mahmoudvand, 2018). Todos esses gráficos podem ser obtidos através da programação do pacote Rssa incorporado ao Rstudio e seus *plots* foram utilizados na descrição dos resultados. Ademais, as análises devem ser feitas de forma simultânea, visto que a informação de uma figura pode complementar a de outra – auxiliando na decisão de agrupamento dos componentes.

⁶³ Menezes (2014) escolhe o método da análise gráfica para operacionalizar sua etapa de agrupamento, mas destaca que esta não é a única opção para agrupar as autotriplas. Os outros métodos destacados pelo autor seriam: análise de componentes principais e clusterização hierárquica.

⁶⁴ O pacote Rssa também permite a exibição de uma quinta figura para o SSA univariado: o *plot* da reconstrução da série baseado em cada autovetor U_i , sendo este uma decorrência do *plot* dos autovetores.

A primeira figura traça o logaritmo dos autovalores obtidos no segundo passo. O logaritmo dos autovalores auxilia na escolha das autotriplas porque a distância entre os autovalores é indicativo do comportamento que ele representa (Golyandina, Nekrutkin e Korobeynikov, 2001; Hassani e Mahmoudvand, 2018). Autovalores que indicam comportamento de tendência geralmente possuem os maiores valores do gráfico e se destacam dos demais que vêm na sequência. Já autovalores que representam os comportamentos harmônicos usualmente estão traçados próximos um ao outro, apresentando pequenas quedas entre si (Hassani e Mahmoudvand, 2018). No que diz respeito a autovalores que apresentam comportamento ruidoso, Golyandina, Nekrutkin e Korobeynikov (2001) ressaltaram que uma série ruidosa produz uma sequência de autovalores que decresce lentamente, logo, para sua identificação é necessário procurar quebras entre os autovalores seguido de um platô dos próximos autovalores traçados.

Já a figura da matriz de w-correlação fornece uma informação visual da separabilidade dos componentes obtidos no segundo passo. As cores da matriz indicam valores que estão entre 0 e 1, em que a cor branca representa uma correlação 0 entre os componentes e a cor preta representa uma correlação 1 entre estes – uma escala gradual de cor cinza representa os valores de correlação entre 0 e 1. A matriz de w-correlação é útil para identificar o agrupamento dos componentes em um mesmo grupo, portanto, autotriplas que estejam com uma forte correlação entre si – formando um “quadrado” preto – devem ser colocadas no mesmo grupo no passo da reconstrução. Utilizando essa informação, a matriz se torna útil para separar os componentes que representam tendência e sazonalidade em grupos diferentes, visto que se espera que estes estariam bem separados entre si (Golyandina, Korobeynikov e Zhigljavsky, 2010). Golyandina, Korobeynikov e Zhigljavsky (2010) também destacaram que, a partir do momento que a matriz apresenta um grande bloco com muitas correlações em escala cinza, então é esperado que esses componentes estejam misturados e estão sendo produzidos pelos ruídos.

No que diz respeito às figuras dos autovetores, estas são produzidas a partir dos autovetores traçados sozinhos ou em pares. Golyandina, Korobeynikov e Zhigljavsky (2010) ressaltaram que autovetores que apresentam pouca variação devem ser incluídos no grupo de tendência, enquanto aqueles que apresentam um comportamento senoidal com frequência específica podem representar a sazonalidade. Para autovetores que apresentam ondas de elevada frequência (destoantes em relação aos autovetores com comportamento harmônico), estes provavelmente representam um comportamento ruidoso. O Rssa também fornece nas figuras de autovetores a porcentagem de contribuição de cada autovetor, e conseqüentemente

autotripla, para a variância total do modelo. Tendo em vista que os autovetores obtidos no segundo passo estão em ordem decrescente, então a contribuição de cada para a variância total também segue esta mesma ordem.

A figura de pares de autovetores auxilia na decisão de incluir estes autovetores harmônicos nos grupos de reconstrução ou não, visto que, caso a figura 2D dos autovetores apresente um polígono, então é possível confirmar o comportamento de sazonalidade destes autovetores (Golyandina, Korobeynikov e Zhigljavsky, 2010). Com isso, autovetores ruidosos não formarão um polígono identificável e, portanto, autovetores de alta-frequência podem ser identificados como ruidosos através da figura dos pares de autovetores.

3.5 BASE DE DADOS

A base de dados do presente trabalho pode ser dividida em duas partes: a primeira dedicada a obter uma mensuração da NAIRU, sendo utilizada nos modelos univariado e multivariado, e a segunda destinada a avaliar o comportamento da NAIRU no acompanhamento da inflação e realizar o teste das mensurações obtidas.

A primeira parte é composta por duas séries: taxa de desemprego (u_t) e inflação dos salários (π_t). A série da taxa de desemprego se refere à taxa de desocupação (%) das pessoas de 14 anos ou mais e foi retirada diretamente da Pesquisa Nacional por Amostra de Domicílios Contínua (PNAD Contínua), publicada pelo Instituto Brasileiro de Geografia e Estatística (IBGE, 2023b) utilizando o Sistema IBGE de Recuperação Automática – SIDRA (IBGE, 2023d), já a série de inflação dos salários foi calculada como a variação média (%) do rendimento médio nominal. A série de rendimentos utilizada para o cálculo da inflação dos salários também foi obtida a partir da PNAD Contínua e corresponde ao rendimento médio nominal de todos os trabalhos, habitualmente recebido por mês, por pessoas de 14 anos ou mais ocupadas na semana de referência da pesquisa (IBGE, 2023b). Ambas as séries possuem periodicidade trimestral se estendem do 1T2012 até o 3T2023, compreendendo 47 observações.

Apesar da PNAD Contínua ter tido início definitivo no primeiro trimestre de 2012 (IBGE, 2023b), no modelo multivariado optou-se pelo início das séries apenas no segundo trimestre de 2012 por causa da preferência em manter séries de tamanhos iguais na aplicação

do MSSA. Isso porque, ao calcular a variação média dos rendimentos para a série de inflação dos salários, a primeira observação desta (1T2012) foi perdida⁶⁵.

Quanto à segunda parte da base, esta é utilizada para discutir, no capítulo 5, as mensurações obtidas da NAIRU, e engloba: a inflação de preços (IPCA), o IPCA – comercializáveis, o IPCA – Livres e alguns núcleos selecionados. Todas essas séries compreendem o mesmo período dos dados obtidos a partir da PNAD (1T2012 até o 3T2023⁶⁶). O índice de inflação coletado foi a variação percentual do IPCA acumulado no trimestre e acumulado em 4 trimestres (IBGE, 2023a). Já a série de comercializáveis, de livres e o dos núcleos foram obtidos a partir do Sistema Gerenciador de Séries Temporais do Banco Central do Brasil (BCB, 2023), e calculadas as taxas de variação para os acumulados no trimestre e em 4 trimestres. O Quadro 2 apresenta quais foram os núcleos selecionados, além de uma descrição de como estes núcleos, o IPCA- comercializáveis e o IPCA – Livres se diferenciam do índice cheio.

Quadro 2 - Descrição sucinta das séries utilizadas para teste da NAIRU

Série	Descrição
IPCA – Comercializáveis	Categoria de itens cujo preço é mais sensível às variações do mercado externo.
IPCA – Livres	Exclui os itens administrados.
Núcleo EX0	Núcleo de exclusão. Retira os preços administrados e a alimentação no domicílio.
Núcleo EX1	Núcleo de exclusão. Retira os 12 itens que recorrentemente são os mais voláteis.
Núcleo MA	Núcleo de média aparada. Corte simétrico (20% em cada cauda) sem considerar os itens suavizados.
Núcleo MS	Núcleo de média aparada. Corte simétrico (20% em cada cauda) considerando os itens suavizados.
Núcleo DP	Núcleo de dupla ponderação. Os pesos do núcleo se fundamentam na volatilidade relativa de 48 meses e nos pesos originais do IPCA.

Fonte: Elaboração Própria com base no conteúdo de Martinez e Cerqueira (2013) (IPCA – comercializáveis e livres), e Silva Filho e Figueiredo (2014) (núcleos).

Por fim, quanto à operacionalização desses modelos, todos foram realizados através do *software* R (R Foundation, 2023). O modelo de componentes não observados foi aplicado utilizando o pacote *rucm* de Chowdhury (2023) e o filtro HP foi empregado a partir do pacote *mFilter* de Balilar (2023). Já operacionalização do SSA e MSSA foi feita usando o pacote *Rssa*

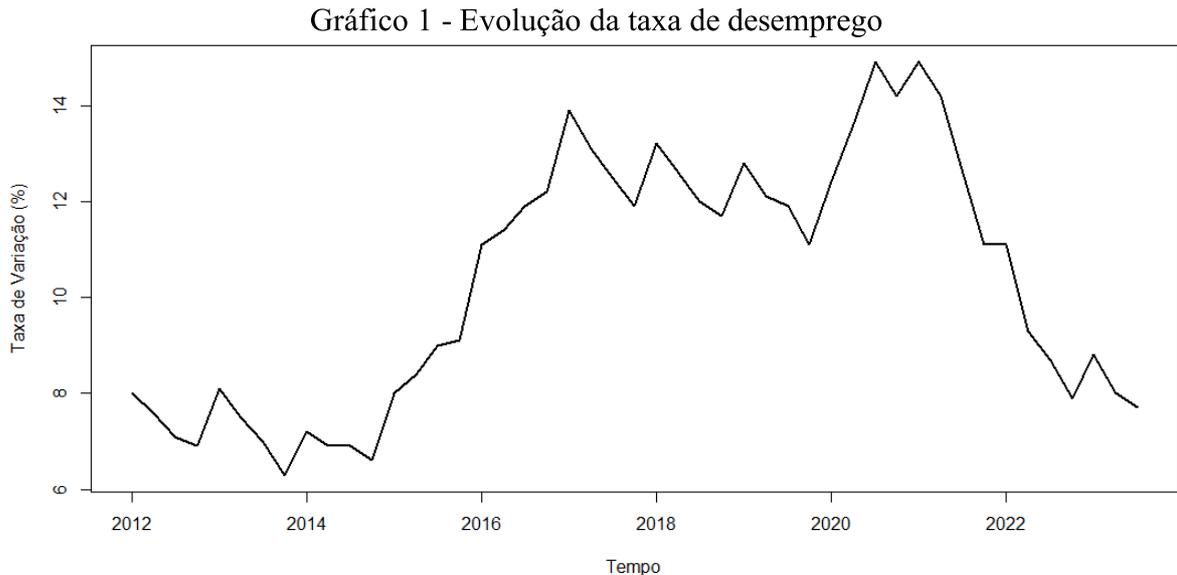
⁶⁵ Outra escolha feita foi a de utilizar apenas os dados do desemprego fornecidos através da PNAD Contínua e não incorporar os dados Pesquisa Mensal do Emprego (PME), por causa de diferenças metodológicas no cálculo das variáveis. A PME foi descontinuada em março de 2016 e foi substituída pela PNAD contínua (IBGE, 2023b).

⁶⁶ Para o modelo multivariado, também foi retirada a primeira observação da série do IPCA e dos núcleos, de forma que todas compreendessem o mesmo período.

desenvolvido por Korobeynikov *et al.* (2023), pacote que reúne diversos tipos de modelo da família SSA - além de fornecer as figuras e gráficos necessários para realizar a análise gráfica dos modelos.

4 RESULTADOS

Este capítulo está dividido em quatro partes e apresenta as mensurações das NAIRUs obtidas com os quatro modelos propostos: Componentes Não Observados, filtro Hodrick-Prescott, e as versões univariado e multivariado do *Singular Spectrum Analysis*. O Gráfico 1 expõe a evolução da taxa de desemprego, série essa que foi utilizada como base em todos os modelos.



Fonte: Elaboração própria.

Assim sendo, a seção 4.1 relata os resultados do modelo de componentes não observados; a seção 4.2 apresenta a mensuração da NAIRU feita via filtro HP; a seção 4.3 exibe a mensuração da NAIRU feita através do SSA, além do processo de decomposição e reconstrução da série; a seção 4.4, por fim, expõe a mensuração da NAIRU feita através de um modelo multivariado.

4.1 NAIRU ESTIMADA UTILIZANDO O UCM

Conforme ressaltado na seção 3.1, o modelo UCM escolhido para estimar a NAIRU foi um BSM univariado ($u_t = \mu_t + \gamma_t + \varepsilon_t$) composto por um componente de tendência (μ_t) (Equação 3.2) que segue um *random walk* com *drift* (logo, $\sigma_\zeta^2 = 0$ e β_0 constante), por um termo de sazonalidade (γ_t) (Equação 3.3) e pelo termo de ruído (ε_t):

$$\mu_t = \mu_{t-1} + \beta_{t-1} + \eta_t, \quad \eta_t \sim NID(0, \sigma_\eta^2) \quad (3.2)$$

$$\begin{aligned}\beta_t &= \beta_{t-1} + \zeta_t, & \zeta_t &\sim NID(0, \sigma_\zeta^2) \\ \gamma_t &= - \sum_{i=1}^{s-1} \gamma_{t-i} + \omega_t, & \omega_t &\sim WN(0, \sigma_\omega^2)\end{aligned}\quad (3.3)$$

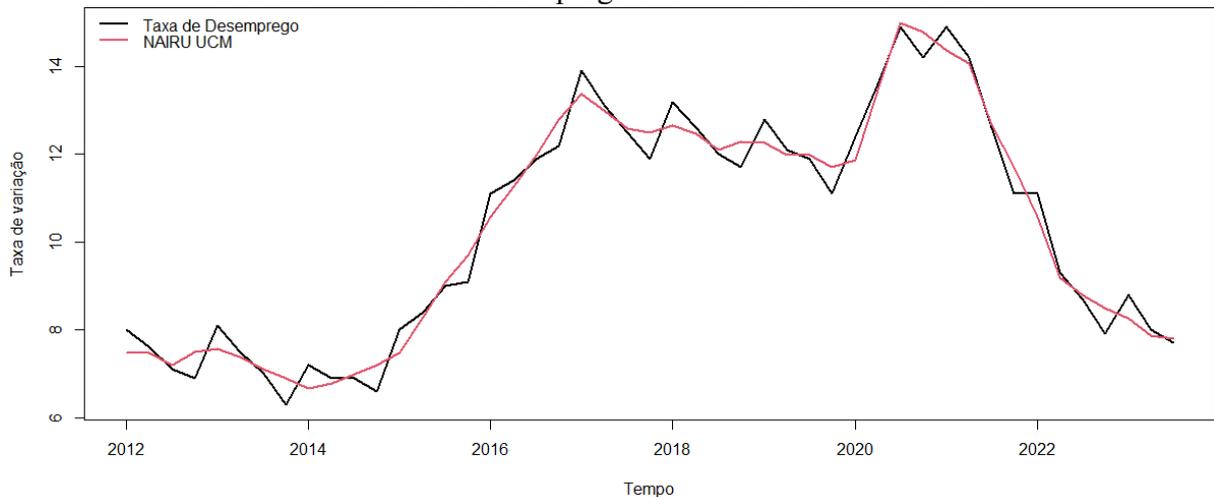
Antes da estimação do modelo, Harvey e Koopman (2009) e Pelagatti (2016) recomendaram um teste para verificar se os dados possuem uma distribuição aproximada da distribuição normal, de acordo com a premissa o estado de espaços gaussiano⁶⁷. Assim, o teste escolhido foi o teste de adequação de Jarque-Bera de Cromwell, Labys e Terraza (1994) que verifica se a série amostral escolhida possui conjuntamente uma assimetria e curtose condizentes com uma distribuição normal. Sob a hipótese nula (H_0) de normalidade, com o p – $valor = 0,1481$ resultante do teste da série de desemprego não foi possível rejeitar H_0 . Portanto, os dados possuem uma distribuição aproximadamente normal.

Passando para a estimação do modelo, o primeiro ponto que deve ser ressaltado é o resultado da estimação do termo de sazonalidade e de sua variância (σ_ω^2). Isso porque, apesar de programar a estimação da sazonalidade estocástica, o resultado obtido foi um termo sazonal com um padrão fixo, logo, $\sigma_\omega^2 = 0$. Conforme Harvey e Koopman (2009), o termo é dado por $\gamma_t = \sum_{j=1}^s \gamma_j Z_{jt}$.

No que diz respeito ao componente de interesse do modelo, tendo em vista que a tendência segue um comportamento de *random walk* com *drift*, a variância do intercepto (σ_ζ^2) foi fixada em zero e a variância do termo de nível (σ_η^2) ficou igual a 0.417 como resultado da estimação do algoritmo. A decomposição do componente de tendência pode ser visualizada no Gráfico 2 - que exhibe a série de desemprego junto à NAIRU estimada via UCM.

⁶⁷ De acordo com Harvey e Koopman (2009), caso os dados não possuam uma distribuição (aproximada) gaussiana, é possível realizar a estimação linear via mínimos quadrados médios.

Gráfico 2 - Taxa de desemprego e NAIRU estimada via UCM

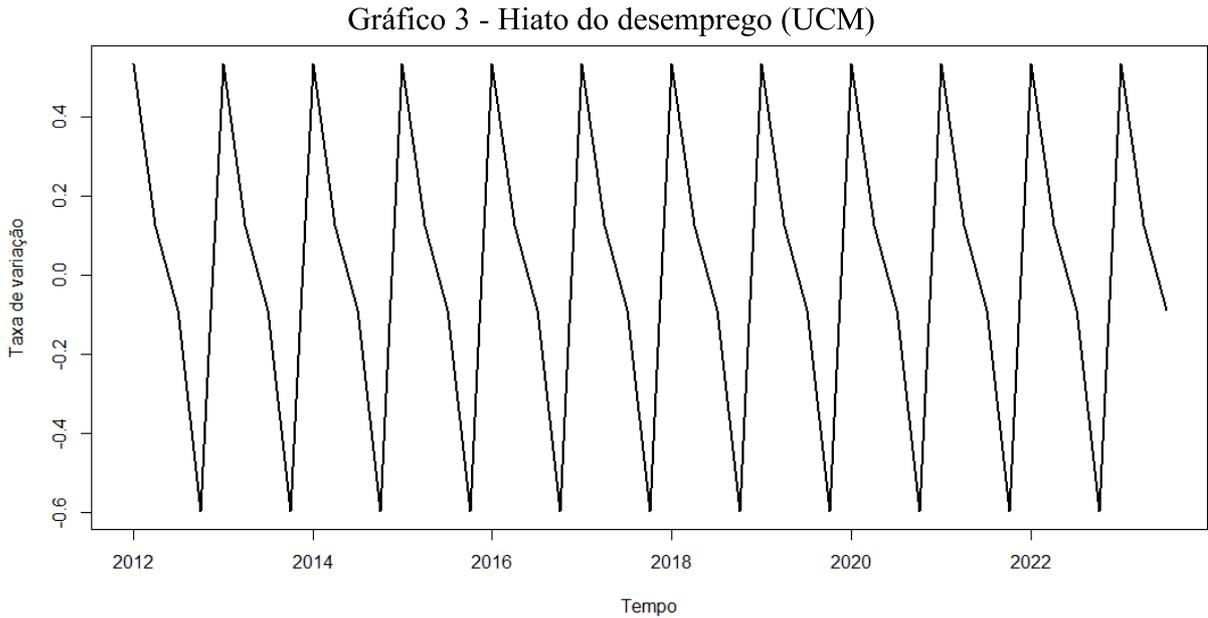


Fonte: Elaboração própria com base nos dados da PNAD contínua

A NAIRU média ao longo das 47 observações correspondeu a 10,32%, sendo que seu pico foi registrado no 3T2020 com 14,99% - superando por pouco os 14,9% registrados no mesmo período pela PNAD Contínua. O ponto mais baixo da série ocorreu no 1T2014 com 6,67%, menor que os 7,2% do desemprego corrente no mesmo período. Ademais, após 2014, a NAIRU obtida acompanhou o comportamento de crescimento do desemprego, vindo a apresentar redução somente após o 1T2017 (13,37%).

O Gráfico 2 também evidenciou que a NAIRU estimada via UCM alternou periodicamente com o desemprego observável, sendo que, ao comparar as séries, verificou-se que esse período de alternância ocorreu a cada dois trimestres por todo período amostral. Com isso, o hiato do desemprego – obtido a partir da diferença entre a série original e sua tendência mensurada – apresentou um comportamento periódico característico (Gráfico 3).

No que diz respeito ao último termo do modelo BSM, o resultado do filtro de Kalman para a variância do termo irregular foi próxima de zero – resultado responsável pela proximidade do hiato do desemprego com os valores do componente sazonal. Considerando o resultado dos resíduos, a subseção 4.1.1 realiza os diagnósticos propostos por Harvey e Koopman (1992) e por Pelagatti (2016).



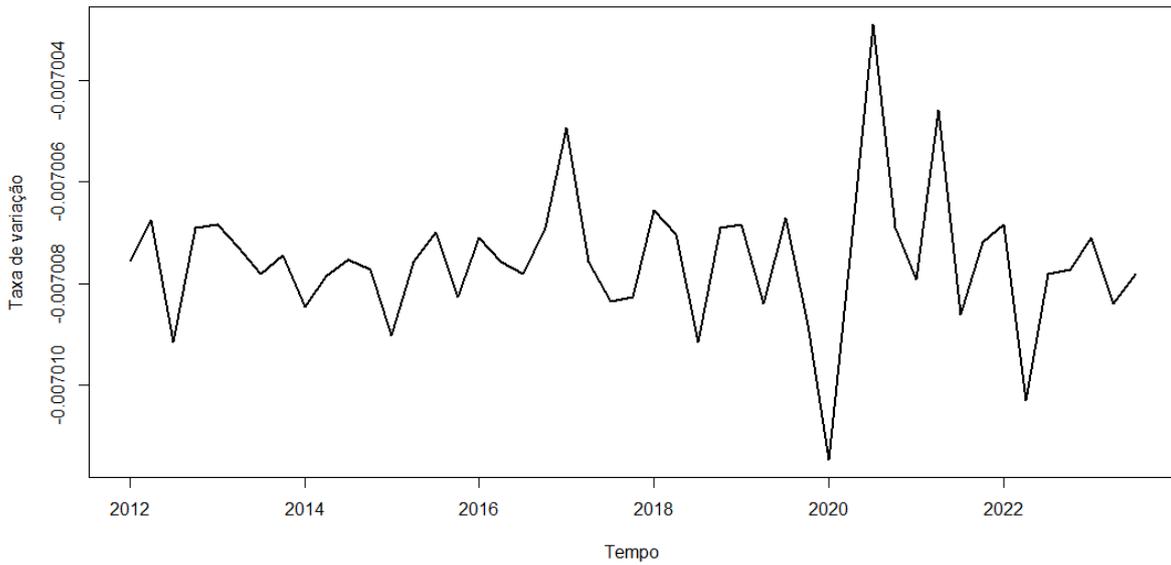
4.1.1 Diagnóstico do componente irregular (ε_t)

De acordo com Harvey e Koopman (1992) e Pelagatti (2016), o diagnóstico dos resíduos se dá através da verificação da presença de autocorrelação serial e da distribuição do termo de erro. Com isso, foram analisados os seguintes resultados: função de autocorrelação (ACF); teste de Box-Pierce; histograma e densidade dos resíduos; e teste de normalidade Jarque-Bera. O Gráfico 4 exibe o *plot* termo de erro.

A função de autocorrelação (Gráfico 5) indicou que o termo de erro do modelo se caracterizou como um ruído branco, visto que seus valores permaneceram dentro do intervalo da função. Já o teste de Box-Pierce (Box e Pierce, 1970) avalia se a série analisada é composta por valores aleatórios, ou seja, se os resíduos são ruído branco, com isso, o teste verifica estatisticamente a presença, ou não, de autocorrelação serial. Sob H_0 de independência dos valores testados, o *p* – valor resultante do teste foi de, aproximadamente, 0,8676, com isso, não foi possível rejeitar a hipótese nula de que os resíduos seguem um ruído branco⁶⁸.

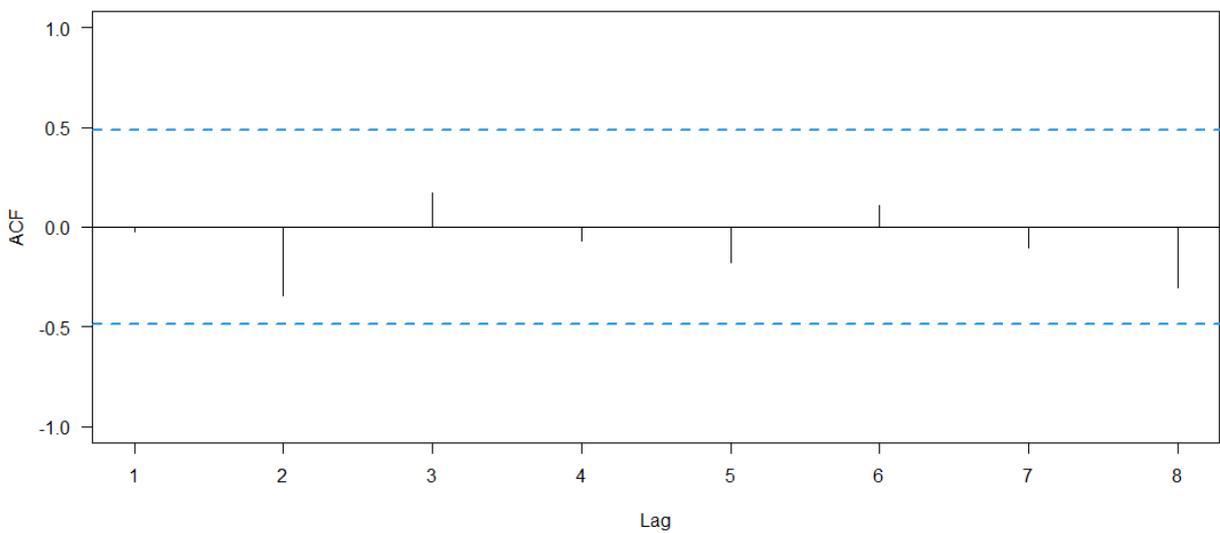
⁶⁸ Realizando o teste para até 8 defasagens (*lags*), não foi possível rejeitar hipótese nula a um nível de 5% de significância.

Gráfico 4 - Termo irregular do modelo UCM



Fonte: Elaboração própria com base nos dados da PNAD contínua

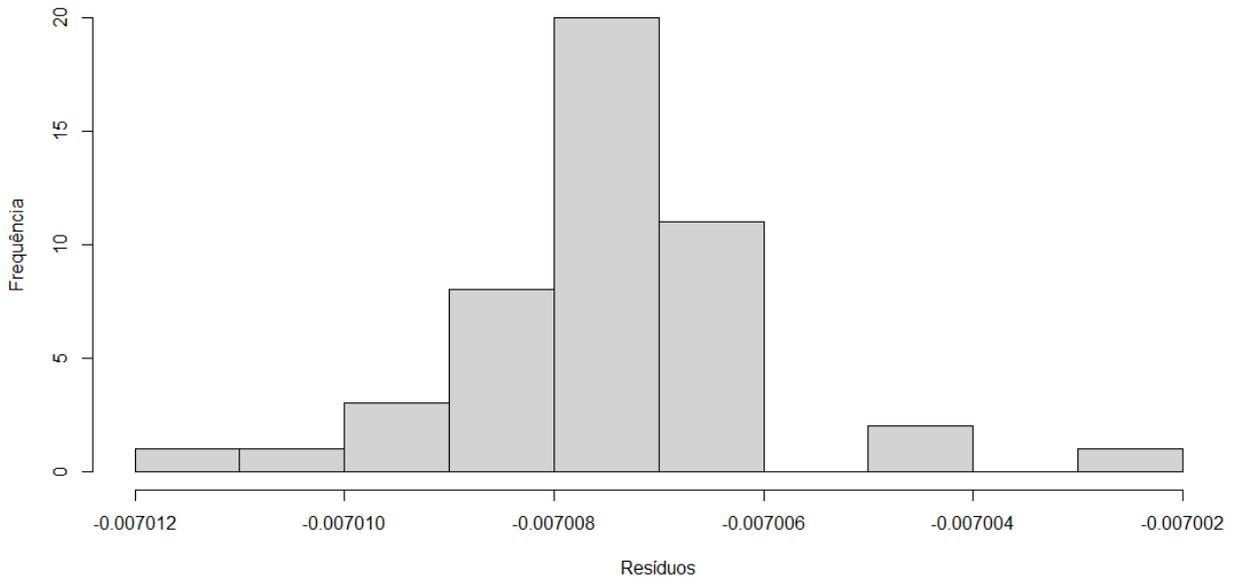
Gráfico 5 - Função de autocorrelação dos resíduos



Fonte: Elaboração própria com base nos dados da PNAD contínua

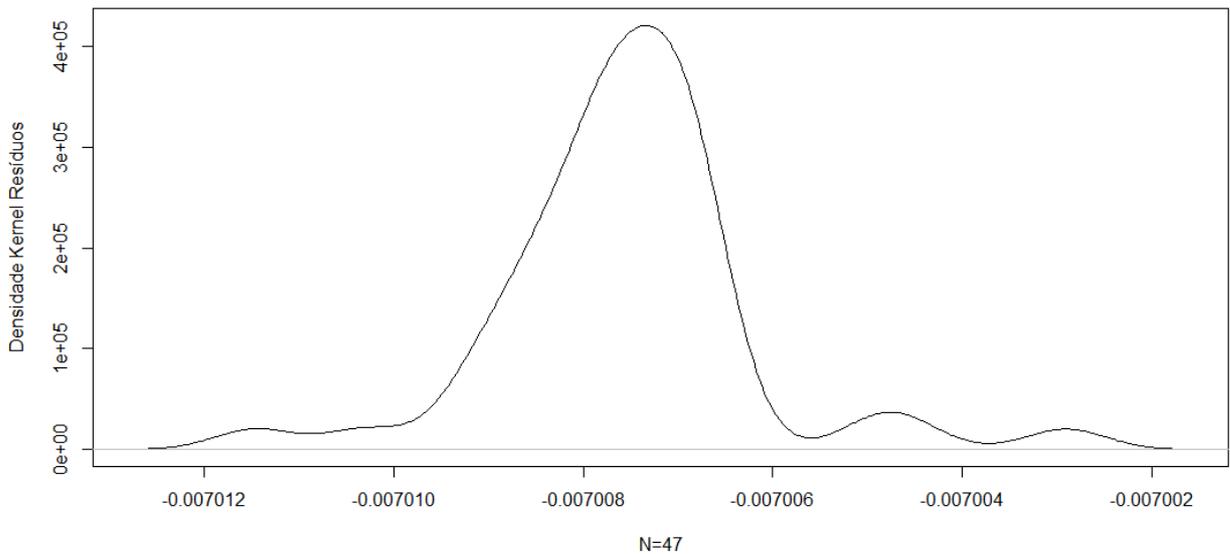
Já os gráficos 6 e 7 apresentam, respectivamente, o histograma e a densidade dos resíduos. Com um $p - valor = 3,29 * 10^{-6}$, a hipótese nula do teste de Jarque-Bera de que a distribuição dos resíduos se aproxima da distribuição normal padrão foi rejeitada.

Gráfico 6 - Histograma dos resíduos



Fonte: Elaboração própria com base nos dados da PNAD contínua

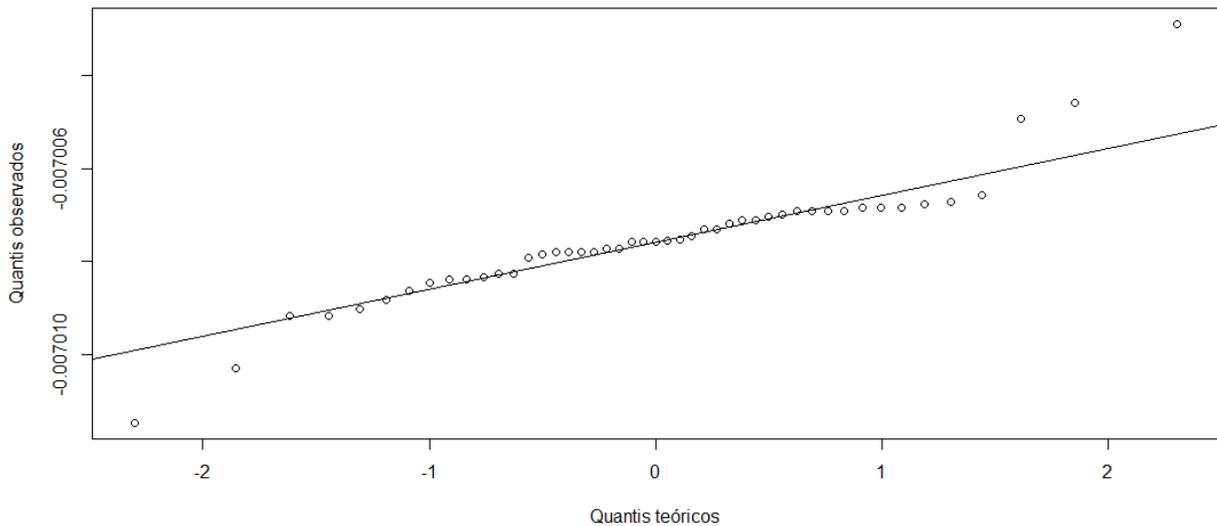
Gráfico 7 - Densidade kernel dos resíduos



Fonte: Elaboração própria com base nos dados da PNAD contínua

Portanto, o diagnóstico dos resíduos do modelo evidenciou um termo irregular aleatório, porém, com distribuição distante do normal padrão. Tendo em vista que a série possui uma distribuição que se assemelha à gaussiana, Pelagatti (2016) elucidou que esse distanciamento pode ter causa na presença de *outliers* na série trabalhada pelo pesquisador. Através do Gráfico 4 é possível verificar a presença de *outliers* para os anos entre 2020 e 2022 – anos afetados pela pandemia de covid-19. Ademais, o QQ-plot dos resíduos (Gráfico 8) exhibe a presença desses *outliers* que distanciaram os resíduos de uma distribuição normal.

Gráfico 8 - QQ plot dos resíduos



Fonte: Elaboração própria com base nos dados da PNAD contínua

4.2 NAIRU OBTIDA UTILIZANDO O FILTRO HP

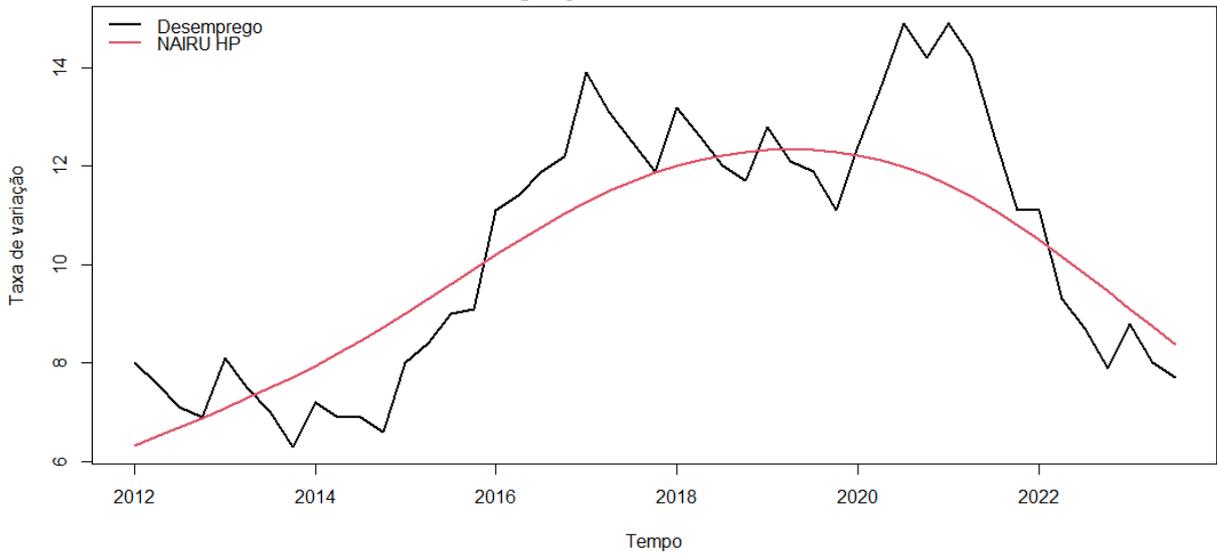
Conforme exposto por Hodrick e Prescott (1997), o primeiro passo consistiu em tratar a série sazonalmente para que o filtro fosse aplicado⁶⁹⁷⁰. Feito isso, parâmetro de suavização escolhido correspondeu a $\lambda = 1600$ – conforme recomendado por Hodrick e Prescott (1997) para dados trimestrais. O Gráfico 9 apresenta o resultado da decomposição da tendência pelo filtro HP frente a série original.

Para todo o período amostral a NAIRU média pelo filtro HP equivaleu a 10,06%, sendo o ponto mais alto no 2T2019 (12,34%) e o ponto mais baixo no início da série (6,31%). O caráter de suavização do filtro HP apresentou uma NAIRU diferente da que foi vista com a metodologia UCM e da que será apresentada na metodologia SSA. Aqui, a NAIRU não alternou em curtos períodos com a taxa de desemprego, visto que entre o 3T2013 até o 4T2015 (10 trimestres) a taxa de desemprego se situou abaixo da NAIRU – o que indicaria uma pressão para aumento da inflação. Da mesma forma, o movimento oposto ocorre logo após esse período e, entre 1T2016 até o 2T2018 (10 trimestres) a taxa de desemprego permaneceu acima da NAIRU.

⁶⁹ O tratamento sazonal foi feito no *software Rstudio* utilizando o pacote *seasonal* (Sax e Eddelbuettel, 2023). O pacote aplica o filtro X-13 para realizar o ajuste sazonal da série. Para mais detalhes do funcionamento do filtro, ver Sax e Eddelbuettel (2018).

⁷⁰ Ainda no que diz respeito ao tratamento sazonal, foram analisados os resultados para a série tratada sazonalmente e sem tratamento. Para os dois modelos, os resultados foram semelhantes.

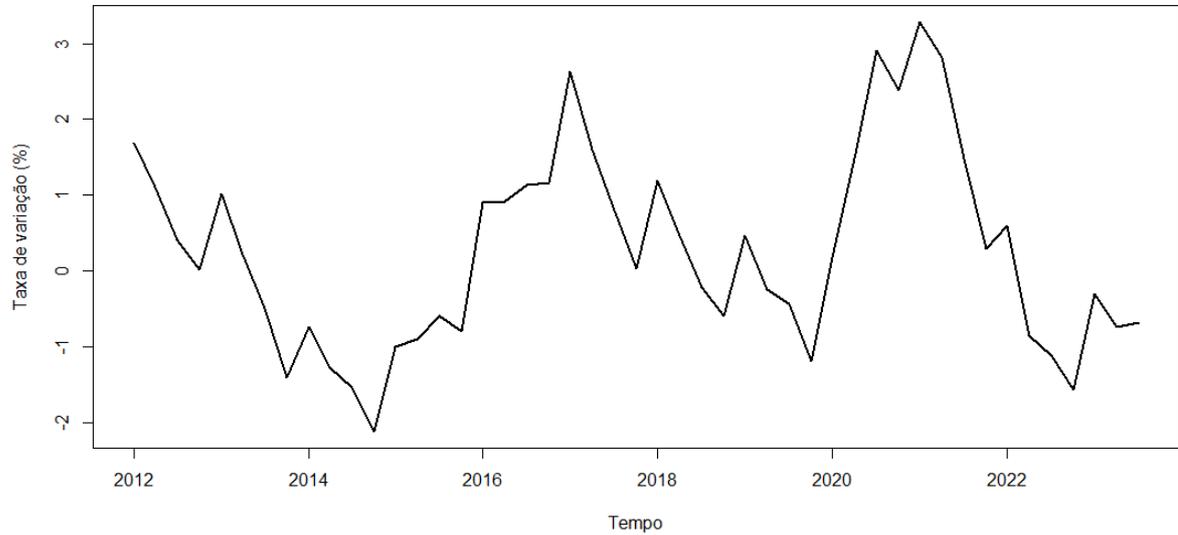
Gráfico 9 - Taxa de desemprego e NAIRU mensurada via filtro HP



Fonte: Elaboração própria com base nos dados da PNAD contínua

Portanto, a NAIRU mensurada pelo filtro HP proporcionou um hiato diferente – com oscilações maiores que chegaram até os -2,11% (4T2014) no vale da série e aos 3,28% (1T2021) em seu pico (Gráfico 10).

Gráfico 10 - Hiato do desemprego (HP)



Fonte: Elaboração própria com base nos dados da PNAD contínua

4.3 NAIRU MENSURADA A PARTIR DO SSA

4.3.1 Etapa da decomposição e análise das autotriplas do modelo SSA univariado

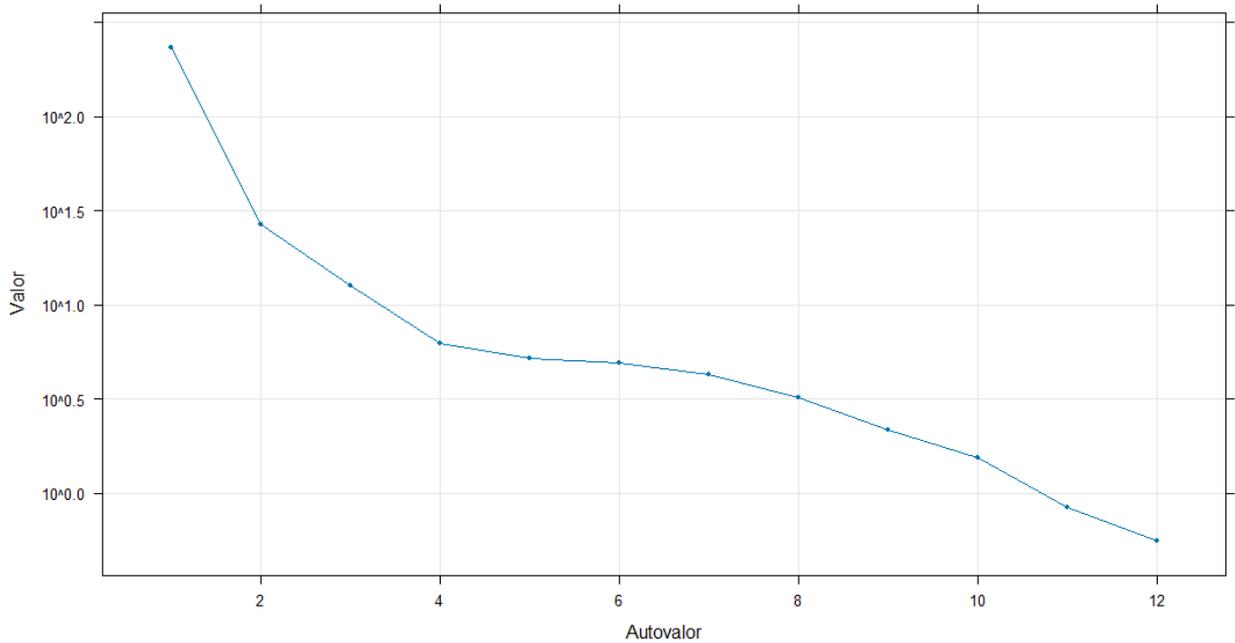
Tendo em vista que o SSA é um método não paramétrico, a série de desemprego foi incorporada ao modelo em nível – sem passar por modificação alguma, como normalização, primeira diferença ou transformação logarítmica. Com isso, a aplicação do modelo já se iniciou na decomposição da série com a escolha do tamanho da janela (L), parâmetro este que define toda a etapa de decomposição.

Para o SSA univariado, cinco janelas foram testadas: $L = 8$; $L = 12$; $L = 16$; $L = 23$ (próximo da metade do tamanho da série), sendo escolhido o tamanho $L = 12$ – tamanho o qual forneceu melhor separabilidade entre os componentes da etapa de decomposição. De acordo com Golyandina et al. (2015), um tamanho de janela menor pode favorecer séries mais curtas, oferecendo, assim, melhor separabilidade entre os componentes – caso que foi observado na aplicação $L = 12$ em comparação com as demais.

Após a aplicação do modelo com o tamanho de janela escolhido, foi necessário realizar a análise gráfica das figuras descritas na subseção 3.4.7 – figuras que também compuseram a análise do modelo multivariado. Portanto, a análise gráfica dos componentes permitiu identificar, a partir da correspondência e separabilidade destes componentes, o sinal da série e decidir quais autotriplas seriam selecionadas para a etapa de reconstrução.

A Figura 1 exibe o logaritmo dos autovalores e de início já foi possível identificar que os 3 primeiros poderiam corresponder ao componente de tendência da série, isso porque estes exibiram quedas agudas e se distanciaram em relação aos autovalores seguintes. Já os autovalores de 4 a 8, apresentaram quedas menores – se dispoendo em pares - estando próximos um ao outro e, portanto, indicando um comportamento sazonal. Após o oitavo autovalor, voltaram a ocorrer quedas abruptas em relação aos autovalores seguintes e, mesmo que um platô não se apresente na Figura 1, esse comportamento para os últimos autovalores da janela sinalizou dois pontos principais: as autotriplas de 9 a 12 contribuem pouco, ou nem contribuem, para explicar a variância total das séries, e que as autotriplas de 9 a 12 estejam apresentando comportamento ruidoso.

Figura 1 - Log dos autovalores de 1 a 12 (SSA)

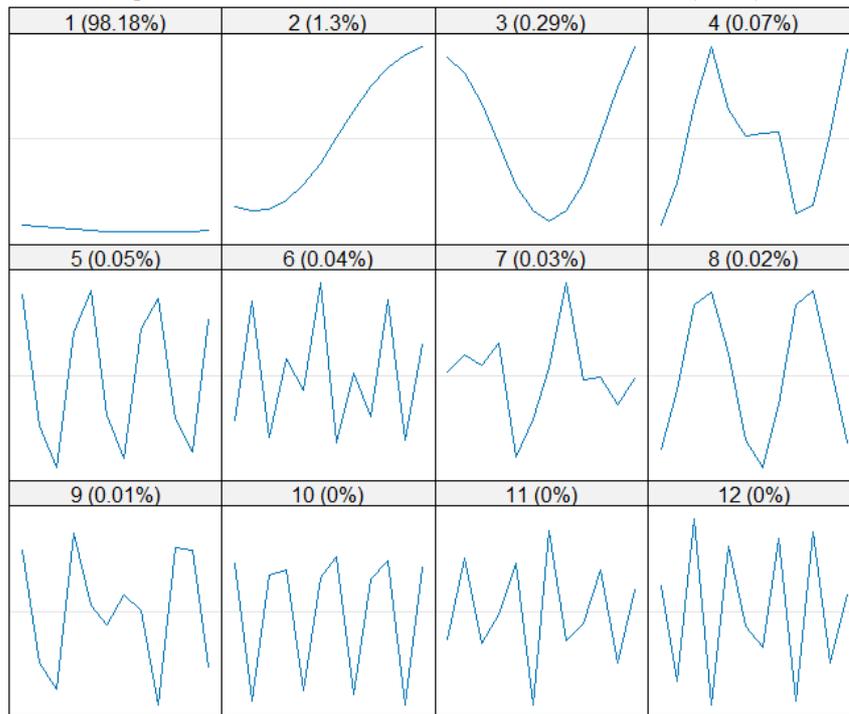


Fonte: Elaboração própria.

Assim como na Figura 1, a figura que apresenta o traçado dos autovetores (Figura 2) indicou o comportamento de tendência para os autovetores 1 e 2 – sendo o primeiro autovetor responsável por 98,18% da variância da série. No que diz respeito ao terceiro autovetor, somente com a Figura 2, não foi possível determinar se este seria incluído na reconstrução da tendência ou sazonalidade, visto que seu traçado apresentou indícios de uma mudança de período. Portanto, principalmente para a terceira autotripla resultante da etapa de decomposição, a análise conjunta das figuras se tornou ainda mais relevante para a reconstrução do modelo.

Quanto aos comportamentos de sazonalidade e ruído, o primeiro pôde ser observado na Figura 2 nos autovetores de 4 a 8 dado seu comportamento senoidal com mudanças de período em frequências menores. Já o segundo correspondeu aos autovetores de 9 a 12 que, além de já apresentarem uma representação ínfima da variância da série, exibiram ondas de maior frequência.

Figura 2 - Traçado dos autovetores de 1 a 12 (SSA)

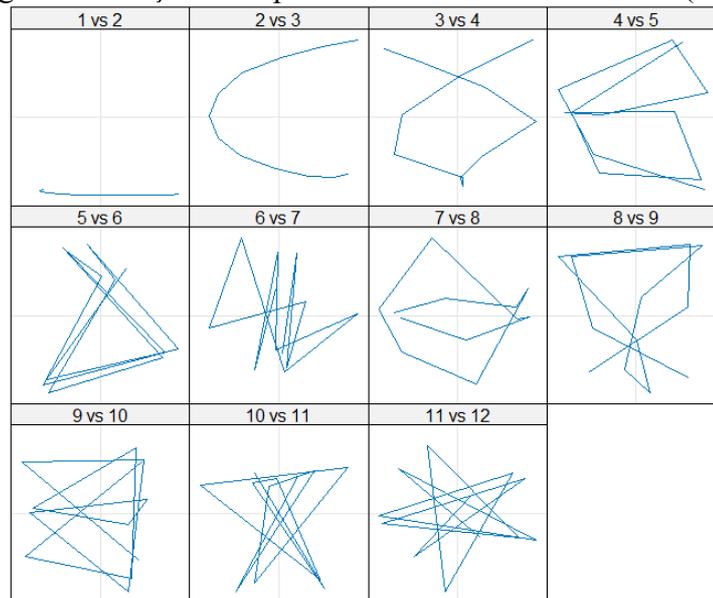


Fonte: Elaboração própria.

A Figura 3, da mesma forma que nas figuras anteriores, também indicou o comportamento de tendência para as autotriplas 1 e 2, dado que os pares “1 vs 2” e “2 vs 3” não formaram polígonos. Já a terceira autotripla apresentou evidências tanto de tendência quanto de sazonalidade, em virtude da não formação de polígono no par “2 vs 3” e na formação aproximada de um polígono convexo no par “3 vs 4” – respectivamente.

A formação aproximada de outros polígonos convexos de três e cinco lados pôde ser verificada do par “4 vs 5” ao par “7 vs 8”, manifestando um comportamento sazonal das respectivas autotriplas. Contudo, é necessário ressaltar que dentro deste intervalo os pares “4 vs 5” e “6 vs 7” não formam polígonos claros, de acordo com Golyandina, Nekrutkin e Zhigljavsky (2001), esse comportamento pode indicar que tais autotriplas estão capturando sazonalidades de diferentes períodos. Quanto aos últimos três pares da Figura 3, estes não apresentaram polígonos claros, reforçando a suspeita de comportamento ruidoso evidenciado pelos autovetores 9 a 12 da Figura 2.

Figura 3 - Traçado dos pares dos autovetores de 1 a 12 (SSA)

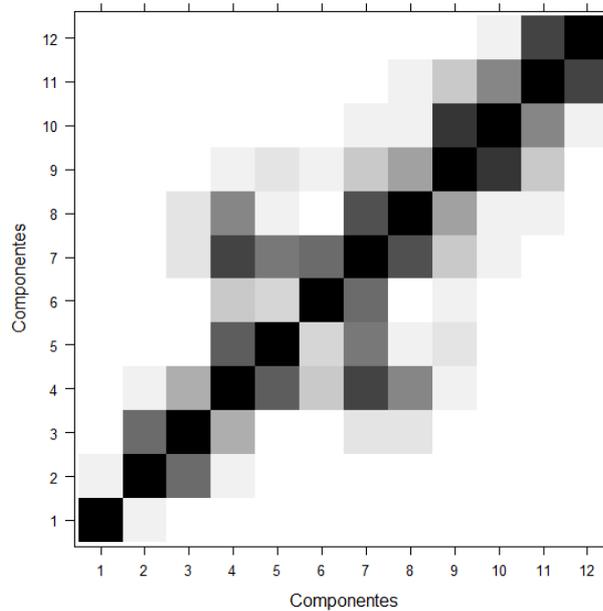


Fonte: Elaboração própria.

De acordo com Golyandina, Korobeynikov e Zhigljavsky (2010), a separabilidade observada nas primeiras autotriplas da matriz de w-correlação (Figura 4) é um indício do comportamento de tendência da série. Esse comportamento foi observado nas autotriplas 1 e 2 que são bem separadas das demais, visto que a primeira autotripla não manifestou correlação com as outras, e a segunda apenas uma correlação maior com a terceira. Até mesmo a terceira autotripla se encaixou como comportamento de tendência na Figura 4 por uma correlação maior com o segundo componente do que com o quarto, e pela separabilidade com os demais.

No que diz respeito às autotriplas de 4 a 8, estas apresentaram maior correlação conforme os pares identificados na Figura 3, ademais, apontaram alguma correlação em certo grau com o restante das autotriplas neste intervalo formando um grande “bloco”, logo, essa é uma sinalização de que devem ser agrupadas no mesmo grupo na etapa da reconstrução (Golyandina, Nekruktin e Zhigljavsky, 2001). Com isso, as autotriplas de 4 a 8 novamente indicaram um comportamento sazonal.

Figura 4 - Matriz de w-correlação dos componentes (SSA)



Fonte: Elaboração própria.

Em relação aos componentes de 9 a 12, a matriz de w-correlação foi condizente com as informações proporcionadas pelo traçado dos pares dos autovetores. Isso porque os componentes apresentaram forte correlação conforme seus pares da Figura 3 – principalmente o 9-10 e o 11-12, indicando que devem permanecer no mesmo grupo na próxima etapa. Apesar da nona autotripla ter mostrado algum nível de correlação até a quarta autotripla, essa correlação foi próxima a zero e, de forma geral, os últimos quatro componentes formaram dois pares separados dos demais. Esse comportamento reforça a análise feita nas figuras anteriores de que o comportamento destas quatro últimas autotriplas é ruidoso.

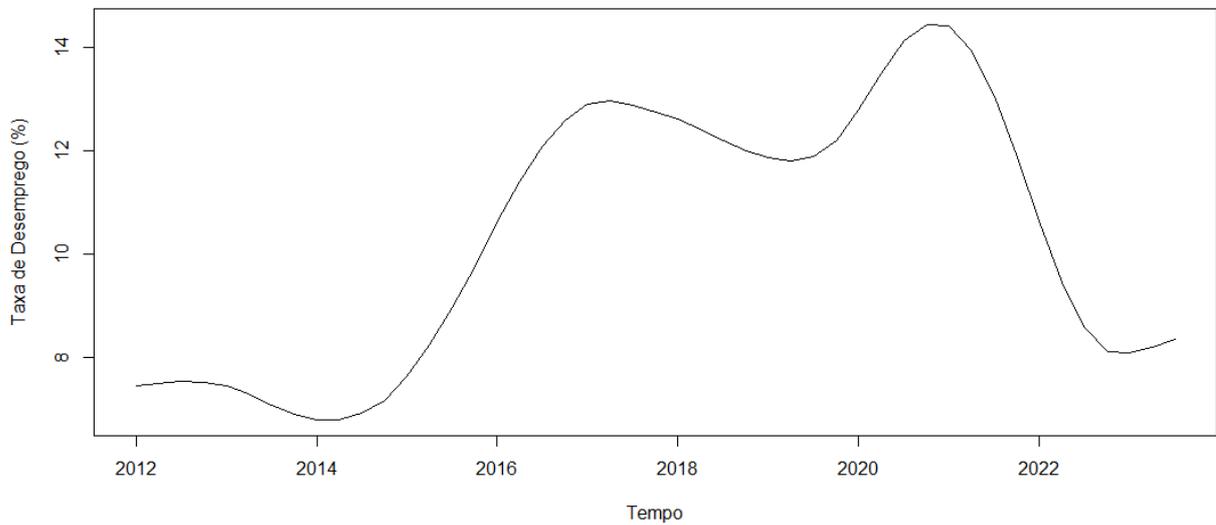
Por fim, resta esclarecer quais autotriplas entraram no passo de reconstrução da série. A partir da análise simultânea de todas as figuras apresentadas até o momento, a reconstrução da série se deu utilizando as autotriplas de 1 a 8, considerando, portanto, as autotriplas de 9 a 12 como ruidosas. O agrupamento das autotriplas de 1 a 8 em tendência e sazonalidade, e os resultados da reconstrução serão discutidos na subseção 4.3.2.

4.3.2 Etapa de reconstrução e análise dos resultados do modelo SSA univariado

Determinada a decisão de incorporar as autotriplas 1 a 8 na etapa de reconstrução do modelo, a última dúvida que permaneceu foi: em qual grupo a terceira autotripla devia ser incluída? Ao longo das análises da subseção anterior, o terceiro componente apresentou evidências de comportamento tanto para tendência quanto para sazonalidade. De acordo com Golyandina, Korobeynikov e Zhigljavsky (2010), situações nas quais a autotripla captura a tendência mesclada com a sazonalidade podem ocorrer em casos de extração de tendências de séries curtas ou extração de tendências complexas utilizando o SSA.

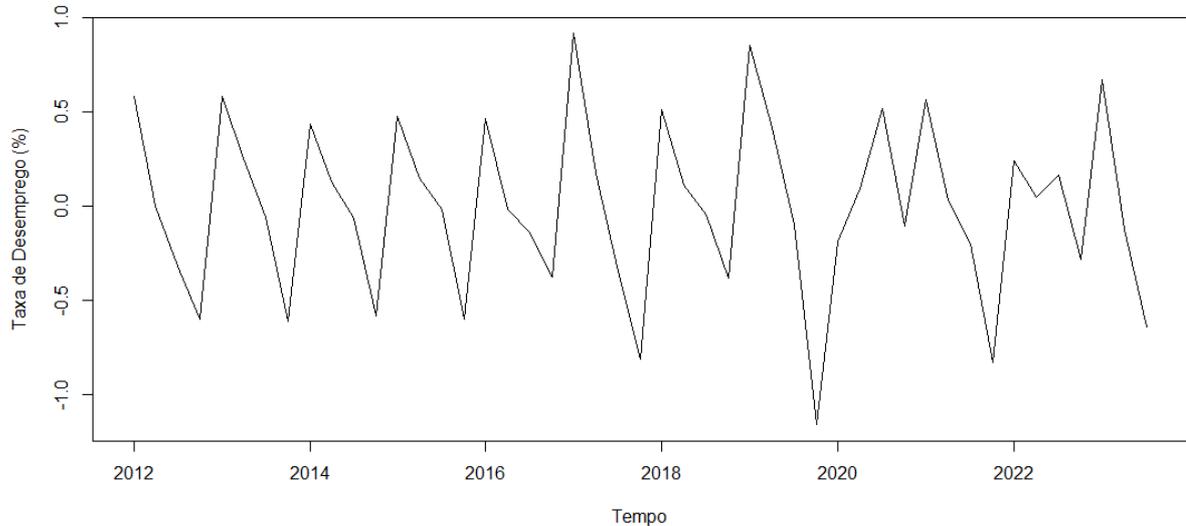
Portanto, tendo em vista esse comportamento mesclado entre tendência e sazonalidade da terceira autotripla, foram realizadas duas reconstruções: a primeira com a tendência de 1 a 3 e a sazonalidade de 4 a 8; a segunda com a tendência de 1 a 2 e a sazonalidade de 3 a 8. Contudo, considerando a reconstrução da tendência (Gráfico 11), da sazonalidade (Gráfico 12) e do ruído (Gráfico 13), a série apresentou melhores resultados com a primeira reconstrução. Então, os resultados discutidos a seguir consideraram as autotriplas de 1 a 3 como tendência, 4 a 8 como sazonalidade e 9 a 12 como ruído.

Gráfico 11 - Reconstrução da tendência para a série de taxa de desemprego (SSA)



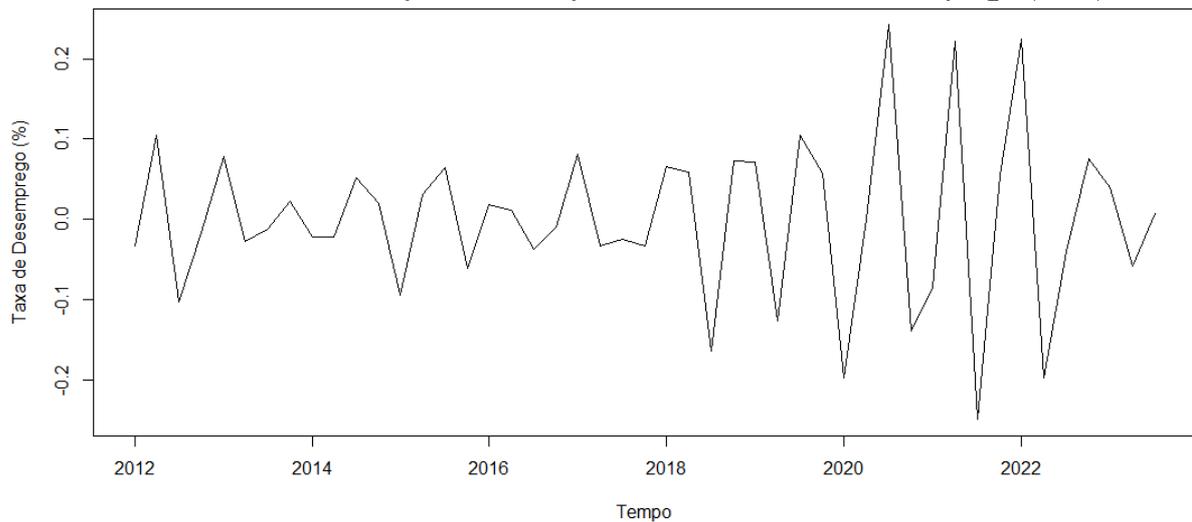
Fonte: Elaboração própria.

Gráfico 12 - Reconstrução da sazonalidade para a série de taxa de desemprego (SSA)



Fonte: Elaboração própria.

Gráfico 13 - Reconstrução do ruído para a série de taxa de desemprego (SSA)



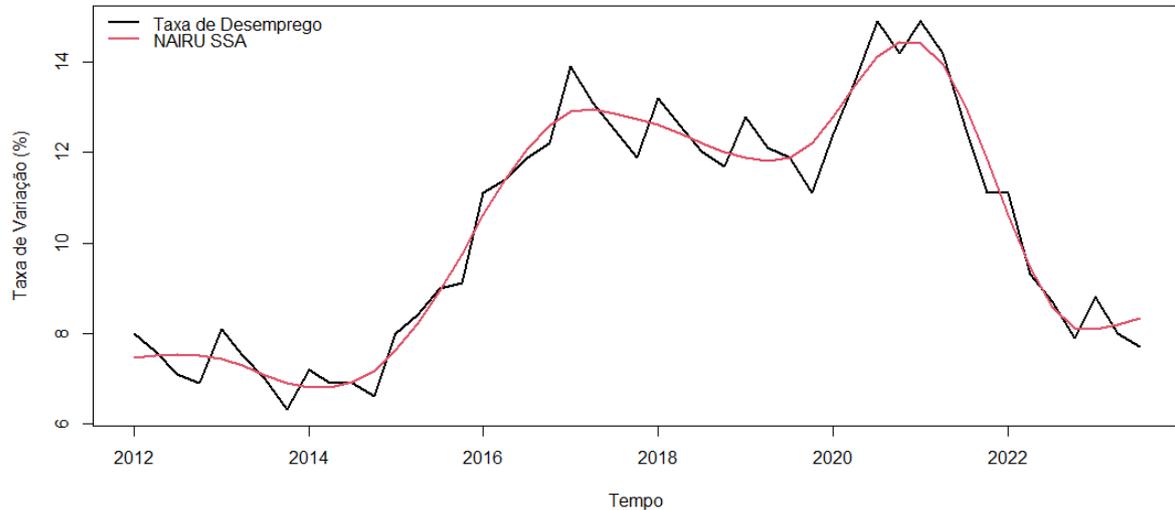
Fonte: Elaboração própria.

A partir do Gráfico 14 foi possível observar que a NAIRU mensurada através do SSA apresentou um comportamento semelhante à NAIRU do Modelo de Componentes Não Observados, isto é, uma NAIRU que evolui próxima à série observável alternando periodicamente com a taxa de desemprego.

Ainda conforme o Gráfico 14, a NAIRU SSA média entre todas as 47 observações foi equivalente a, aproximadamente, 10,33% - mesmo patamar que os estimados 10,32% da NAIRU UCM. Os pontos mais altos da NAIRU SSA se situaram após o crescimento da taxa de desemprego em 2020 no 4T2020 (14,44%) e no 1T2021 (14,41%). Já o patamar mais baixo se localizou na primeira metade de 2014, onde os dois primeiros trimestres ambos corresponderam a uma NAIRU aproximada de 6,89%. A NAIRU somente voltou a decrescer - acompanhando

a taxa de desemprego - após seu pico no 1T2021, chegando a 8,09% no 1T2023 – nível esse que não era observado desde o início de 2015.

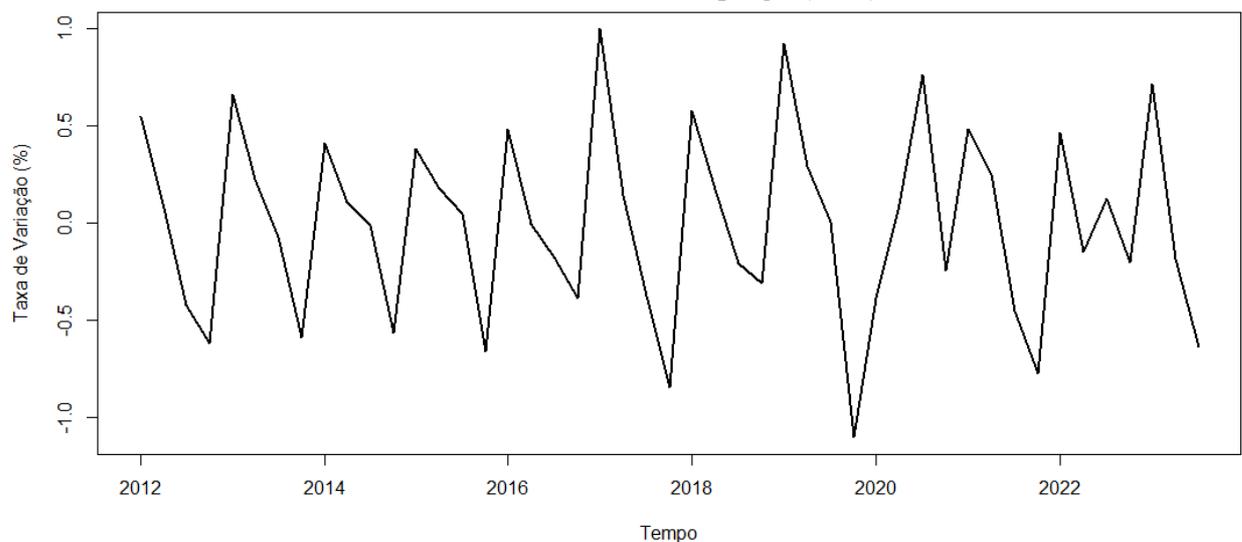
Gráfico 14 - Taxa de desemprego e NAIRU (SSA)



Fonte: Elaboração própria.

O citado movimento de alternância recorrente da NAIRU com a taxa de desemprego, ao contrário do que foi observado para os resultados do filtro HP, não resultou em longos períodos nos quais a taxa de desemprego sobrepujasse a NAIRU. O maior período registrado nos resultados do modelo SSA foi de 3 trimestres: 1T2015 ao 3T2015; e 1T2019 ao 3T2019 (Gráfico 14). No restante do período amostral, o período de alternância observado é a cada dois trimestres – o que resultou em um periódico hiato do desemprego (Gráfico 15).

Gráfico 15 - Hiato do desemprego (SSA)

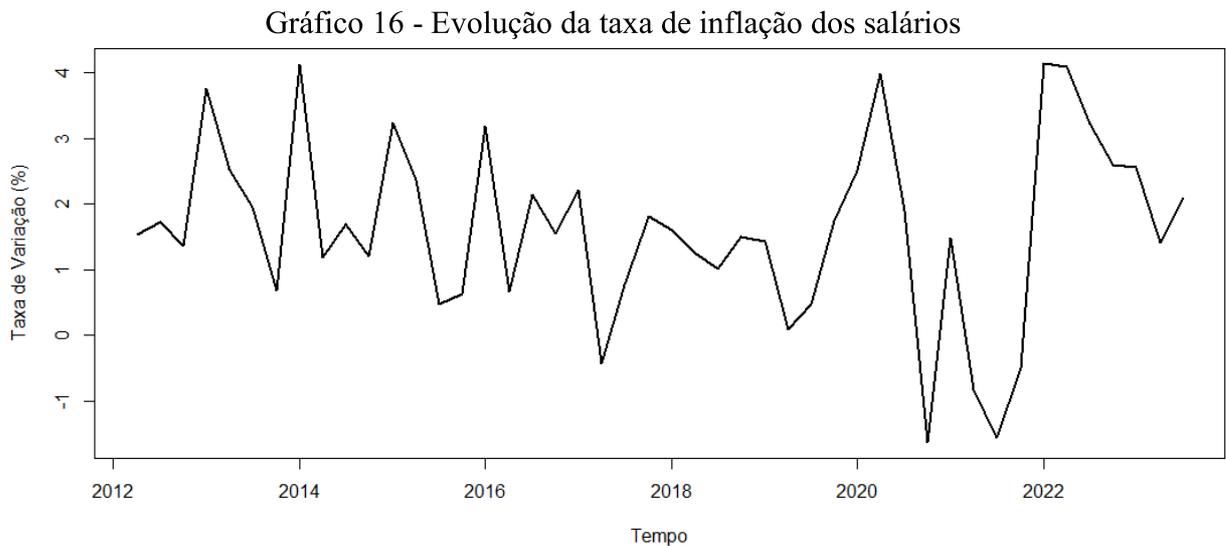


Fonte: Elaboração própria.

4.4 NAIRU MENSURADA A PARTIR DO MSSA

4.4.1 Etapa da decomposição e análise das autotriplas

Na versão multivariada do SSA, o modelo foi composto pela já trabalhada série da taxa de desemprego adicionada da série de taxa de inflação dos salários (Gráfico 16). Considerando as particularidades expostas na seção 3.5, ambas as séries possuíam 46 observações (2T2012 até o 3T2023) quando incorporadas ao modelo. Tal como para o modelo univariado, as séries inseridas no MSSA não sofreram modificações.



Fonte: Elaboração própria.

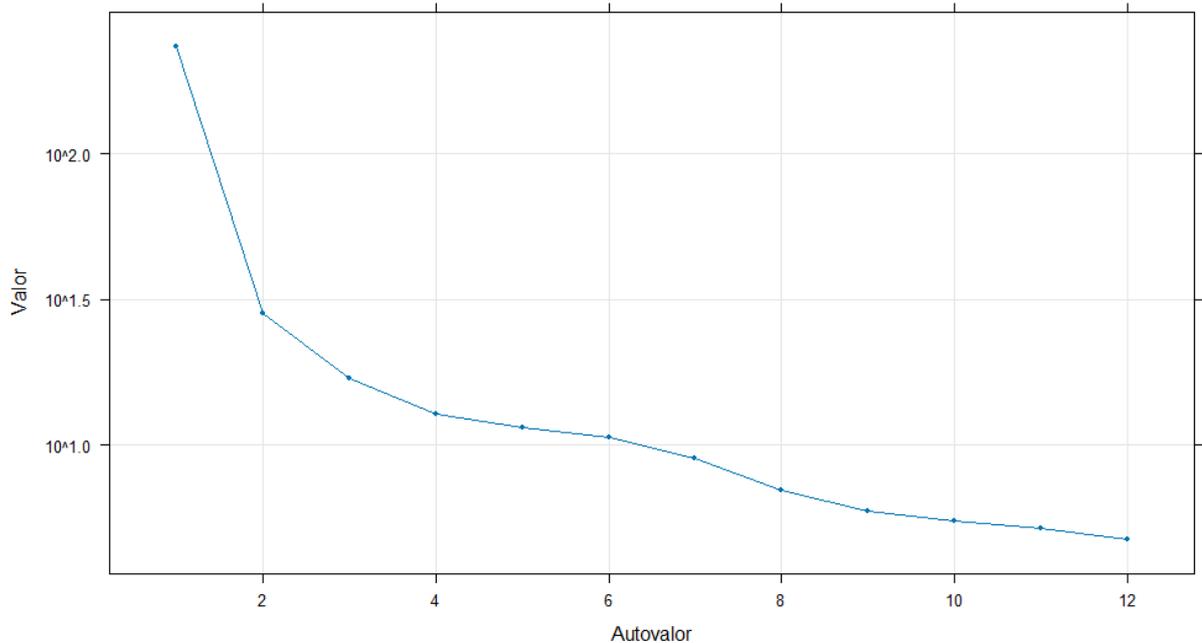
Da mesma forma que no modelo univariado, para o MSSA houve a necessidade de testar diferentes janelas para a etapa de decomposição das séries: $L = 8$; $L = 12$; $L = 16$; $L = 23$; $L = 31$ (a última conforme proposta de Hassani e Mahmoudvand, 2013 – equação 3.15). O teste de janelas para o MSSA foi recomendado por Golyandina *et al.* (2015), visto que mesmo tamanhos propostos na literatura (equação 3.15) podem não se adequar ao problema do pesquisador. Realizados os testes, a janela escolhida também foi $L = 12$, visto que evidenciou uma melhor separabilidade entre os componentes – sendo mais um indício que janelas menores podem favorecer séries curtas (Golyandina *et al.*, 2015).

Conforme ressaltado no capítulo de metodologia, a forma como é feita análise gráfica dos componentes gerados na etapa de decomposição não se diferencia substancialmente do ambiente univariado para o multivariado – especialmente em um modelo HMSSA. Contudo, agora é preciso ter em mente que os autovalores, os autovetores e, conseqüentemente, as autotriplas da matriz de w -correlação representam o comportamento sinal e ruído das duas séries do modelo.

Quando analisado o logaritmo dos autovalores (Figura 5), o primeiro autovalor se destacou pela distância dos demais – evidenciando um comportamento de tendência e de alta representação da variância total das séries. No que diz respeito aos sinais de comportamento de tendência, os autovalores 2 e 3 também se distanciaram dos demais. Quanto à sazonalidade na Figura 5, sua evidência fica mais clara do autovalor 4 ao 6, dado que depois do sexto autovalor, as quedas mais acentuadas voltaram a ocorrer.

Contudo, como um platô foi formado somente após o nono autovalor, os autovalores 7 a 9 ainda poderiam fazer parte da reconstrução da sazonalidade. Com isso, o ruído seria composto apenas pelos três últimos autovalores, e não pelos autovalores de 7 a 12 como a Figura 5 pode dar a entender.

Figura 5 - Log dos autovalores de 1 a 12 (MSSA)

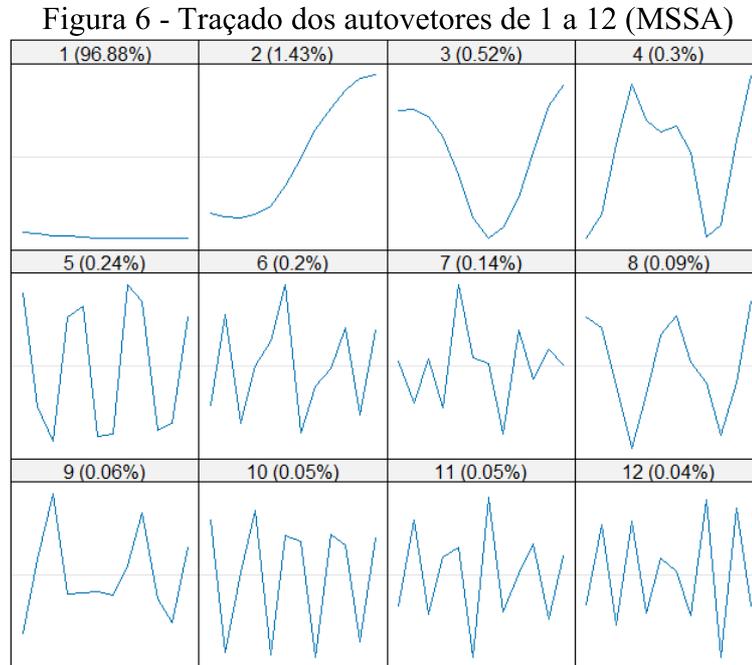


Fonte: Elaboração própria.

Condizente com as informações da Figura 5, a figura do traçado dos autovetores (Figura 6) exibiu que o primeiro e o segundo autovetor indicam o comportamento de tendência das séries, além de serem responsáveis por grande parte da variância delas com 98,31% no total. No entanto, na Figura 6 o terceiro autovetor mereceu maior atenção na análise, visto que, assim como no modelo univariado, este expôs o início de uma mudança de período.

O traçado dos autovetores também já elucidou a dúvida que pairou sobre os autovalores de 7 a 12 na Figura 5. Isso porque na Figura 6 os autovetores 4 a 9 apresentaram evidências a favor da sazonalidade das séries – comportamento senoidal com baixa frequência na mudança

dos períodos. Já os últimos autovetores (10 a 12), estes sim se mostraram ruidosos por causa da alta frequência na mudança dos períodos.

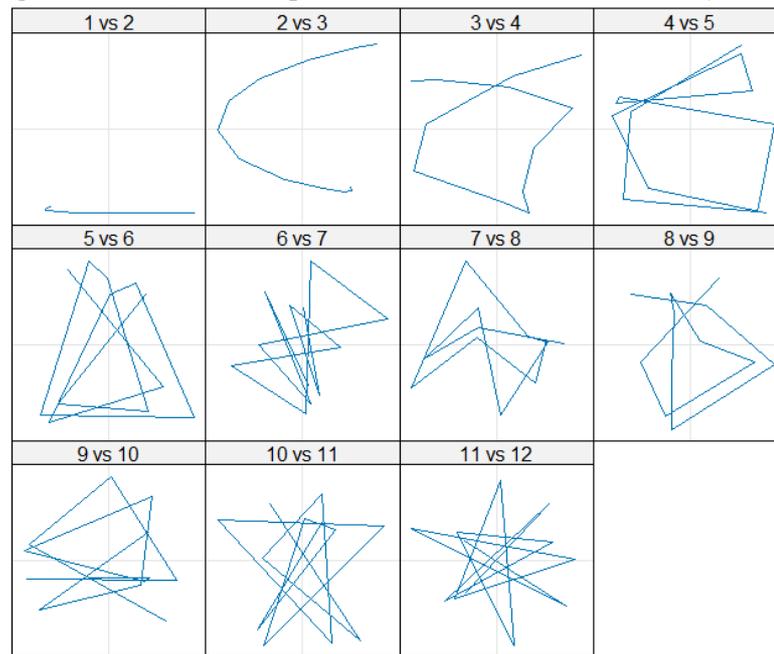


Fonte: Elaboração própria.

Na Figura 7, os pares “1 vs 2” e “2 vs 3” apontaram para o comportamento de tendência das séries ao não formarem polígonos. A estruturação de polígonos de três e quatro lados ocorreram nos pares formados pelos autovetores de 4 a 9 – com sinalização de sazonalidade de diferentes períodos (par “6 vs 7”), assim como ocorrido no modelo univariado. A formação destes polígonos evidenciou novamente que as autotriplas de 7 a 9 devem compor a reconstrução da sazonalidade das séries. Já os três últimos autovetores mais uma vez se mostraram ruidosos ao não formarem polígonos identificáveis.

Finalmente, ainda na Figura 7, os pares formados pelo terceiro autovetor, exibiram que este foi influenciado pelo comportamento de tendência e de sazonalidade das séries. Da mesma forma, esse indício foi corroborado pela matriz de w-correlação (Figura 8), visto que, por apresentar correlações semelhantes com os componentes 2 e 4, a autotripla 3 poderia se encaixar em quaisquer um dos dois grupos.

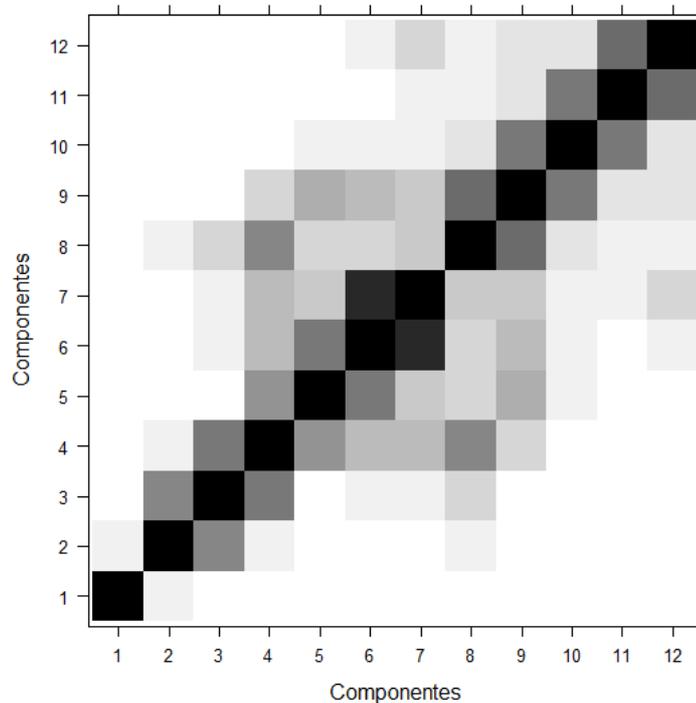
Figura 7 - Traçado dos pares dos autovetores de 1 a 12 (MSSA)



Fonte: Elaboração própria.

Feita a ressalva sobre o terceiro componente, na matriz de w-correlação (Figura 8) o comportamento de tendência foi observado para o primeiro e o segundo componente. Apesar do segundo componente apresentar uma correlação expressiva com o terceiro e próxima de zero com os componentes 4 e 8, este continua isolados dos demais da série.

Figura 8 - Matriz de w-correlação dos componentes (MSSA)



Fonte: Elaboração própria.

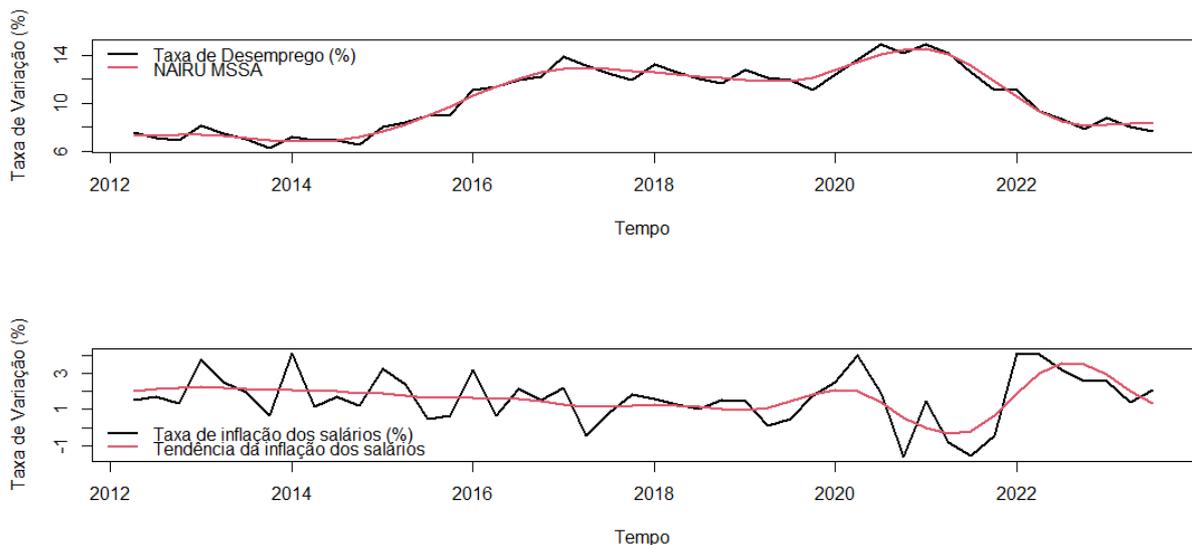
Assim como no modelo univariado, foi possível observar o “bloco” de autotriplas que constituíram o grupo de sazonalidade na etapa de reconstrução (4 a 9). Junto as demais evidências das outras figuras, a matriz de w-correlação foi essencial para determinar até quais autotriplas deveriam ser utilizadas para a reconstrução do sinal da série, isso porque, com exceção do componente 9, a correlação da décima autotripla com as de 5 a 8 é próxima de zero. Quanto às últimas autotriplas, a forte correlação dos componentes se dispôs conforme os pares da Figura 7 – reforçando que estas três autotriplas devem pertencer ao mesmo grupo, o do ruído.

Portanto, tendo como base as quatro figuras apresentadas para o modelo multivariado, as autotriplas utilizadas para a etapa de reconstrução do sinal das séries foram as autotriplas de 1 a 9, com os componentes de 10 a 12 considerados como ruído. Na próxima subseção serão discutidos os resultados da etapa de reconstrução do modelo.

4.4.2 Etapa de reconstrução e análise dos resultados do modelo MSSA

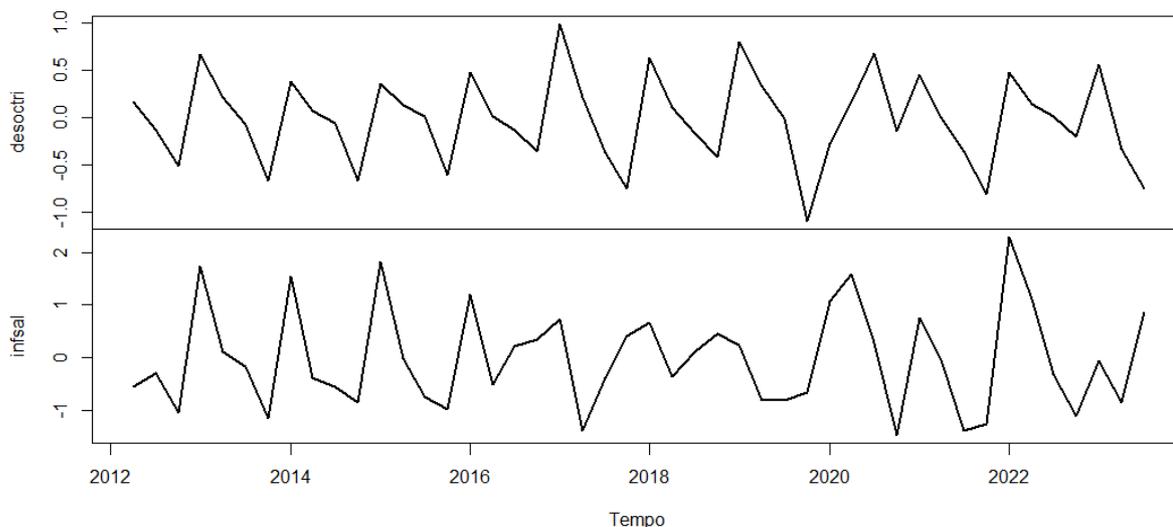
O resultado da reconstrução do sinal das séries no MSSA, da mesma forma que no modelo univariado, foi melhor quando o terceiro componente foi incluído no grupo de reconstrução da tendência, e não da sazonalidade. Logo, o modelo foi reconstruído com a tendência sendo de 1 a 3, e a sazonalidade de 4 a 9. A reconstrução da tendência, sazonalidade e o ruído das séries podem ser observados nos Gráficos de 17 a 19.

Gráfico 17 - Reconstrução da tendência para as séries de taxa de desemprego e inflação dos salários



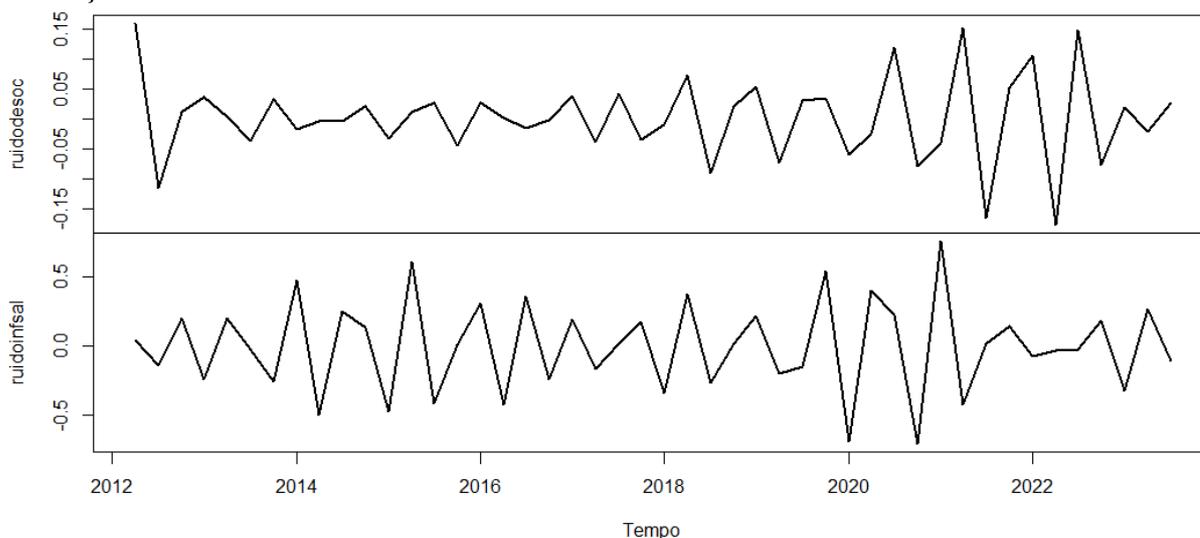
Fonte: Elaboração própria.

Gráfico 18 - Reconstrução da sazonalidade para as séries de taxa de desemprego e inflação dos salários



Fonte: Elaboração própria. Nota: Os termos “desoctri” e “infsal” foram os nomes dados para as variáveis de taxa de desemprego e inflação dos salários, respectivamente.

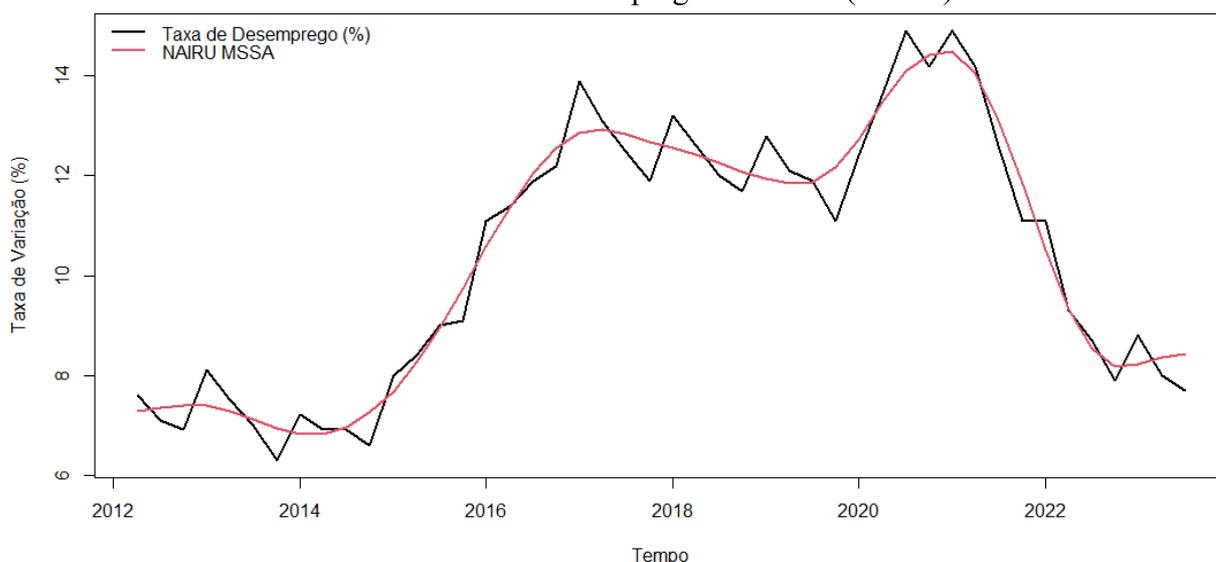
Gráfico 19 - Ruídos resultantes da etapa de reconstrução para as séries de taxa de desemprego e inflação dos salários



Fonte: Elaboração própria. Nota: Os termos “desoctri” e “infsal” foram os nomes dados para as variáveis de taxa de desemprego e inflação dos salários, respectivamente.

O Gráfico 20 apresenta em detalhes que a NAIRU obtida via MSSA seguiu o mesmo comportamento visto no modelo univariado e no modelo UCM – uma tendência próxima à série. Logo, o MSSA também mensurou uma tendência que varia periodicamente com a taxa de desemprego, ora superando a taxa corrente, ora estando abaixo da taxa.

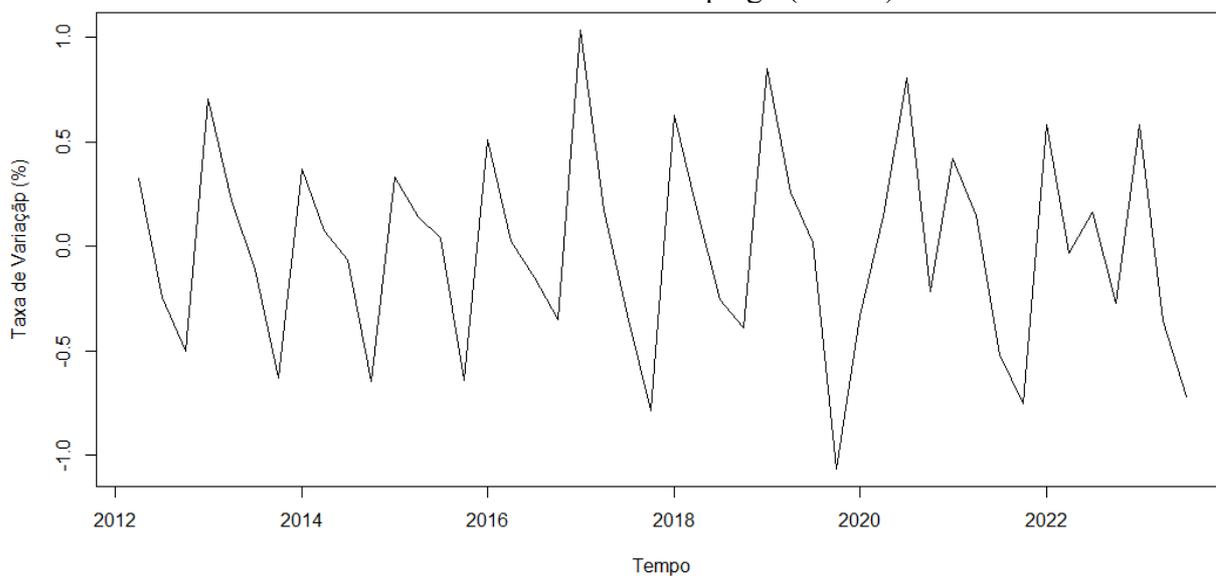
Gráfico 20 - Taxa de desemprego e NAIRU (MSSA)



Fonte: Elaboração própria.

No MSSA a NAIRU média correspondeu a 10,39% para todo o período amostral. Após o vale na primeira metade de 2014 (aproximadamente 6,83% para os dois trimestres), a NAIRU acompanhou o aumento do desemprego – atingindo 12,92% no 2T2017 e, posteriormente, 14,48% no 1T2021. Em seguida do pico na primeira metade de 2021, a NAIRU seguiu com queda encerrando a série com 8,41% no 3T2023.

Gráfico 21 - Hiato do Desemprego (MSSA)



Fonte: Elaboração própria.

Conforme já se esperava pelo Gráfico 20, a alternância cíclica da taxa de desemprego com a NAIRU MSSA resultou novamente em um hiato do desemprego periódico (Gráfico 21). Em média, ao longo de toda a série, a taxa de desemprego se mantém acima da NAIRU a cada dois trimestres e vice-versa.

Com os resultados da NAIRU mensurada via MSSA, destacou-se a semelhança entre três das quatro variáveis obtidas e, com isso, dois pontos devem ser elucidados. O primeiro é a conjuntura da economia ao longo do período amostral, visto que a variável de desemprego, após 2015, apresentou crescimento ininterrupto até o 1T2017 – crescimento esse que voltou a ocorrer após 2020. Já o segundo se refere à utilidade das taxas mensuradas para acompanhar o movimento da inflação, dado que - segundo a literatura (Gordon, 1997; Grant, 2002) – a relação entre a taxa de desemprego e a NAIRU é capaz de sinalizar o comportamento da inflação. Portanto, o próximo capítulo visa esclarecer a conjuntura do período amostral analisado e avaliar se as NAIRUs mensuradas são capazes de descrever o comportamento da inflação.

5 ANÁLISE DE CONJUNTURA E VERIFICAÇÃO DAS MENSURAÇÕES OBTIDAS

O presente capítulo visa avaliar se as NAIRUs mensuradas são capazes de acompanhar a evolução do IPCA ao longo do período amostral das séries, logo, se são consistentes com o comportamento da inflação baseado na relação exposta por Stiglitz (1997) e Grant (2002).

Para atingir esse objetivo, o capítulo 5 propõe, inicialmente, uma discussão de conjuntura sobre os comportamentos das séries da taxa de desemprego e do IPCA. Em seguida, é realizada a avaliação das medidas obtidas no capítulo 4 utilizando a posição da taxa de desemprego acerca à NAIRU; a análise da evolução do hiato do desemprego em relação ao IPCA; e o teste das mensurações para as diferentes séries relacionadas à inflação de preços.

Assim, a seção 5.1 apresenta uma análise conjuntural das variáveis de desemprego e inflação e a seção 5.2 expõe a discussão sobre a consistência das NAIRU obtidas.

5.1 DISCUSSÃO DO COMPORTAMENTO DO DESEMPREGO E DA INFLAÇÃO DE PREÇOS ENTRE O 1T2012 E O 3T2023

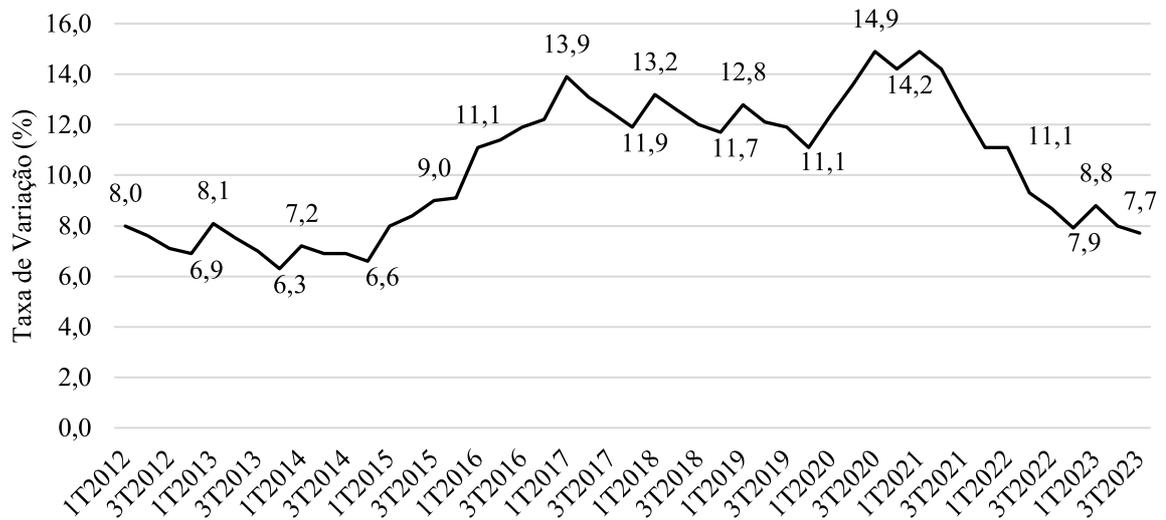
Conforme ressaltado na seção 2.2, uma das utilidades da NAIRU reside em acompanhar o comportamento da inflação de preços. Contudo, antes de avaliar se a relação entre taxa de desemprego, NAIRU e inflação se sustenta para as mensurações obtidas, se faz necessário entender melhor a conjuntura adjacente a estas séries observáveis para o período amostral selecionado.

Para o período anterior à amostra, de acordo com os Relatórios de Inflação do Banco Central do 4T2011 e do 1T2012 (BCB, 2011; BCB, 2012), a taxa de desemprego – utilizando os dados da PME – apresentou uma tendência de queda nos últimos quatro meses de 2011. Na média trimestral, a taxa atingiu uma média de 6,0% no trimestre encerrado em outubro e de 5,6% no trimestre encerrado em janeiro.

Quanto aos dados da PNAD Contínua (IBGE, 2023b), o primeiro trimestre de 2012 foi marcado por uma taxa de desemprego de 8,0%. Entre o 1T2012 e o 4T2014 a taxa de desemprego oscilou entre 6,0% e 8,0%, no entanto, a partir do 1T2015 (8%) observou-se uma tendência crescente da taxa que se estendeu até o 1T2017, quando atingiu 13,9%. Após o 1T2017, a taxa de desemprego voltou a registrar comportamento periódico de queda a cada último trimestre do ano, seguido de um crescimento no primeiro trimestre do ano seguinte e encerrou 2019 com uma taxa de 11,1%. A partir do 4T2019, voltou a crescer, chegando a atingir

14,9% no 3T2020 e no 1T2021 – patamar este que foi o maior registrado na série. Posteriormente ao pico do 1T2021, o desemprego voltou a exibir reduções consecutivas até atingir 7,7% no 3T2023, retornando para a faixa de 6,0% a 8,0% registrada no começo da série (Gráfico 22).

Gráfico 22 - Evolução da taxa do desemprego com detalhamento para trimestres selecionados

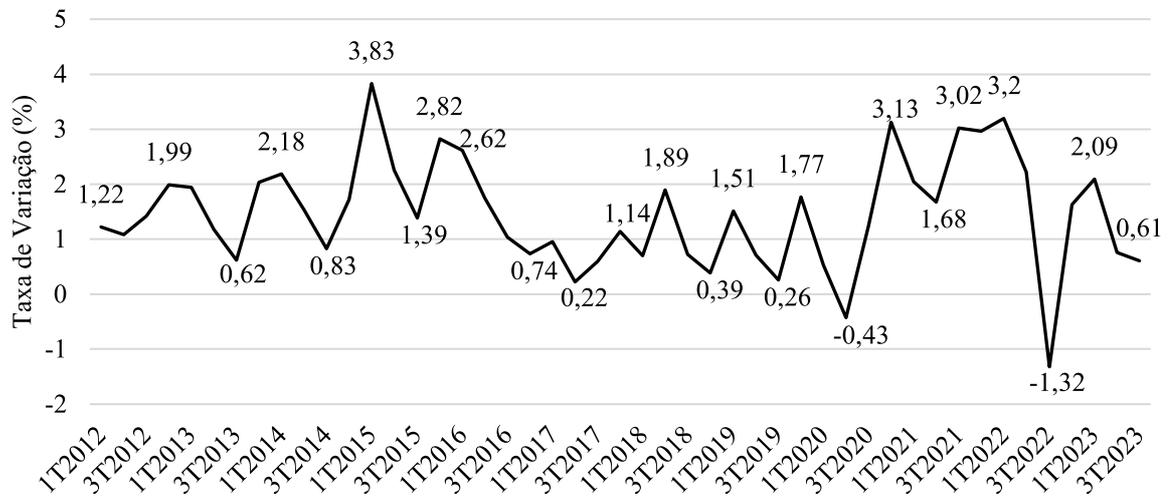


Fonte: Elaboração própria com base nos dados de IBGE (2023b). Nota: os trimestres em destaque são, respectivamente: 1T2012, 4T2012, 1T2013, 4T2013, 1T2014, 4T2014, 4T2015, 1T2016, 1T2017, 4T2017, 1T2018, 4T2018, 1T2019, 4T2019, 3T2020, 4T2020, 1T2022, 4T2022, 1T2023, 3T2023.

No que diz respeito à inflação de preços, a série do IPCA utilizada para a análise foi coletada para dois horizontes: o primeiro na variação (%) acumulada no trimestre, e o segundo na variação (%) acumulada em 4 trimestres, ambas retiradas para o mesmo período da PNAD Contínua - do 1T2012 ao 3T2023 (IBGE, 2023a).

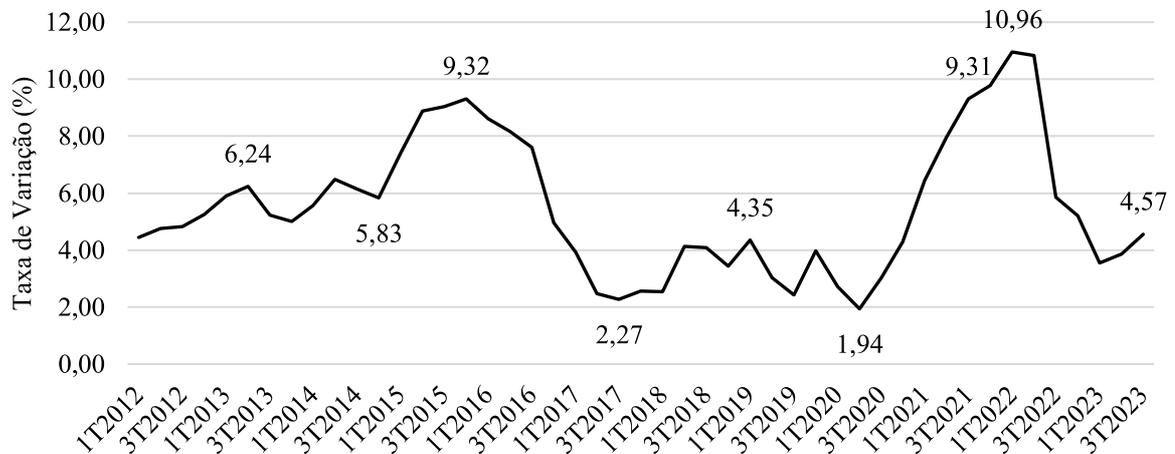
Para o primeiro caso, o IPCA é caracterizado pelo seu comportamento periódico que oscila, em média, a cada dois trimestres ao longo de toda a amostra. Contudo, esse comportamento foi marcado por variações expressivas em 2015 e 2016, e posteriormente entre 2020 e 2022. Tais anos registraram os picos 1T2015 (3,83%), 4T2020 (3,13%) e 1T2022 (3,2%), e os vales 2T2020 (-0,43%) e 2T2022 (-1,32%) da amostra. Outro destaque é que as quebras no comportamento de variação a cada dois trimestres ocorreram nesse mesmo período (Gráfico 23).

Gráfico 23 - Evolução do IPCA acumulado em 3 meses com detalhamento para trimestres selecionados



Fonte: Elaboração própria com base nos dados de (2023a). Nota: os trimestres em destaque são, respectivamente: 1T2012, 4T2012, 3T2013, 1T2014, 3T2014, 1T2015, 3T2015, 4T2015, 1T2016, 4T2016, 2T2017, 4T2017, 2T2018, 4T2018, 1T2019, 3T2019, 4T2019, 2T2020, 4T2020, 2T2021, 3T2021, 1T2022, 3T2022, 1T2023, 3T2023.

Gráfico 24 - Evolução do IPCA acumulado em 4 trimestres com detalhamento para trimestres selecionados



Fonte: Elaboração própria com base nos dados de (2023a). Nota: os trimestres em destaque são, respectivamente: 2T2013; 4T2014; 4T2015; 3T2017; 1T2019; 2T2020; 3T2021; 1T2022; 3T2023.

Quanto ao Gráfico 24, este exibe o IPCA no segundo horizonte citado. Por construção, aqui a variável é caracterizada por uma persistência nos comportamentos de aceleração ou redução do índice. Do início da série até o seu pico no 4T2015, o IPCA apresentou uma tendência positiva decorrente da expansão do índice nos trimestres, apesar das reduções após o 2T2013 e mais adiante depois no 2T2014. Essa tendência positiva foi sucedida por uma diminuição expressiva da taxa ao longo de todo 2016 até o 3T2017, que chegou a apresentar um dos pontos mais baixos da série (2,27%). Posteriormente até o 4T2020, o IPCA nesse

segundo horizonte se manteve dentro das bandas para a meta da inflação, exceto pelo vale no 2T2020 que ficou abaixo do limite inferior de 2,50% estabelecido pelo Banco Central. No entanto, assim como em 2015, o IPCA voltou a acelerar ao longo de 2021, se situando fora da meta até o final de 2022.

Tendo em vista o comportamento do desemprego e do IPCA ao longo da análise, é possível observar que a crise econômica e instabilidade política dos anos de 2015 e 2016, e depois, a crise sanitária entre 2020 e 2022 elevaram o patamar do desemprego e provocaram a aceleração do IPCA, este marcado pela alta frequência do índice no acumulado no trimestre e pelo crescimento persistente no acumulado em 4 trimestres que chegou a ultrapassar a meta. Ademais, esses anos se destacaram por altos níveis de incerteza e por ajustes na meta da Taxa Selic, ajustes esses que viriam a representar os picos e vales da série histórica entre 2012 e 2023 (BCB, 2024b).

No que diz respeito aos níveis de incerteza da economia brasileira, ao calcular a média trimestral do Indicador de Incerteza da Economia do Brasil (IIE-Br) da Fundação Getúlio Vargas (FGV/IBRE) foi possível observar uma mudança positiva de patamar da série entre 2015 e 2016 e uma abrupta elevação do índice com o início da crise sanitária (FGV/IBRE, 2024). O Apêndice B apresenta a série calculada trimestralmente para o mesmo período amostral trabalhado e detalha sua evolução.

Quanto à condução da política monetária nesses anos, em janeiro de 2015 o Copom (Comitê de Política Monetária) aprovou a elevação da taxa Selic para 12,25% a.a., um aumento de 0,5 p.p, em relação à meta estabelecida na reunião anterior. Ainda em julho do mesmo ano, a meta da taxa foi elevada para 14,25% a.a. – maior valor entre 2012 e 2023. Para o restante de 2015 e maior parte de 2016, a taxa Selic foi mantida e voltou a reduzir apenas a partir de outubro, período o qual as expectativas de inflação recuaram e a atividade econômica demonstrou sinais de recuperação (BCB, 2024a).

Já para o período da crise de Covid-19, em agosto de 2020 o Copom aprovou o menor nível para a taxa Selic (2% a.a.) durante o período amostral observado, reflexo de uma recessão econômica global e de uma expectativa de ainda baixa inflação em 2020. Conforme o Gráfico 24, a aceleração da inflação em 2021 foi o fator que motivou os reajustes da taxa de juros – elevando-a consecutivamente até 9,25% a.a. em dezembro. Já em 2022, ainda em decorrência de uma alta inflação e da volatilidade da economia externa, o Copom seguiu elevando a taxa de juros, que chegou a 13,75% a.a. em agosto – nível que se manteve até dezembro (BCB, 2024a).

Portanto, tendo em vista a evolução do desemprego e do IPCA nesses períodos, o ambiente de incerteza e a condução da política monetária, faz-se necessário entender os fatores que influenciaram na aceleração do desemprego e da inflação nesses dois períodos, visto que estes podem ser um obstáculo na relação entre taxa de desemprego, NAIRU e inflação.

De acordo com a Carta de Conjuntura do IPEA (Instituto de Pesquisa Econômica Aplicada) de março de 2016 (IPEA, 2016a) o ano de 2015 foi marcado por resultados fiscais negativos, pela instabilidade política e pela recessão na produção. Esse conjunto de fatores contribuiu para a aceleração descrita na análise do IPCA acumulado em 4 trimestres, assim como para as altas taxas no acumulado no trimestre. Quanto ao desemprego, o aumento observado foi consequência, além da recessão econômica, de uma política monetária restritiva que, por sua vez, também afetou negativamente a demanda interna.

Em relação a 2016, a economia brasileira ainda enfrentava um cenário de recessão econômica aliada à incerteza de como o país ajustaria seu lado fiscal (IPEA, 2016b). É possível ver nos gráficos 22 a 24 uma taxa de desemprego que ainda alcançava patamares mais elevados, contrastando com a inflação que exibiu sucessivas reduções – principalmente no segundo horizonte. Em especial, a aceleração do desemprego decorreu da combinação da deterioração da ocupação e da renda da força de trabalho, enquanto o comportamento da inflação foi influenciado pela política fiscal mais restritiva, pela expectativa da retomada do crescimento econômico em 2017 e, conseqüentemente, por um mercado de trabalho deteriorado.

Apesar de não ter sido citado dentre os períodos destacados anteriormente, é preciso contextualizar a economia brasileira em 2017, visto que o ano iniciou com a expectativa de melhorias nos índices macroeconômicos, expectativas que se consolidaram com a recuperação do PIB junto à evolução dos índices de confiança (IPEA, 2017b). Dado o comportamento da taxa de desemprego ao longo da amostra, é a partir deste ano que a variável volta a apresentar reduções – o que não ocorria desde o 4T2014. Segundo IPEA (2018), os motivos dessa redução, além da retomada da produção, foram a recuperação do dinamismo no mercado de trabalho, o aumento na população ocupada e a elevação do rendimento real.

No que diz respeito à evolução da inflação em 2017, ambas as métricas permaneceram em um patamar menor que nos anos anteriores. Para o IPCA acumulado em 4 trimestres, esse comportamento foi reflexo do recuo das seguintes categorias: alimentos, bens industriais e serviços (IPEA, 2017b). Em relação ao primeiro horizonte do IPCA, o destaque foi a aceleração da taxa na segunda metade do ano que, mesmo não ultrapassando os dois pontos percentuais,

refletiu no segundo horizonte no ano seguinte. Essa aceleração foi provocada pelo aumento dos preços administrados, que superou a deflação dos alimentos na segunda metade do ano.

Quanto ao segundo período destacado – de 2020 a 2022 – a pandemia de Covid-19 se tornou um obstáculo para a atividade econômica brasileira, contrariando as expectativas geradas no final de 2019, produzindo incertezas inéditas e apresentando comportamentos divergentes das variáveis macroeconômicas quando comparadas em diferentes períodos.

De acordo com IPEA (2023), as políticas sociais que visaram a faixa da população mais afetada pela pandemia – como o auxílio emergencial – viabilizaram a trajetória de recuperação da atividade econômica ao longo de 2020. No 3T2020 o desemprego superou o elevado patamar do início de 2017 com uma taxa de 14,9%, sendo este elevado patamar, em um primeiro momento, um reflexo da redução das oportunidades de trabalho decorrentes do isolamento social. Posteriormente, com o afrouxamento do isolamento e restrições nos benefícios sociais, o aumento da taxa de desemprego foi influenciado pela retomada da busca por um emprego no mercado de trabalho, assim, elevou-se a oferta de trabalho em um mercado que ainda apresentava uma demanda restrita.

No que se refere ao comportamento da inflação no primeiro ano da crise sanitária, esta acelerou após o segundo trimestre em ambos os horizontes. Esse crescimento foi carregado pela desvalorização cambial e pela redução de oferta de itens agrícolas da cesta de consumo do IPCA (IPEA, 2023).

Os anos de 2021 e 2022 consolidaram as reduções da taxa de desemprego, contudo, essa melhora teve motivos diferentes em cada um dos anos. Em 2021, o principal fator de redução da taxa de desemprego foram os aumentos que ocorreram nos números da população ocupada (IPEA, 2023). No entanto, no ano de 2022 a redução do desemprego foi acarretada por uma retração da força de trabalho – mesmo em um mercado que obteve recuperação nos rendimentos e evolução da massa salarial real (IPEA, 2023).

Acerca da inflação, nesses dois anos o IPCA acumulado no trimestre foi marcado por variações expressivas no índice, enquanto no acumulado em 4 trimestres foi possível observar como o IPCA aumentou ao longo de 2021 e retornou em direção ao centro da meta de inflação ao longo de 2022. Dentre os motivos da pressão inflacionária em 2021, têm-se: choques de oferta (*e.g.* escassez de matérias-primas e custo da energia); desvalorização cambial; elevação nos preços das *commodities* no mercado externo – principalmente do petróleo; e crise hídrica (IPEA, 2023). Quanto a 2022, os principais responsáveis pela redução apresentada ao longo do

ano foram os preços administrados e as *commodities* energéticas que desaceleraram neste período.

Com isso, a análise finaliza com destaque em dois períodos atípicos para o comportamento das variáveis: a crise econômica aliada à instabilidade política entre 2015 e 2016; e a pandemia de Covid-19 entre 2020 e 2022. Nesses dois períodos ocorreu não somente a aceleração do desemprego, como também a mudança de patamar do mesmo – que permaneceu acima dos 10% de 2016 ao primeiro trimestre de 2022, refletindo em uma NAIRU elevada.

Quanto ao comportamento da inflação para o período de crise econômica e pandemia, enquanto o IPCA acumulado no trimestre apresentou uma maior frequência e quebra da periodicidade da série em relação ao restante da amostra, o IPCA acumulado em 4 trimestres permitiu a visualização de como o índice reagiu a esses dois períodos, chegando a ultrapassar a meta de inflação estabelecida pelo Banco Central e, conseqüentemente, ficando perceptível as mudanças de patamar do índice ao longo da amostra.

Por fim, a próxima seção tem por finalidade avaliar se as medidas obtidas de NAIRU são consistentes com o comportamento da inflação brasileira para todo o período analisado. Para isso, as variáveis mensuradas foram testadas e avaliadas graficamente, comparando seu hiato com a evolução da inflação.

5.2 AVALIAÇÃO DAS MENSURAÇÕES DA NAIRU

Definidas como a tendência do desemprego, as NAIRUs mensuradas no capítulo 4 exibiram semelhanças em seu comportamento, sendo as principais: o crescimento após o ano de 2015 e a alternância periódica com a taxa de desemprego. A análise conjuntural feita na seção anterior visou elucidar a mudança de patamar que o desemprego apresentou ao discutir a conjuntura por trás da evolução da série para os anos de 2015 e 2016, e posteriormente no período da pandemia de Covid-19. Não obstante, também se fez necessário entender como a inflação, seja ela acumulada no trimestre ou em 4 trimestres, se comportou no mesmo período, visto que, conforme a literatura, a NAIRU deve acompanhar o movimento da inflação.

Assim, esta seção visa averiguar a relação entre taxa de desemprego, NAIRU e taxa de inflação, isto é: se a taxa de desemprego estiver acima da NAIRU, espera-se uma tendência de queda da inflação, e se a taxa de desemprego estiver abaixo da NAIRU, espera-se um comportamento de aumento da inflação (Grant 2002). Portanto, para analisar essa relação, a presente seção propõe examinar a evolução do hiato do desemprego resultante das mensurações em conjunto com a inflação, nos dois horizontes já citados, ao longo de toda a amostra. Para complementar a análise, as NAIRUs também foram testadas conforme proposta de Portugal e Madalozzo (2000).

Considerando a dinâmica entre taxa de desemprego e NAIRU, Portugal e Madalozzo (2000) propuseram uma regressão simples entre o hiato do desemprego ($u_t - NAIRU_t$) e a taxa de inflação (π_t) (equação 5.1) feita via Mínimos Quadrados Ordinários:

$$(u_t - NAIRU_t) = \beta_0 - \beta_1\pi_t + \varepsilon_t \quad (5.1)$$

Em que ε_t representa o termo de erro da equação. De acordo com os autores, para que a relação da NAIRU mensurada seja consistente com o desemprego e a inflação brasileira – conforme a definição da literatura - o coeficiente β_1 da equação 5.1 deve ser negativo, correspondendo à relação da Curva de Phillips. Os trabalhos de Oliveira, Portugal e Abrita (2016) e Nobrega, Besarria e Oliveira (2020) também utilizaram do teste para verificar suas estimativas, direcionando a discussão para o sinal do coeficiente e sua significância estatística. Não obstante, Oliveira, Portugal e Abrita (2016) complementaram os resultados do teste com a análise da evolução da inflação, assim como feito também por Palma e Ferreira (2017).

Além da taxa de inflação medida pelo IPCA, para averiguar a robustez das medidas obtidas, o teste do hiato do desemprego foi incorporado com as seguintes séries relacionadas à

inflação: IPCA – Livres e IPCA – Comercializáveis, e com os seguintes núcleos de inflação (BCB, 2023): EX0; EX1; MA; MS; e DP. Tendo em vista que os dados foram disponibilizados com periodicidade mensal, todas essas medidas foram calculadas para a taxa acumulada no trimestre e em 4 trimestres. De resto, para realizar os testes baseados na proposta de Portugal e Madalozzo (2000), foi necessário verificar se – no corte amostral – as séries eram estacionárias ou não. Portanto, o Apêndice A apresenta os testes de raiz unitária realizados e seus resultados. Por fim, o uso das séries dos grupos de itens do IPCA e dos núcleos de inflação no teste também foi motivado pela versatilidade do IPCA em acompanhar os diferentes grupos de itens que afetam taxas salariais diferentes, e pelo uso dos núcleos pelo Banco Central para monitorar a inflação.

A Tabela 1 exibe os valores da taxa de desemprego com cada uma das quatro NAIRUs mensuradas, assinalando se a taxa de desemprego observada está acima ou abaixo da NAIRU. Tendo em vista que o hiato do desemprego é a diferença entre as duas séries, a Tabela 1 também indica os trimestres para os quais o hiato é positivo (taxa de desemprego acima da NAIRU) e negativo (taxa de desemprego abaixo da NAIRU).

Em síntese, a Tabela 1 evidenciou quais variáveis evoluem próximas à série de desemprego, isto é, alternam periodicamente com a taxa corrente do desemprego. Para o modelo UCM, essa periodicidade foi igual a dois trimestres, similar ao observado para os modelos SSA e MSSA, que também mostraram, em média, uma alternância a cada dois trimestres, apesar de apresentarem quebra desse comportamento em diversos períodos. Em contraste com esse comportamento, a NAIRU HP – mensurada a partir de uma tendência suavizada – se situou abaixo, ou acima, do desemprego por períodos muito maiores, estes que chegaram a se estender a até 10 trimestres.

Tabela 1 - Posição da taxa de desemprego em relação às NAIRUs mensuradas

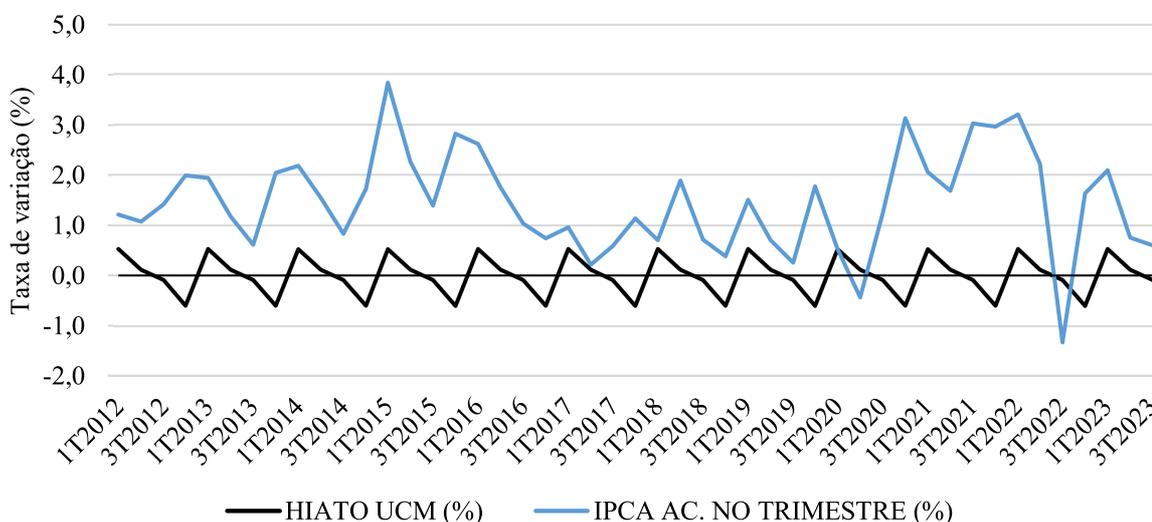
Trimestre	Taxa de Desemprego (%)	NAIRU UCM (%)		NAIRU SSA (%)		NAIRU MSSA (%)		NAIRU HP (%)	
1T2012	8,0	7,467	ACIMA	7,449	ACIMA	–	–	6,308	ACIMA
2T2012	7,6	7,474	ACIMA	7,495	ACIMA	7,275	ACIMA	6,498	ACIMA
3T2012	7,1	7,190	ABAIXO	7,520	ABAIXO	7,346	ABAIXO	6,689	ACIMA
4T2012	6,9	7,497	ABAIXO	7,515	ABAIXO	7,399	ABAIXO	6,881	ACIMA
1T2013	8,1	7,567	ACIMA	7,440	ACIMA	7,394	ACIMA	7,077	ACIMA
2T2013	7,5	7,374	ACIMA	7,275	ACIMA	7,280	ACIMA	7,278	ACIMA
3T2013	7,0	7,090	ABAIXO	7,070	ABAIXO	7,107	ABAIXO	7,487	ABAIXO
4T2013	6,3	6,897	ABAIXO	6,887	ABAIXO	6,930	ABAIXO	7,706	ABAIXO
1T2014	7,2	6,667	ACIMA	6,786	ACIMA	6,827	ACIMA	7,938	ABAIXO
2T2014	6,9	6,774	ACIMA	6,789	ACIMA	6,827	ACIMA	8,182	ABAIXO
3T2014	6,9	6,990	ABAIXO	6,911	ABAIXO	6,964	ABAIXO	8,441	ABAIXO
4T2014	6,6	7,197	ABAIXO	7,163	ABAIXO	7,247	ABAIXO	8,713	ABAIXO
1T2015	8,0	7,467	ACIMA	7,616	ACIMA	7,669	ACIMA	8,997	ABAIXO
2T2015	8,4	8,274	ACIMA	8,222	ACIMA	8,259	ACIMA	9,291	ABAIXO
3T2015	9,0	9,090	ABAIXO	8,953	ACIMA	8,960	ACIMA	9,591	ABAIXO
4T2015	9,1	9,697	ABAIXO	9,757	ABAIXO	9,743	ABAIXO	9,894	ABAIXO
1T2016	11,1	10,567	ACIMA	10,616	ACIMA	10,591	ACIMA	10,194	ACIMA
2T2016	11,4	11,274	ACIMA	11,406	ABAIXO	11,378	ACIMA	10,487	ACIMA
3T2016	11,9	11,990	ABAIXO	12,078	ABAIXO	12,048	ABAIXO	10,767	ACIMA
4T2016	12,2	12,797	ABAIXO	12,586	ABAIXO	12,553	ABAIXO	11,032	ACIMA
1T2017	13,9	13,367	ACIMA	12,901	ACIMA	12,867	ACIMA	11,276	ACIMA
2T2017	13,1	12,974	ACIMA	12,958	ACIMA	12,924	ACIMA	11,497	ACIMA
3T2017	12,5	12,590	ABAIXO	12,873	ABAIXO	12,828	ABAIXO	11,693	ACIMA
4T2017	11,9	12,497	ABAIXO	12,745	ABAIXO	12,688	ABAIXO	11,864	ACIMA
1T2018	13,2	12,667	ACIMA	12,620	ACIMA	12,572	ACIMA	12,009	ACIMA
2T2018	12,6	12,474	ACIMA	12,428	ACIMA	12,421	ACIMA	12,128	ACIMA
3T2018	12,0	12,090	ABAIXO	12,207	ABAIXO	12,255	ABAIXO	12,220	ABAIXO
4T2018	11,7	12,297	ABAIXO	12,009	ABAIXO	12,089	ABAIXO	12,287	ABAIXO
1T2019	12,8	12,267	ACIMA	11,876	ACIMA	11,949	ACIMA	12,328	ACIMA
2T2019	12,1	11,974	ACIMA	11,807	ACIMA	11,840	ACIMA	12,343	ABAIXO
3T2019	11,9	11,990	ABAIXO	11,894	ACIMA	11,883	ACIMA	12,331	ABAIXO
4T2019	11,1	11,697	ABAIXO	12,202	ABAIXO	12,162	ABAIXO	12,291	ABAIXO
1T2020	12,4	11,867	ACIMA	12,783	ABAIXO	12,732	ABAIXO	12,223	ACIMA
2T2020	13,6	13,474	ACIMA	13,505	ACIMA	13,452	ACIMA	12,123	ACIMA
3T2020	14,9	14,990	ABAIXO	14,139	ACIMA	14,094	ACIMA	11,990	ACIMA
4T2020	14,2	14,797	ABAIXO	14,441	ABAIXO	14,418	ABAIXO	11,822	ACIMA
1T2021	14,9	14,367	ACIMA	14,419	ACIMA	14,481	ACIMA	11,618	ACIMA
2T2021	14,2	14,074	ACIMA	13,947	ACIMA	14,051	ACIMA	11,380	ACIMA
3T2021	12,6	12,690	ABAIXO	13,048	ABAIXO	13,118	ABAIXO	11,111	ACIMA
4T2021	11,1	11,697	ABAIXO	11,873	ABAIXO	11,853	ABAIXO	10,814	ACIMA
1T2022	11,1	10,567	ACIMA	10,633	ACIMA	10,518	ACIMA	10,496	ACIMA
2T2022	9,3	9,174	ACIMA	9,446	ABAIXO	9,333	ABAIXO	10,161	ABAIXO
3T2022	8,7	8,790	ABAIXO	8,572	ACIMA	8,535	ACIMA	9,814	ABAIXO
4T2022	7,9	8,497	ABAIXO	8,103	ABAIXO	8,172	ABAIXO	9,459	ABAIXO
1T2023	8,8	8,267	ACIMA	8,086	ACIMA	8,220	ACIMA	9,100	ABAIXO
2T2023	8,0	7,874	ACIMA	8,182	ABAIXO	8,355	ABAIXO	8,739	ABAIXO
3T2023	7,7	7,790	ABAIXO	8,334	ABAIXO	8,418	ABAIXO	8,377	ABAIXO

Fonte: Elaboração própria.

Com relação ao modelo UCM, conforme ressaltado na discussão de conjuntura, a frequência de dois trimestres também é peculiaridade do IPCA acumulado no trimestre, exceto para os trimestres compreendidos dentro das crises citadas na seção anterior. No entanto, a característica do IPCA acumulado em 4 trimestres de persistência no comportamento de aceleração, ou redução, do índice propõe o questionamento se a NAIRU periódica é capaz de acompanhar a inflação no período acumulado de quatro trimestres. Dessa forma, a análise para dois horizontes distintos permite verificar não somente para a NAIRU UCM, mas como se as outras mensurações são adequadas para ambos os horizontes.

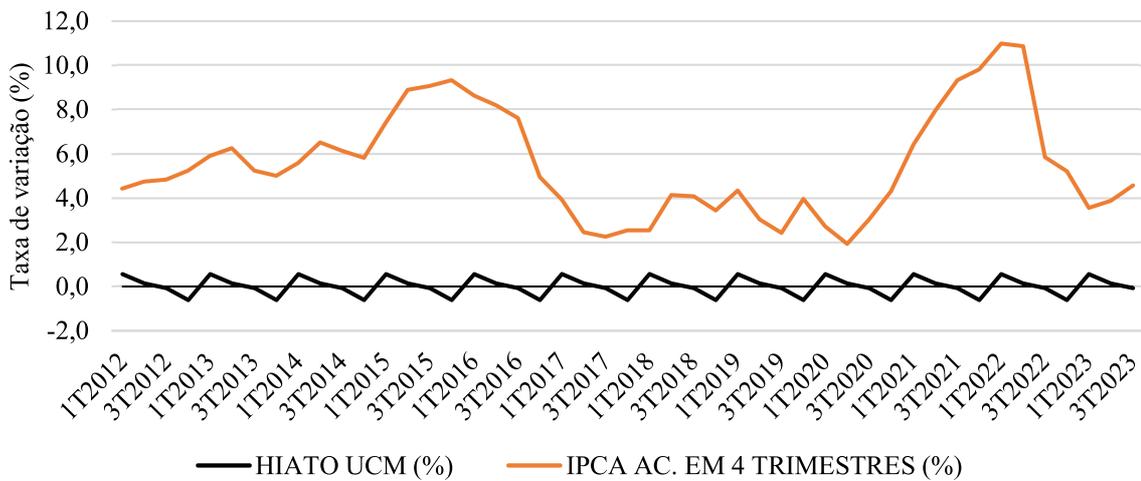
O Gráfico 25 apresenta o Hiato UCM e o IPCA acumulado no trimestre. Considerando o comportamento periódico da NAIRU UCM, o hiato do desemprego acompanhou o comportamento da inflação no acumulado no trimestre. Do 1T2012 ao 3T2015 o hiato correspondeu aos períodos de aceleração e redução da inflação do IPCA em t e em $t + 1$. Esse movimento também ocorreu para os períodos 4T2016 - 2T2020 e após o 1T2022. Contudo, é necessário ressaltar que ocorreram exceções a essa relação nos períodos da incerteza fiscal e política (4T2015 - 3T2016) e da pandemia de Covid-19 (3T2020 ao 3T2021).

Gráfico 25 - Hiato UCM e IPCA acumulado no trimestre



Fonte: Elaboração própria.

Gráfico 26 - Hiato UCM e IPCA acumulado em 4 trimestres



Fonte: Elaboração própria.

No que diz respeito à inflação no acumulado em 4 trimestres, a NAIRU UCM não foi capaz de refletir a tendência de alta ou baixa do índice de forma consistente ao longo da amostra, principalmente para os períodos de forte expansão e redução da taxa. Assim, apesar do período entre 2018 e 2019 em que essa correspondência ocorreu devido ao aumento da frequência do índice, não se pode afirmar que a NAIRU UCM condisse com o comportamento do IPCA no acumulado em 4 trimestres.

Essa dinâmica da NAIRU UCM em relação ao IPCA, para os ambos os horizontes citados, também foi evidenciada no resultado dos testes para o modelo UCM (Tabela 2 e Tabela 3). Para as séries acumuladas no trimestre, todos os coeficientes foram negativos, logo, conforme Portugal e Madalozzo (2000) a variável é consistente com o comportamento da inflação brasileira acumulada no trimestre. Ademais, o sinal negativo e a significância estatística dos coeficientes ao longo dos testes do Hiato UCM demonstraram a robustez da variável na correspondência com o índice nesse horizonte. Portanto, aliando a análise gráfica com os resultados observados na Tabela 2, a NAIRU UCM se mostrou uma ferramenta adequada para acompanhar o IPCA acumulado no trimestre.

Quanto às séries acumuladas em 4 trimestres (Tabela 3), o sinal do coeficiente para o teste com IPCA acumulado 4 trimestres foi positivo, refletindo a não correspondência da medida com o índice acumulado em 4 trimestres. Além disso, apesar de alguns coeficientes negativos, como para o IPCA - Livres e IPCA - Comercializáveis, estes foram muito pequenos e não significantes, assim como os demais. Sendo assim, os resultados dos testes do modelo UCM da Tabela 3 corroboram com a evidência de que a NAIRU UCM, uma variável que

evoluiu próxima à série de desemprego, não é adequada para ser utilizada no acompanhamento da inflação no acumulado 4 trimestres.

Tabela 2 - Resultados dos testes das mensurações da NAIRU para o horizonte acumulado no trimestre

	NAIRU UCM		NAIRU SSA		NAIRU MSSA		NAIRU HP	
	Coefficiente	<i>p-valor</i>	Coefficiente	<i>p-valor</i>	Coefficiente	<i>p-valor</i>	Coefficiente	<i>p-valor</i>
IPCA	-0,1038**	0,0451	-0,0592	0,3470	-0,0600	0,3390	0,0063	0,9700
COMER.	-0,0831*	0,0758	-0,0551	0,3310	-0,0345	0,5500	0,0380	0,8020
LIVRES	-0,1733***	0,0033	-0,1433**	0,0476	-0,1322*	0,0675	-0,0467	0,8120
EX0	-0,3070***	0,0008	-0,2758**	0,0141	-0,2761**	0,0135	0,0475	0,8780
EX1	-0,0677	0,4620	-0,0023	0,9840	-0,0090	0,9350	0,1706	0,5600
MA	-0,2487*	0,0676	-0,2393	0,1440	-0,2066	0,2100	0,1501	0,7330
MS	-0,1161	0,4610	-0,2186	0,2440	-0,1762	0,3580	0,3130	0,5330
DP	-0,2252*	0,0558	-0,1852	0,1930	-0,1735	0,2230	0,0823	0,8290

Fonte: Elaboração própria. Nota: * caracteriza a rejeição da hipótese nula a 10%; ** caracteriza rejeição da hipótese nula a 5%; *** caracteriza rejeição da hipótese nula a 1%.

Tabela 3 - Resultados dos testes das mensurações da NAIRU para o horizonte acumulado em 4 trimestres

	NAIRU UCM		NAIRU SSA		NAIRU MSSA		NAIRU HP	
	Coefficiente	<i>p-valor</i>	Coefficiente	<i>p-valor</i>	Coefficiente	<i>p-valor</i>	Coefficiente	<i>p-valor</i>
IPCA	0,0194	0,6880	-0,0090	0,877	-0,0051	0,931	0,1740	0,2560
COMER.	-0,0010	0,9490	0,0046	0,814	0,0055	0,777	0,0069	0,8940
LIVRES	-0,0001	0,9950	0,0070	0,802	0,0084	0,762	-0,1081	0,1380
EX0	-0,0197	0,8250	-0,0312	0,769	-0,0016	0,988	0,4077	0,1450
EX1	-0,0046	0,9420	0,0146	0,848	0,0271	0,724	0,1906	0,3460
MA	0,0198	0,8520	-0,0052	0,967	0,0295	0,817	0,4205	0,2090
MS	0,0291	0,7950	-0,0907	0,498	-0,0797	0,552	0,5033	0,1530
DP	0,0024	0,9790	-0,0342	0,754	-0,0144	0,895	0,2755	0,3410

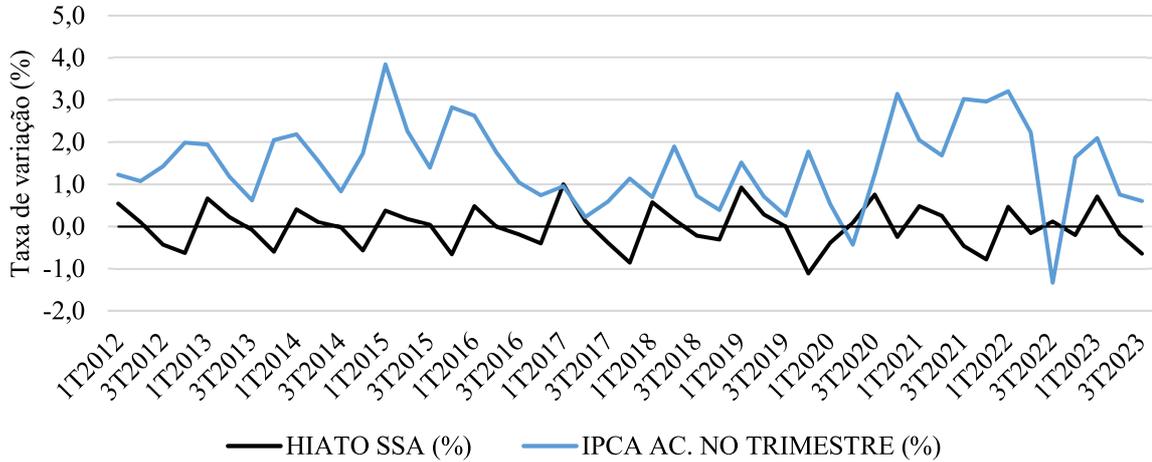
Fonte: Elaboração própria. Nota: * caracteriza a rejeição da hipótese nula a 10%; ** caracteriza rejeição da hipótese nula a 5%; *** caracteriza rejeição da hipótese nula a 1%.

No que se refere à metodologia SSA, conforme comentado anteriormente, a Tabela 1 evidenciou que as NAIRUs SSA e MSSA trocaram de posição com a série de desemprego, em média, a cada 2 trimestres. Contudo, ao contrário do modelo UCM, deve-se dizer que isso ocorreu na média porque essa alternância foi quebrada em diversos pontos da amostra: entre os anos de 2015 e 2016; para os três primeiros trimestres de 2019; e do 1T2022 até o final da amostra, intervalo em que a taxa de desemprego volta a reduzir a níveis semelhantes ao do início da série.

Além de demonstrar o padrão do comportamento da taxa de desemprego em relação à NAIRU, a Tabela 1 apresentou a semelhança no comportamento da NAIRU entre os modelos univariado e multivariado. Do mesmo modo, essa semelhança pode ser visualizada na evolução

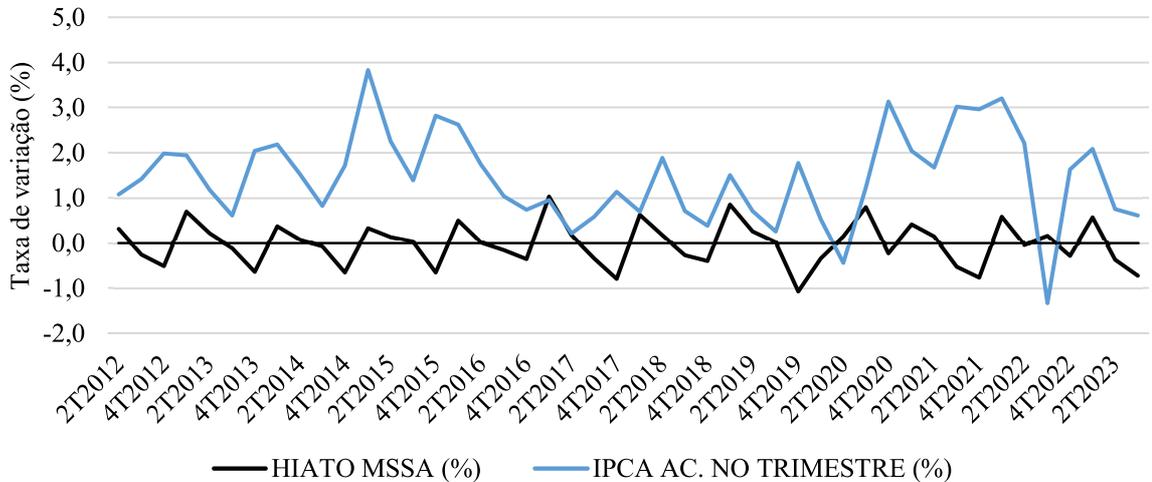
dos hiatos (Gráfico 27 e Gráfico 28) e nos resultados dos testes (Tabela 2 e Tabela 3). Portanto, tal similaridade entre os resultados dos modelos faz com que o modelo univariado seja preferido ao multivariado como ferramenta, visto que sua elaboração é mais simples.

Gráfico 27 - Hiato SSA e IPCA acumulado no trimestre



Fonte: Elaboração própria.

Gráfico 28 - Hiato MSSA e IPCA acumulado no trimestre

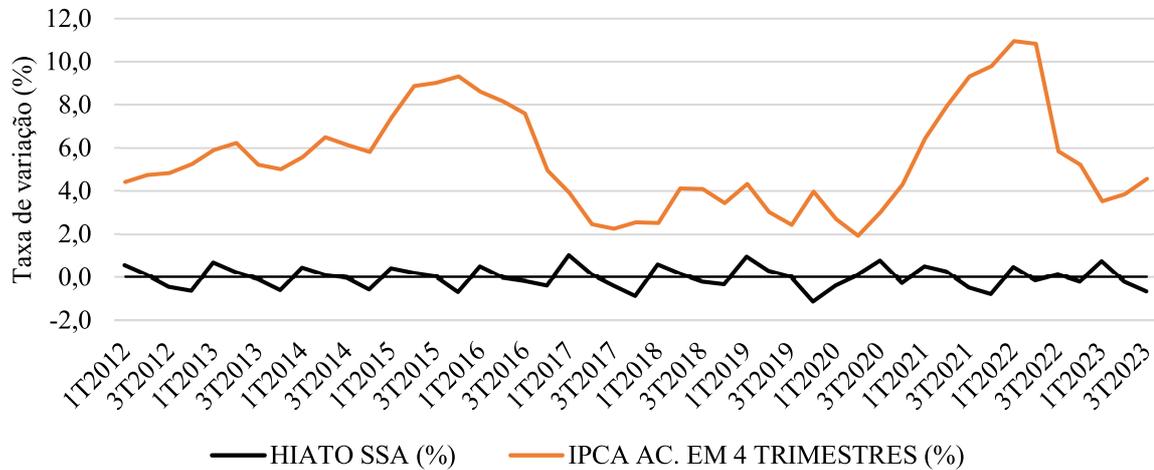


Fonte: Elaboração própria.

Então, com exceção dos períodos: 3T2016 – 2T2017 e 1T2020 - 3T2020, a NAIRU SSA foi condizente com o comportamento do IPCA acumulado no trimestre (Gráfico 27). Comparado à evolução do Hiato UCM com a inflação acumulada no trimestre, o Hiato SSA se diferenciou ao corresponder com mais trimestres de variações abruptas da inflação, isso porque a variável apontou os movimentos do índice ainda no transcorrer da crise política e fiscal entre o 1T2015 e o 2T2016, e logo após o terceiro trimestre de 2020 - período ainda acometido pela

pandemia de Covid-19. Com isso, a NAIRU SSA se adaptou melhor aos períodos de irregularidade⁷¹ da inflação quando comparada à NAIRU UCM.

Gráfico 29 - Hiato SSA e IPCA acumulado em 4 trimestres



Fonte: Elaboração própria.

Em relação ao Hiato SSA e o IPCA acumulado em 4 trimestres (Gráfico 29), assim como para a NAIRU UCM, a NAIRU SSA – e consequentemente a NAIRU MSSA - não foi capaz de acompanhar a evolução da inflação nesse segundo horizonte, falhando em antecipar o comportamento do índice ao longo de todo o período amostral. Portanto, mesmo com algumas poucas exceções em períodos de maior frequência do IPCA acumulado em 4 trimestres, evidencia-se que as NAIRUs que evoluíram próximas à série de desemprego não foram apropriadas para apontar o comportamento da inflação em um horizonte maior do que o acumulado no trimestre.

Os resultados dos testes, tanto para o IPCA acumulado no trimestre quanto em 4 trimestres, corroboraram com os indícios obtidos na análise gráfica (Tabela 2 e Tabela 3). Ademais, as Tabelas 2 e 3 ressaltam novamente à similaridade entre a NAIRU SSA e a NAIRU MSSA, o que reforçou o indicativo de que a série de inflação dos salários não contribuiu substancialmente para obtenção da variável não observável.

Quanto aos resultados dos testes para o IPCA acumulado no trimestre expostos na Tabela 2, os modelos não paramétricos foram capazes de fornecer uma NAIRU consistente para o IPCA. Dados os demais resultados, todos apresentando o sinal negativo, estes evidenciaram que a consistência das NAIRUs obtidas através dos modelos não paramétricos são robustas na

⁷¹ Nesse contexto, o termo irregularidade se refere às bruscas variações da inflação acumulada no trimestre que se destoaram do comportamento do índice no restante da amostra.

correspondência com a inflação acumulada no trimestre. Ademais, é necessário ressaltar a significância estatística dos coeficientes para as séries que retiram os preços administrados do índice cheio (IPCA - Livres e núcleo EX0), indicando que – no acumulado no trimestre - a NAIRU acompanha a variação dos itens com preço flutuante que compõem o índice.

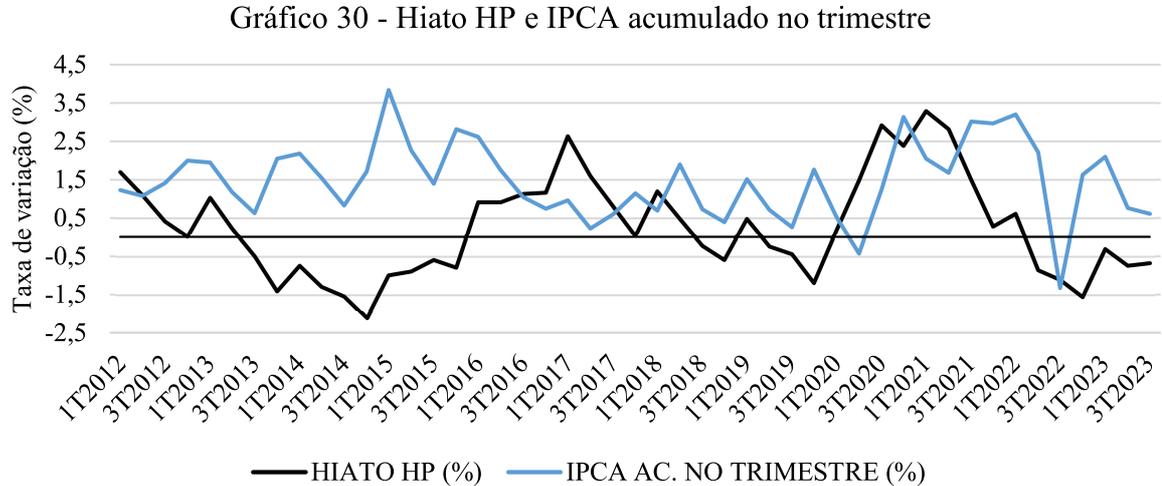
Ainda na discussão para esse primeiro horizonte, os resultados dos testes das NAIRUs UCM, SSA e MSSA vão de acordo com o resultado encontrado por Nobrega, Besarria e Oliveira (2020) ao testar, conforme proposta de Portugal e Madalozzo (2000), sua NAIRU para o INPC trimestral, isto é, um coeficiente negativo e estatisticamente significativo. Quanto ao trabalho de Oliveira, Portugal e Abrita (2016) – também utilizando o INPC trimestral - o coeficiente foi positivo e não significativo, contudo, os autores argumentaram que a análise gráfica da variável demonstrou que a NAIRU estimada foi robusta no acompanhamento da inflação ao longo do período trabalhado – entre 2000 e 2013, destoando do que foi encontrado neste trabalho, em que os resultados dos testes corroboraram com a análise gráfica para o comportamento do IPCA acumulado no trimestre.

No que diz respeito aos testes para as séries acumuladas em 4 trimestres (Tabela 3), o modelo univariado apresentou sinal negativo em 5 das 8 séries testadas, incluindo para o IPCA – o que não ocorreu no modelo UCM. Contudo, assim como discutido anteriormente, os valores dos coeficientes foram pequenos e não significativos e, considerando a análise gráfica da evolução do hiato frente ao IPCA acumulado em 4 trimestres, os sinais negativos dos coeficientes não refletiram a inconsistência das variáveis em indicar o comportamento da inflação nesse segundo horizonte. Portanto, a NAIRU SSA e a NAIRU MSSA se mostraram adequadas apenas para o acumulado no trimestre.

Em relação aos resultados obtidos via Filtro HP, a principal característica da NAIRU HP é o comportamento suavizado em relação à série do desemprego, contrastando com o comportamento das outras mensurações vistas até o momento. Através da Tabela 1 é possível observar que essa suavização implica em períodos muito maiores para a alternância entre a taxa de desemprego e a NAIRU. Um exemplo dessa diferença na relação entre as duas variáveis, pode ser visualizado entre o 3T2013 e o 4T2015, período em que a taxa de desemprego se situou 10 trimestres abaixo da NAIRU. Posteriormente essa relação é invertida e, entre o 1T2016 e o 2T2018, a taxa de desemprego ficou por mais 10 trimestres acima da NAIRU.

Portanto, como consequência do comportamento da NAIRU HP e como esta evolui ao longo do tempo junto com a taxa de desemprego corrente, ao longo do período analisado o

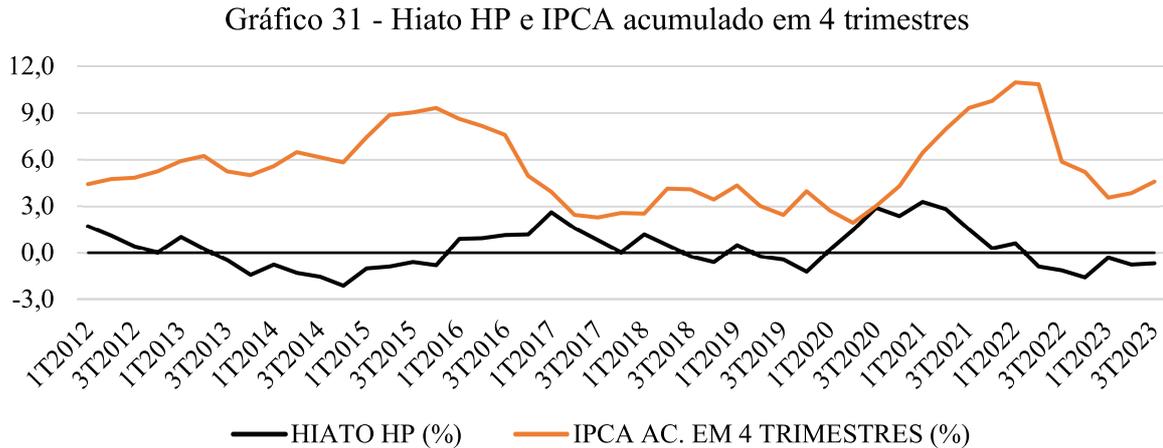
Hiato HP permaneceu positivo ou negativo por intervalos bem maiores que nas análises dos demais modelos. O Gráfico 30 apresenta a evolução do Hiato HP junto com o IPCA acumulado no trimestre.



Fonte: Elaboração própria.

Para o IPCA acumulado no trimestre, o Hiato HP não foi capaz de acompanhar o comportamento da inflação por toda a amostra. Logo, os curtos períodos nos quais Hiato HP indicou o comportamento da inflação, como entre 2016 e a primeira metade de 2017 e posteriormente ao longo de 2019, não foram suficientes para afirmar que a NAIRU HP é consistente com o comportamento da inflação nesse primeiro horizonte.

O início da amostra serve como exemplo da inconsistência da mensuração em apontar o comportamento do IPCA, isso porque o hiato negativo ao longo de 10 trimestres – 3T2013 ao 4T2015 – não correspondeu a contínuas acelerações da inflação para o mesmo período, visto que o hiato negativo indicaria sucessivas pressões para aumento da inflação ao longo de todo o período. Mesmo assim, é necessário destacar que - apesar das fortes variações nesse período - a série do IPCA acumulada no trimestre apresentou uma tendência positiva antes da brusca queda após o 1T2016, desse modo, quando analisadas as variações acumuladas em 4 trimestres do IPCA, o Hiato HP se mostrou uma boa ferramenta para acompanhar o comportamento do IPCA acumulado em 4 trimestres (Gráfico 31).



Fonte: Elaboração própria.

Com a ressalva dos períodos 4T2017-1T2018 e do 3T2020 ao 1T2022 – este último compreendendo o choque de oferta decorrente da crise de Covid-19, a NAIRU HP foi capaz de acompanhar os movimentos da inflação para o acumulado em 4 trimestres, incluindo o período da crise econômica e instabilidade política entre os anos de 2015 e 2016. Dessa forma, dentre todas as medidas avaliadas até o momento, a NAIRU HP foi a única que conseguiu apontar coerentemente o comportamento do IPCA acumulado em 4 trimestres por todo o período amostral.

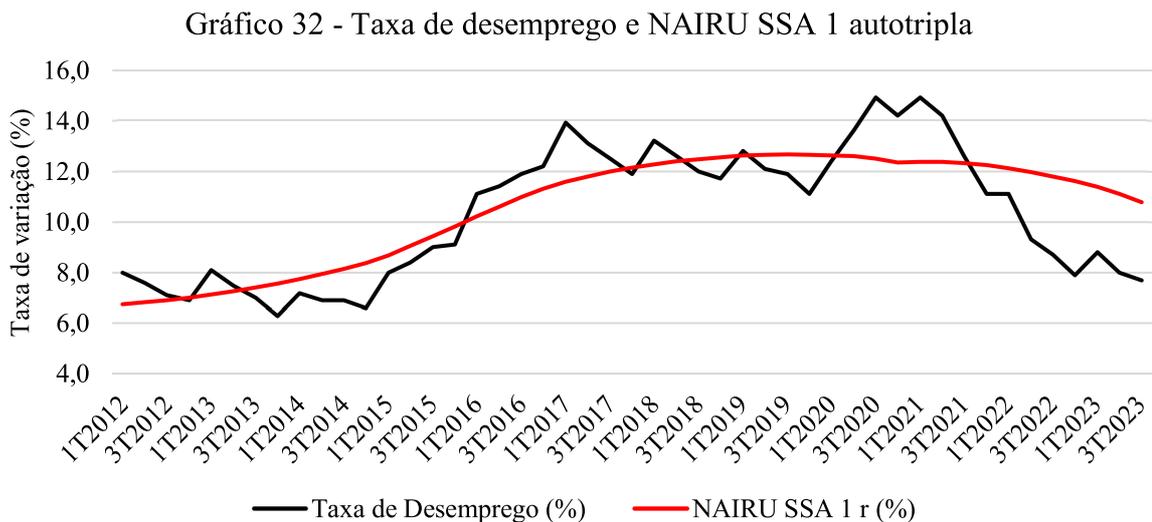
No que diz respeito aos testes realizados para a NAIRU HP (Tabela 2 e Tabela 3), os resultados em relação às séries acumuladas no trimestre vão de acordo com a análise do acompanhamento do IPCA acumulado no trimestre, isto é, o Hiato HP não corresponde às tendências de aumento ou redução do índice para esse horizonte.

Para as séries acumuladas em 4 trimestres (Tabela 3), o Hiato HP também apresentou o sinal negativo para a série do IPCA Livres com um nível de confiança de 85%, indicando a consistência da NAIRU HP para a parte da inflação que não é influenciada pela rigidez de preços. Apesar da ausência de outros coeficientes negativos nesse segundo horizonte, a investigação do Gráfico 31 mostrou que a NAIRU HP é adequada para acompanhar os movimentos do IPCA no acumulado em 4 trimestres. Ademais, a ausência dos coeficientes negativos pode ser remetida à ausência dos componentes sazonais na estimação da equação, componentes estes que provavelmente influenciaram os resultados das estimações dos testes no acumulado no trimestre para as NAIRUs UCM, SSA e MSSA (Tabela 2).

Considerando a característica das tendências mensuradas, o contraste dos resultados para o acompanhamento do IPCA acumulado no trimestre e do IPCA acumulado em 4 trimestres levantou o questionamento sobre a eficiência da NAIRU que evolui próxima à série

de desemprego em acompanhar a inflação acumulada no trimestre e da variável obtida a partir de tendência suavizada em acompanhar a inflação acumulada em 4 trimestres. Com isso, explorando a versatilidade da metodologia SSA, foi obtida – e colocada sob análise – uma NAIRU mensurada a partir do mesmo modelo SSA univariado utilizado anteriormente, agora, porém, a tendência foi reconstruída utilizando apenas a primeira autotripla.

Conforme ressaltado na seção 3.3, Golyandina, Nekruktin e Zhigljavsky (2001) relataram que é possível obter uma tendência suavizada – ou uma tendência que represente o comportamento geral da série trabalhada pelo pesquisador – no modelo SSA a partir da escolha do primeiro(s) componente(s) do modelo na etapa de reconstrução. Então, neste caso a NAIRU foi construída utilizando a primeira autotripla (r) resultante da etapa de decomposição, esta que representou sozinha 98,18% de toda a variância da série do desemprego na primeira etapa do modelo.



Fonte: Elaboração própria.

O Gráfico 32 também expõe uma NAIRU suavizada, de forma semelhante à NAIRU HP. A Tabela 4 apresenta os valores mensurados da variável e relaciona se a série de desemprego está acima ou abaixo da nova variável, lado a lado com outras mensurações já vistas. A partir dela, é possível observar que, apesar da semelhança, a NAIRU SSA 1 autotripla se difere na quantidade de trimestres em que as trocas de posição ocorreram, são exemplos: o desemprego abaixo da NAIRU SSA 1 autotripla no início da amostra; o período de dominância de 10 trimestres ocorreu apenas uma vez para a NAIRU SSA 1 autotripla; revezamento das variáveis entre 2017 e início de 2020 com frequência maior que nos demais períodos.

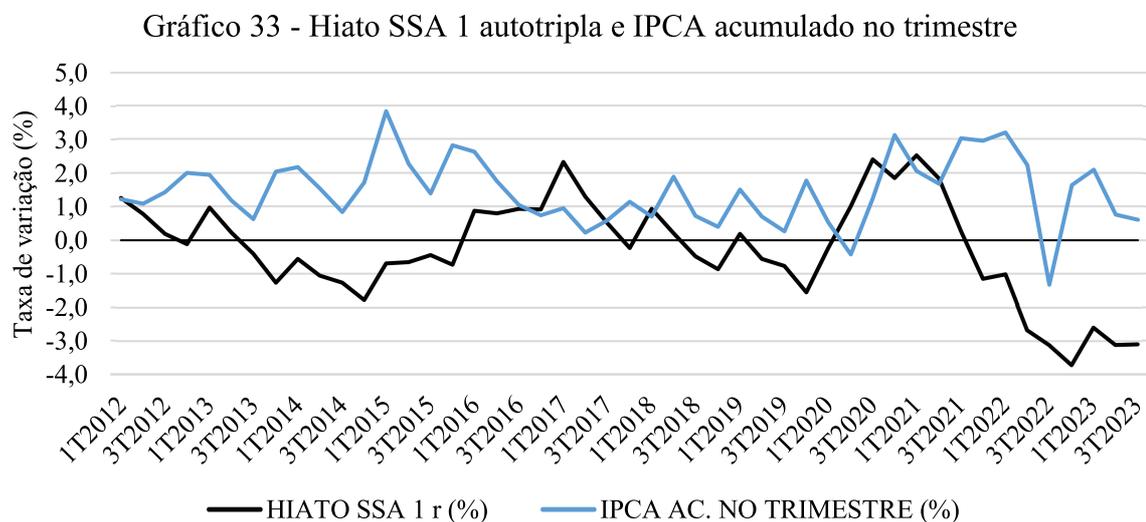
Tabela 4 - Posição ABAIXO/ACIMA da taxa de desemprego frente às NAIRUs selecionadas e NAIRU SSA 1 autotripla

Trimestre	Taxa de Desemprego (%)	NAIRU SSA (%)		NAIRU HP (%)		NAIRU SSA 1 autotripla (%)	
1T2012	8,0	7,449	ACIMA	6,308	ACIMA	6,752	ACIMA
2T2012	7,6	7,495	ACIMA	6,498	ACIMA	6,823	ACIMA
3T2012	7,1	7,520	ABAIXO	6,689	ACIMA	6,911	ACIMA
4T2012	6,9	7,515	ABAIXO	6,881	ACIMA	7,019	ABAIXO
1T2013	8,1	7,440	ACIMA	7,077	ACIMA	7,135	ACIMA
2T2013	7,5	7,275	ACIMA	7,278	ACIMA	7,264	ACIMA
3T2013	7,0	7,070	ABAIXO	7,487	ABAIXO	7,407	ABAIXO
4T2013	6,3	6,887	ABAIXO	7,706	ABAIXO	7,567	ABAIXO
1T2014	7,2	6,786	ACIMA	7,938	ABAIXO	7,746	ABAIXO
2T2014	6,9	6,789	ACIMA	8,182	ABAIXO	7,945	ABAIXO
3T2014	6,9	6,911	ABAIXO	8,441	ABAIXO	8,153	ABAIXO
4T2014	6,6	7,163	ABAIXO	8,713	ABAIXO	8,365	ABAIXO
1T2015	8,0	7,616	ACIMA	8,997	ABAIXO	8,688	ABAIXO
2T2015	8,4	8,222	ACIMA	9,291	ABAIXO	9,048	ABAIXO
3T2015	9,0	8,953	ACIMA	9,591	ABAIXO	9,433	ABAIXO
4T2015	9,1	9,757	ABAIXO	9,894	ABAIXO	9,825	ABAIXO
1T2016	11,1	10,616	ACIMA	10,194	ACIMA	10,220	ACIMA
2T2016	11,4	11,406	ABAIXO	10,487	ACIMA	10,605	ACIMA
3T2016	11,9	12,078	ABAIXO	10,767	ACIMA	10,968	ACIMA
4T2016	12,2	12,586	ABAIXO	11,032	ACIMA	11,296	ACIMA
1T2017	13,9	12,901	ACIMA	11,276	ACIMA	11,575	ACIMA
2T2017	13,1	12,958	ACIMA	11,497	ACIMA	11,797	ACIMA
3T2017	12,5	12,873	ABAIXO	11,693	ACIMA	11,978	ACIMA
4T2017	11,9	12,745	ABAIXO	11,864	ACIMA	12,136	ABAIXO
1T2018	13,2	12,620	ACIMA	12,009	ACIMA	12,271	ACIMA
2T2018	12,6	12,428	ACIMA	12,128	ACIMA	12,383	ACIMA
3T2018	12,0	12,207	ABAIXO	12,220	ABAIXO	12,477	ABAIXO
4T2018	11,7	12,009	ABAIXO	12,287	ABAIXO	12,555	ABAIXO
1T2019	12,8	11,876	ACIMA	12,328	ACIMA	12,613	ACIMA
2T2019	12,1	11,807	ACIMA	12,343	ABAIXO	12,649	ABAIXO
3T2019	11,9	11,894	ACIMA	12,331	ABAIXO	12,662	ABAIXO
4T2019	11,1	12,202	ABAIXO	12,291	ABAIXO	12,653	ABAIXO
1T2020	12,4	12,783	ABAIXO	12,223	ACIMA	12,628	ABAIXO
2T2020	13,6	13,505	ACIMA	12,123	ACIMA	12,588	ACIMA
3T2020	14,9	14,139	ACIMA	11,990	ACIMA	12,504	ACIMA
4T2020	14,2	14,441	ABAIXO	11,822	ACIMA	12,354	ACIMA
1T2021	14,9	14,419	ACIMA	11,618	ACIMA	12,380	ACIMA
2T2021	14,2	13,947	ACIMA	11,380	ACIMA	12,374	ACIMA
3T2021	12,6	13,048	ABAIXO	11,111	ACIMA	12,327	ACIMA
4T2021	11,1	11,873	ABAIXO	10,814	ACIMA	12,241	ABAIXO
1T2022	11,1	10,633	ACIMA	10,496	ACIMA	12,120	ABAIXO
2T2022	9,3	9,446	ABAIXO	10,161	ABAIXO	11,969	ABAIXO
3T2022	8,7	8,572	ACIMA	9,814	ABAIXO	11,798	ABAIXO
4T2022	7,9	8,103	ABAIXO	9,459	ABAIXO	11,607	ABAIXO
1T2023	8,8	8,086	ACIMA	9,100	ABAIXO	11,385	ABAIXO
2T2023	8,0	8,182	ABAIXO	8,739	ABAIXO	11,105	ABAIXO
3T2023	7,7	8,334	ABAIXO	8,377	ABAIXO	10,779	ABAIXO

Fonte: Elaboração própria.

Quando colocado lado a lado com o IPCA acumulado no trimestre (Gráfico 33), a NAIRU SSA 1 autotripla correspondeu ao comportamento do índice nesse horizonte apenas para poucos trimestres da amostra. Então, de forma similar ao observado para o caso HP, o Hiato SSA 1 autotripla não foi capaz de indicar o comportamento da inflação para o acumulado no trimestre, reforçando o indício de que as NAIRUs mensuradas a partir de uma tendência suavizada não são as ferramentas indicadas para acompanhar o comportamento deste primeiro horizonte da inflação. Isso também pode ser observado na comparação direta entre a NAIRU SSA – esta que evolui próxima à taxa de desemprego – e a NAIRU SSA 1 autotripla, visto que, sendo ambas retiradas do mesmo modelo, a NAIRU SSA foi capaz de acompanhar o IPCA acumulado no trimestre, ao contrário da NAIRU SSA 1 autotripla.

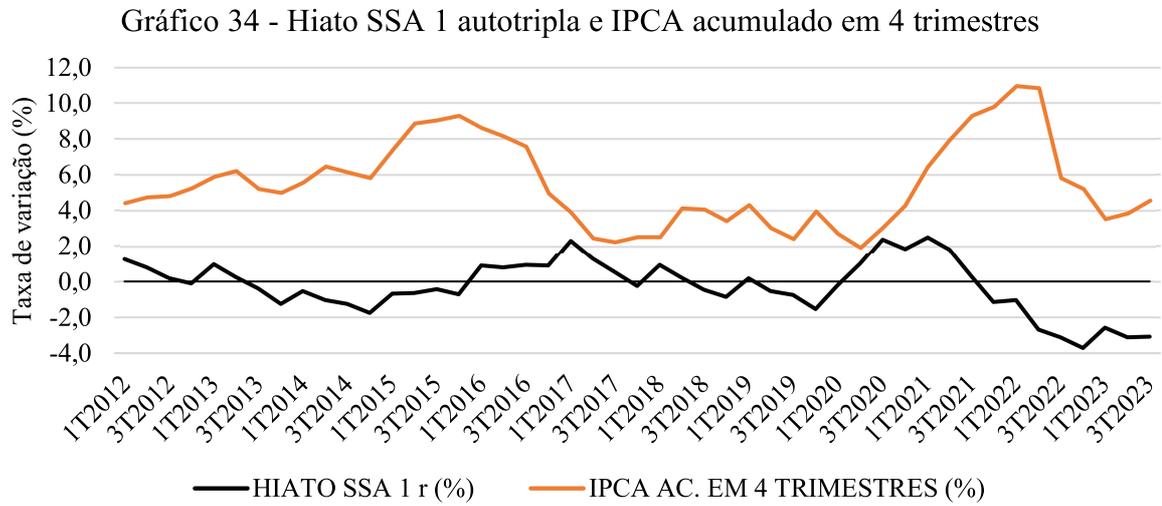
A inconsistência da NAIRU SSA 1 autotripla para o IPCA acumulado no trimestre, pode ser exemplificada com os três últimos trimestres da amostra, na qual, novamente, a variável mensurada a partir da tendência suavizada não foi capaz de apontar o comportamento da inflação nem para os trimestres que já não foram afetados pela crise sanitária. Ademais, dado o período em que a NAIRU foi dominante nos 10 trimestres entre 2013 e 2015 (Tabela 4) não foi observado um aumento da inflação na mesma proporção no IPCA acumulado no trimestre, apenas a já mencionada tendência positiva que foi encerrada em 2016.



Fonte: Elaboração própria.

Assim, quando o comportamento acumulado da inflação foi analisado no segundo horizonte, a NAIRU SSA 1 autotripla se destacou como ferramenta (Gráfico 34). Isso porque, exceto para o período da crise sanitária e para o último ano da amostra na qual a NAIRU suavizada ainda não acompanhou a redução brusca do desemprego após a crise, para todo o

restante do período amostral o Hiato SSA 1 autotripla acompanhou consistentemente o movimento do IPCA acumulado em 4 trimestres.



Fonte: Elaboração própria.

Dessa forma, ambas as NAIRUs mesuradas a partir de uma tendência suavizada se adequaram melhor para análise da inflação no acumulado em 4 trimestres, em que o índice apresenta baixa frequência, dada a persistência dos aumentos e reduções da inflação. Os resultados da NAIRU HP e da NAIRU SSA 1 autotripla para a inflação acumulada em 4 trimestres também se assemelharam à mensuração da NAIRU de Palma e Ferreira (2017), na qual os autores verificaram que seu hiato positivo correspondeu a uma tendência decrescente da inflação, esta trabalhada pelos autores com periodicidade mensal.

No que diz respeito aos testes para as diferentes medidas de inflação nos dois horizontes trabalhados, a NAIRU SSA 1 autotripla, assim como para o HP, não apresentou consistência para nenhuma das séries testadas no horizonte acumulado no trimestre (Tabela 5). Quando colocados os resultados lado a lado, percebe-se melhor que a característica da tendência influenciou na qualidade da ferramenta em acompanhar o comportamento da inflação acumulada no trimestre, visto que, assim como observado na análise gráfica, a NAIRU SSA apresentou consistência para as séries e seus resultados foram robustos, diferentemente da NAIRU SSA 1 autotripla.

Quanto aos resultados para o segundo horizonte da inflação, a NAIRU SSA 1 autotripla apresentou coeficientes negativos apenas para alguns testes com as séries acumuladas em 4 trimestres, sendo consistente e significativa a 5% para a série IPCA – Livres (Tabela 6).

Tabela 5 - Resultados dos testes da NAIRU SSA 1 autotripla e NAIRUs selecionadas para as séries acumuladas no trimestre

	NAIRU SSA		NAIRU HP		NAIRU SSA 1 autotripla	
	Coefficiente	<i>p-valor</i>	Coefficiente	<i>p-valor</i>	Coefficiente	<i>p-valor</i>
IPCA	-0,0592	0,3470	0,0063	0,9700	0,0523	0,7890
COMER.	-0,0551	0,3310	0,0380	0,8020	0,0450	0,7980
LIVRES	-0,1433**	0,0476	-0,0467	0,8120	0,0393	0,8640
EX0	-0,2758**	0,0141	0,0475	0,8780	0,1614	0,6530
EX1	-0,0023	0,9840	0,1706	0,5600	0,2673	0,4320
MA	-0,2393	0,1440	0,1501	0,7330	0,3404	0,5060
MS	-0,2186	0,2440	0,3130	0,5330	0,5913	0,3090
DP	-0,1852	0,1930	0,0823	0,8290	0,2615	0,5560

Fonte: Elaboração própria. Nota: * caracteriza a rejeição da hipótese nula a 10%; ** caracteriza rejeição da hipótese nula a 5%; *** caracteriza rejeição da hipótese nula a 1%.

Tabela 6 - Resultados dos testes da NAIRU SSA 1 autotripla e NAIRUs selecionadas para as séries acumuladas em 4 trimestres

	NAIRU SSA		NAIRU HP		NAIRU SSA 1 autotripla	
	Coefficiente	<i>p-valor</i>	Coefficiente	<i>p-valor</i>	Coefficiente	<i>p-valor</i>
IPCA	-0,0090	0,877	0,1740	0,2560	0,2651	0,1340
COMER.	0,0046	0,814	0,0069	0,8940	-0,0413	0,4910
LIVRES	0,0070	0,802	-0,1081	0,1380	-0,1695**	0,0433
EX0	-0,0312	0,769	0,4077	0,1450	0,5121	0,1140
EX1	0,0146	0,848	0,1906	0,3460	0,2457	0,2950
MA	-0,0052	0,967	0,4205	0,2090	0,5517	0,1550
MS	-0,0907	0,498	0,5033	0,1530	0,6999*	0,0859
DP	-0,0342	0,754	0,2755	0,3410	0,3588	0,2850

Fonte: Elaboração própria. Nota: * caracteriza a rejeição da hipótese nula a 10%; ** caracteriza rejeição da hipótese nula a 5%; *** caracteriza rejeição da hipótese nula a 1%.

Ainda no que diz respeito aos testes, apesar da NAIRU SSA 1 autotripla apresentar resultados melhores no acumulado em 4 trimestres em relação à NAIRU HP – principalmente para o IPCA – Livres, o resultado do teste do IPCA não entrou em concordância com a análise gráfica do comportamento do respectivo hiato com o IPCA no acumulado em 4 trimestres, visto que o coeficiente também foi positivo e não significativo.

Isto posto, tendo em vista a adequação do Hiato SSA 1 autotripla para o IPCA acumulado em 4 trimestres argumentada anteriormente com o Gráfico 34 e a semelhança com o ocorrido para a avaliação do Hiato HP também para esse segundo horizonte, os resultados obtidos com as medidas suavizadas sinalizaram novamente que o teste pode estar capturando a sazonalidade das séries NAIRU UCM, SSA e MSSA e da série do IPCA acumulada no trimestre.

Finalmente, na comparação direta entre NAIRU HP e NAIRU SSA 1 autotripla, com base nos resultados dos testes e principalmente das análises gráficas, a NAIRU SSA 1 autotripla

apresentou resultados ainda melhores que o modelo HP para indicar o comportamento do IPCA acumulado em 4 trimestres. Assim, a NAIRU SSA 1 autotripla se mostrou a melhor ferramenta, dentre as mensurações obtidas nesse trabalho, para acompanhar o comportamento do IPCA acumulado em 4 trimestres.

Em suma, a presente seção teve por finalidade discutir se as medidas obtidas da NAIRU foram condizentes com os fatos estilizados expostos no capítulo 2 que definiram a relação taxa de desemprego, NAIRU e inflação de preços.

Dado que as NAIRUs mensuradas foram analisadas para dois horizontes diferentes do IPCA – acumulado no trimestre e acumulado em 4 trimestres, constatou-se que a eficácia das medidas obtidas para a inflação em cada um desses horizontes varia de acordo com a característica da tendência obtida. Em outras palavras, a análise do comportamento dos hiatos calculados a partir das NAIRU de cada modelo evidenciou dois resultados distintos.

O primeiro se refere às variáveis não observáveis que foram mensuradas a partir de uma tendência que evolui de maneira próxima à série do desemprego, caso da NAIRU UCM, NAIRU SSA e NAIRU MSSA. Estas variáveis foram consistentes em acompanhar o comportamento da inflação no acumulado no trimestre e se mostraram as ferramentas adequadas, e robustas, para apontar o comportamento da inflação nesse primeiro horizonte, contudo, quando utilizadas para indicar o comportamento do IPCA acumulado em 4 trimestres, as variáveis foram inconsistentes ao longo do período amostral e não são recomendadas para esta análise.

Além disso, apesar da NAIRU UCM ter apresentado melhores resultados nos testes baseados na proposta de Portugal e Madalozzo (2000) para o acumulado no trimestre, os resultados dos modelos não paramétricos foram condizentes com o escopo teórico abordado e, na análise gráfica, foram capazes de acompanhar o IPCA acumulado no trimestre em mais trimestres de crise econômica do que a NAIRU UCM. No entanto, os resultados do SSA e do MSSA foram muito similares e, portanto, o enfoque da análise e a recomendação como instrumento ficou para o modelo univariado, visto que sua construção é mais simples.

Quanto ao segundo resultado, este se refere à NAIRU HP obtida a partir de uma tendência suavizada. Diferente das outras medidas, apesar de não indicar coerentemente o comportamento da inflação no acumulado no trimestre, a NAIRU HP se destacou ao apontar consistentemente o comportamento do IPCA acumulado em 4 trimestres – sugerindo que uma NAIRU suavizada seja mais adequada para acompanhar a inflação nesse segundo horizonte.

Sob o objetivo de verificar essa suspeita, e utilizando a versatilidade da metodologia SSA, uma tendência suavizada foi obtida a partir do mesmo modelo SSA univariado empregado anteriormente, representando a tendência geral da série do desemprego – a NAIRU SSA 1 autotripla. Tal medida, além de permitir a comparação direta desses dois comportamentos distintos da tendência, reafirmou as suspeitas de que uma “NAIRU suavizada” é a ferramenta mais indicada para acompanhar a inflação acumulada na janela de 4 trimestres, visto que seus resultados foram não somente similares aos obtidos com o Filtro HP, como também melhores – sendo a variável consistente na análise gráfica e, portanto, a ferramenta indicada para acompanhar o comportamento da inflação no acumulado em 4 trimestres.

Por fim, um ponto em comum ao longo da seção foi o coeficiente negativo e a significância estatística para o teste com a série IPCA – Livres. Conforme apresentado na seção de base de dados, a série IPCA – Livres exclui os itens administrados, sendo assim, esses resultados assinalaram que as NAIRUs acompanharam principalmente aqueles itens que compõem o IPCA cujo preços são flexíveis.

6 CONCLUSÃO

Definida como a taxa de desemprego consistente com o movimento inflacionário, o objetivo deste trabalho foi realizar uma mensuração da NAIRU para a economia brasileira que fosse compatível com o *tradeoff* entre a taxa de desemprego e a inflação utilizando os dados da PNAD Contínua. Assim, estabelecida como a tendência da taxa de desemprego, quatro modelos foram propostos para extrair a variável: componentes não observados, filtro HP, SSA e MSSA. A série de desemprego utilizada nos modelos foi retirada da PNAD Contínua e compreendeu o período entre o 1T2012 e o 3T2023.

As diferentes medidas da NAIRU apresentaram uma taxa média próxima dos 10,5% para todo o período amostral, com crescimentos expressivos a partir de 2015 e posteriormente em 2020, voltando a reduzir apenas a partir de 2022. Sob outra perspectiva, esses 10,5% refletem que, em média, mais de 10 milhões de brasileiros precisariam estar desocupados para que a inflação não fosse pressionada pelo nível do emprego. Quanto à característica das variáveis, exceto pela mensuração feita com o filtro HP, os modelos capturaram uma NAIRU que evoluiu próxima a série de desemprego – o que resultou em um hiato com comportamento periódico que alterna, em média, a cada dois trimestres.

A discussão da conjuntura econômica da série do desemprego destacou dois períodos em que ocorreram a aceleração da variável – acarretando um crescimento da NAIRU e elevando sua média amostral em todas as estimativas, foram estes: a recessão econômica aliada à instabilidade política entre 2015 e 2016; e a crise de Covid-19 para os anos de 2020 a 2022. Além do desemprego, a inflação de preços também apresentou variações que contrariaram as expectativas e se destoaram de seu comportamento no restante do corte amostral – chegando a acelerar em períodos de recuo da produção. Tais comportamentos puderam ser vistos tanto para o IPCA acumulado no trimestre, quanto para o IPCA acumulado em 4 trimestres.

Feita a análise conjuntural, foi necessário verificar se as diferentes medidas da NAIRU se adequaram ao comportamento de *tradeoff* das taxas de desemprego e inflação para a economia brasileira, conforme definição de Stiglitz (1997) e Grant (2002), isto é, avaliar se as mensurações obtidas foram consistentes. Para tal, dois métodos foram empregados: a análise gráfica da evolução do hiato do desemprego e do IPCA, e o teste baseado em Portugal e Madalozzo (2000). No primeiro, o IPCA foi avaliado em dois horizontes distintos, o acumulado no trimestre e o acumulado em 4 trimestres. Já no segundo, também foram incorporados aos

testes outras séries relacionadas ao IPCA, também para os dois horizontes já citados, sendo estas: IPCA – Livres, IPCA – Comercializáveis e alguns núcleos selecionados.

Dentre as avaliações das medidas realizadas, o principal resultado foi a evidência de que a frequência com a qual a NAIRU alterna de posição com a taxa de desemprego influencia na capacidade da ferramenta em acompanhar comportamento do IPCA nos dois horizontes abordados nesse trabalho. Com isso, as NAIRUs que evoluíram próximas à série de desemprego foram as ferramentas mais adequadas para acompanhar o IPCA acumulado no trimestre, enquanto as NAIRUs obtidas a partir de uma tendência suavizada foram as melhores para o IPCA acumulado em 4 trimestres.

As NAIRUs UCM, SSA e MSSA foram as variáveis que conseguiram acompanhar o comportamento do IPCA acumulado no trimestre. Entre estas, a ferramenta que apresentou os melhores resultados foi a NAIRU SSA, dado que a variável apontou o comportamento do IPCA em mais trimestres que a NAIRU UCM. A consistência da NAIRU SSA em relação à inflação acumulada no trimestre também foi evidenciada nos resultados dos testes para as séries de inflação, e seus núcleos, visto que os resultados do sinal do coeficiente foram robustos para as demais séries além do IPCA acumulado no trimestre. Sendo assim, o modelo não paramétrico foi capaz de fornecer uma NAIRU que possui utilidade no acompanhamento da inflação acumulada no trimestre e, portanto, é condizente com a proposta da literatura.

Quanto à relação das mensurações com o IPCA acumulado em 4 trimestres, as NAIRUs que foram capazes de acompanhar o movimento do índice foram a NAIRU HP e a NAIRU SSA 1 autotripla. A NAIRU SSA 1 autotripla foi extraída do mesmo modelo SSA utilizado no capítulo 4, sob o objetivo de verificar se uma tendência que representasse o comportamento geral da série de desemprego seria capaz de acompanhar melhor o comportamento do IPCA acumulado em 4 trimestres. Isto posto, a característica de baixa frequência na alternância com a série de desemprego resultou em um hiato condizente com o comportamento do índice nesse segundo horizonte, para ambos os modelos.

Dentre as duas variáveis, a NAIRU SSA 1 autotripla se mostrou uma variável ainda mais adequada que a NAIRU HP, isso porque foi capaz de acompanhar o movimento da inflação nesse segundo horizonte em mais trimestres do que a mensuração HP. Em relação aos testes, com exceção da série IPCA – Livres, os demais resultados contradisseram a análise gráfica realizada para ambas as variáveis, quanto a isso, suspeita-se que a ausência do componente sazonal nessas séries tenha influenciado os resultados para a ausência dos sinais

negativos dos coeficientes e de sua respectiva significância estatística. Finalmente, dadas as avaliações das mensurações obtidas, o modelo SSA proposto forneceu as mensurações mais adequadas para lidar com os dois diferentes horizontes da inflação.

Além dos resultados para estes dois horizontes, é necessário ressaltar os resultados dos testes realizados para as séries IPCA – Livres e núcleo EX0 ao longo da seção 5.2, dado que apresentaram consistência e significância estatística ao longo de toda a seção. Assim, os resultados expuseram a relação entre a NAIRU e os itens que não possuem rigidez de preço dentro do índice de inflação, sendo, em grande parte, os itens que afetam o dia a dia do consumidor brasileiro.

Posto os resultados, é preciso ressaltar que este trabalho não está livre de limitações. A principal limitação foi o desafio proposto pelo seu objetivo, isto é, o tamanho da amostra utilizada para a mensuração da NAIRU, limitação esta que é fruto da disponibilidade dos dados da PNAD Contínua. Outra limitação foi a proximidade dos resultados entre o modelo univariado e o multivariado da metodologia SSA, portanto, preferenciando a maior simplicidade na elaboração do modelo univariado, os resultados do SSA foram preferidos ao invés do MSSA neste trabalho.

Por fim, para pesquisas futuras sugere-se a investigação, e proposta, de outros modelos multivariados para obtenção da NAIRU, além do emprego dos dados atualizados da PNAD Contínua. Sugere-se também a avaliação de medidas futuras da NAIRU para diferentes horizontes da inflação, visto que as características da série de inflação podem influenciar no acompanhamento de seu comportamento. Finalmente, recomenda-se o emprego da metodologia SSA para a obtenção de outras variáveis não observáveis, ou decomposição de séries econômicas – como a decomposição do produto para obter seu hiato.

REFERÊNCIAS

- ANDREI, A. M. Using asymmetric Okun law and Phillips Curve for potential output estimates: an empirical study for Romania. **REVISTA ADMINISTRATIE SI MANAGEMENT PUBLIC**, n.23, p. 6-18, 2014.
- ARLTOVÁ, M. FEDOROVÁ, D. Selection of Unit Root Test on the Basis of Length of the Time Series and Value of AR(1) Parameter. **Statistika: Statistics and Economy Journal**, v.96, n.3, p. 47 – 64, set. 2016.
- BALCILAR, M. mFilter: Miscellaneous Time Series Filters. **CRAN Repository**. Disponível em: < <https://cran.r-project.org/web/packages/mFilter/index.html>>. Acesso em: 25 nov. 2023.
- BALL, L; MANKIW, N. G. The NAIRU in Theory and Practice. **Journal of Economic Perspectives**, v.16, n.4, p. 115-136, outono de 2002.
- BANCO CENTRAL DO BRASIL - BCB. **Relatório de Inflação**, Brasília, v.13, n.4, p. 1-153, dez. 2011.
- BANCO CENTRAL DO BRASIL - BCB. **Relatório de Inflação**, Brasília, v.14, n.1, p. 1-145, mar. 2012.
- BANCO CENTRAL DO BRASIL – BCB. **Sistema Gerenciador de Séries Temporais**. Disponível em: <<https://www3.bcb.gov.br/sgspub/localizarseries/localizarSeries.do?method=prepararTelaLocalizarSeries>>. Acesso em: 23 de nov. 2023.
- BANCO CENTRAL DO BRASIL – BCB. **Comunicados do Copom**. Disponível em: < <https://www.bcb.gov.br/controleinflacao/comunicadoscopom/cronologicos>>. Acesso em: 29 de ago. 2024a.
- BANCO CENTRAL DO BRASIL – BCB. **Taxas de juros básicas – Histórico**. Disponível em: < <https://www.bcb.gov.br/controleinflacao/historicotaxasjuros>>. Acesso em: 28 de ago. 2024b.
- BELL, D. N. F.; BLANCHFLOWER, D. G. The lack of wage growth and the falling NAIRU. **National Institute Economic Review**. Londres, v.245, p. R40-R55, ago. 2018.
- BLANCHARD, O.; KATZ, L. F. What We Know and Do Not Know About the Natural Rate of Unemployment. **Journal of Economic Perspectives**, v.11, n.1, p. 51-72, dez.-mar. 1997.

BOX, G. E. P.; PIERCE, D. A. Distribution of Residual Autocorrelations in Autorregressive-Integrated Moving Average Time Series Models. **Journal of the American Statistical Association**, v.65, n.332, p. 1509-1526, 1970.

CAPEHART, K. W. What's the natural rate of unemployment? Answers from forecasters. **International Review of Applied Economics**, Londres, v.33, n.5, p.712-732, jan. 2019.

CARVALHO, M. de.; RODRIGUES, P. C.; RUA, A. Tracking the US business cycle with a singular spectrum analysis. **Economics Letters**, v.114, n.1, p. 32-35, jan. 2012.

CHOWDHURY, K. R. Rucm: Implementation of Unobserved Components Model (UCM). **CRAN Repository**. Disponível em: <<https://cran.r-project.org/web/packages/rucm/index.html>>. Acesso em: 25 nov. 2023.

CLAAR, Victor V. Is the NAIRU more useful in forecasting inflation than the natural rate of unemployment? **Applied Economics**, v.38, n.18, p. 2179-2189, 2006.

CONSTANTINESCU, M.; NGUYEN A. D. M. Unemployment or Credit: Wich One Holds the Potential? Results for a Small-Open Economy with a Low-Degree of Financialization. **Economic Systems**, v.42, n.4, p. 649-664, dez. 2018.

CROMWELL, J. B.; LABYS, W. C.; TERRAZA, M. **Univariate Tests for Time Series Models**. 1. Ed. Thousand Oaks: Sage Publications, p. 20-22, 1994.

DA SILVA, D. F. R. Friedman, Phelps, Lucas and the Natural Rate of Unemployment. In: XXXIX Encontro Nacional de Economia (Anpec), 2011, Foz do Iguaçu. **Texto para discussão**, p. 1-20, 2011.

DE JONG, R. M.; SAKARYA, N. The Econometrics of the Hodrick-Prescott Filter. **The Review of Economics and Statistics**, v.98, n.2, p. 310-317, mai. 2016.

DEPARTAMENTO INTERSINDICAL DE ESTATÍSTICA E ESTUDOS SOCIOECONÔMICOS – DIEESE. **Pesquisa de Emprego e Desemprego**. Disponível em: <<https://www.dieese.org.br/analisedped/ped.html>>. Acesso em: 02 ago. 2023.

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

DIEBOLD, F. X.; MARIANO, R. S. Comparing Predictive Accuracy. **Journal of Business & Economic Statistics**, v. 13, n. 3, p. 134–144, jul. 1995.

DOMÉNECH, R.; GÓMEZ, V. Estimating Potential Output, Core Inflation, and the NAIRU as Latent Variables. **Journal of Business & Economic Statistics**, Londres, v.24, n.3, p.354-365, 2006.

DUTRA, R. C. D. **Estimação da NAIRU do Brasil entre 2002 e 2011**, 2011. 64 p. Dissertação (Mestrado) – Insper Instituto de Ensino e Pesquisa, São Paulo, 2011.

EMMANUEL, S. S. *et al.* Cross country relations in European tourist arrivals. **Annals of Tourism Research**, v.63, n.1, p. 151-168, mar. 2017.

FRIEDMAN, M. The Role of Monetary Policy. **The American Economic Review**, v. 58, n.1, p. 1-17, mar. 1968.

FUNDAÇÃO GETÚLIO VARGAS – FGV/IBRE. **Indicador de Incerteza da Economia do Brasil (IIE-Br)**. Disponível em: < <https://extra-ibre.fgv.br/IBRE/sitefgvdados/consulta.aspx>>. Acesso em: 28 ago. 2024.

GALÍ, J. The Return of The Wage Phillips Curve. **Journal of European Economic Association**, v.9, n.3, p. 436-461, jun. 2011.

GOLYANDINA, N. *et al.* Multivariate and 2D Extensions of Singular Spectrum Analysis with the Rssa Package. **Journal of Statistical Software**, v.67, n.2, p. 1-78, out. 2015.

GOLYANDINA, N.; KOROBEYNIKOV, A.; ZHIGLJAVSKY, A. **Singular Spectrum Analysis with R**. 1. ed. Berlim: Springer, 2010.

GOLYANDINA, N.; NEKRUTKIN, V.; ZHIGLJAVSKY, A. **Analysis of Time Series Structure: SSA and Related Techniques**. 1 ed. Boca Raton: Chapman & Hall/CRC, 2001.

GOLYANDINA, N.; STEPANOV, D. SSA-based approaches to analysis and forecast of multidimensional time series. **Proceedings of the 5th St. Petersburg Workshop on Simulation**, p. 293-298, 2005.

GORDON, R. J. The Time-Varying NAIRU and its Implications for Economy Policy. **Journal of Economic Perspectives**, v. 11, n.1, p. 11-32, 1997.

GRANT, A. P. Time-Varying estimates of the natural rate of unemployment: A revisit of Okun's Law. **The Quarterly Review of Economics and Finance**. V. 42, n.1, p. 95-113, jun.-ago. 2002.

HAMILTON, J. D. Why You Should Never Use the Hodrick-Prescott Filter. **The Review of Economics and Statistics**, v.100, n.5, p.831-843, 2018.

HARVEY, A. C. State space models and the Kalman filter. In: HARVEY, A. C. **Forecasting, structural time series models and the Kalman filter**. 1. ed. Cambridge: Cambridge University Press, cap.3, p. 100-167, 1989.

HARVEY, A. C.; KOOPMAN. S. J. Diagnostic Checking of Unobserved-Components Time Series Models. **Journal of Business & Economic Statistics**, v.10, n.4, p. 377-389, out. 1992.

HARVEY, A. C.; KOOPMAN. S. J. Signal extraction and the formulation of unobserved components models. **Econometrics Journal**, v. 3, n.1, p. 84-107, 2000.

HARVEY, A. C.; KOOPMAN. S. J. Unobserved Components Models in Economics and Finance: the role of Kalman filter in time series econometrics. **IEEE Control Systems Magazine**, v.29, n.6, p.71-81, nov. 2009.

HARVEY, D. I.; LEYBOURNE, S. J.; TAYLOR, A. M. R. Testing for Unit Roots in the Presence of Uncertainty over Both the Trend and Initial Condition. **Journal of Econometrics**, v.169, n.2, p.188-195, 2012.

HASSANI, H.; HERAVI, S.; ZHIGLJAVSKY A. Forecasting European industrial production with singular spectrum analysis. **International Journal of Forecasting**, v.25, n.1, p. 103-118, jan. - mar. 2009.

HASSANI, H.; MAHMOUDVAND, R. Multivariate Singular Spectrum Analysis: A General View and New Vector Forecasting Approach. **International Journal of Energy and Statistics**, v.1, n.1, p. 55-83, 2013.

HASSANI, H.; MAHMOUDVAND, R. **Singular Spectrum Analysis: Using R**. 1 ed. Londres: Palgrave Pivot, jun. 2018.

HASSANI, H. THOMAKOS, D. A Review on singular spectrum analysis for economic and financial time series. **Statistics and its Interface**, v.3, p. 377-397, 2010.

HASSANI, H.; ZHIGLJAVSKY, A. Singular Spectrum Analysis: methodology and application to economics data. **Journal of Systems Science and Complexity**, v.22, p. 372-394, 2009.

HEIMBERGER, P.; KAPPELLER, J.; SCHUTZ, B. The NAIRU determinants: what's structural about unemployment in Europe? **Journal of Policy Modeling**, v.39, n.5, p. 883-908, set.-out. 2017.

HODRICK, R. J.; PRESCOTT, E. C. Postwar U.S. Business Cycles: An Empirical Investigation. **Journal of Money, Credit and Banking**, v.29, n.1, p. 1-16, fev. 1997.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA – IBGE. **IPCA – Índice Nacional de Preços ao Consumidor Amplo**. Disponível em: <<https://www.ibge.gov.br/estatisticas/economicas/precos-e-custos/9256-indice-nacional-de-precos-ao-consumidor-amplo.html>>. Acesso em: 20 nov. 2023a.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA – IBGE. **PNAD Contínua – Pesquisa Nacional por Amostra de Domicílios Contínua**. Disponível em: <<https://www.ibge.gov.br/estatisticas/sociais/trabalho/17270-pnad-continua.html>>. Acesso em: 30 mai. 2023b.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA – IBGE. **PME – Pesquisa Mensal do Emprego**. Disponível em: <<https://www.ibge.gov.br/estatisticas/sociais/trabalho/9180-pesquisa-mensal-de-emprego.html?=&t=o-que-e>>. Acesso em: 30 mai. 2023c.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA – IBGE. **Sistema IBGE de Recuperação Automática - SIDRA**. Disponível em: <<https://sidra.ibge.gov.br/home/pnadcm/brasil>>. Acesso em: 30 mai. 2023d.

INSTITUTO DE PESQUISA ECONÔMICA APLICADA – IPEA. **Carta de Conjuntura**, Rio de Janeiro, v.1, n.30, p. 1-141, mar. 2016a.

INSTITUTO DE PESQUISA ECONÔMICA APLICADA – IPEA. **Carta de Conjuntura**, Rio de Janeiro, v.1, n.33, p. 1-135, out.-dez. 2016b.

INSTITUTO DE PESQUISA ECONÔMICA APLICADA – IPEA. **Carta de Conjuntura**, Rio de Janeiro, v.1, n.34, p. 1-183, jan.-mar. 2017a.

INSTITUTO DE PESQUISA ECONÔMICA APLICADA – IPEA. **Carta de Conjuntura**, Rio de Janeiro, v.1, n.37, p. 1-144, out.-dez. 2017b.

INSTITUTO DE PESQUISA ECONÔMICA APLICADA – IPEA. **Carta de Conjuntura**, Rio de Janeiro, v.1, n.38, p. 1-215, jan.-mar. 2018.

INSTITUTO DE PESQUISA ECONÔMICA APLICADA – IPEA. **Carta de Conjuntura: Visão Geral da Conjuntura**. Disponível em: <<https://www.ipea.gov.br/cartadeconjuntura/index.php/category/sumario-executivo/>>. Acesso em: 23 nov. 2023.

JAŠOVÁ, E.; KADEŘÁBKOVÁ, B.; ČERMÁKOVÁ, K. Use of the method of the stochastic trend for NAIRU estimation in the Czech Republic and Slovakia at the macro- and meso-levels. **Economic Research-Ekonomska Istraživanja**, v.30, n.1, p. 256-272, abr. 2017.

KAPL, M.; MÜLLER, W. G. Prediction of steel prices: A comparison between conventional regression model and MSSA. **STATISTICS AND ITS INTERFACE**, v.3, p. 369-375, 2010.

KIM, C.; NELSON, R. C. **State Space Models with Regime Switching**. Londres: The MIT Press, 1999.

KING, B. T.; MORLEY, J. In search of the natural rate of unemployment. **Journal of Monetary Economics**, v.54, n.2, p. 550-564, mar. 2007.

KOROBENNIKOV, A. *et al.* Rssa: A Collection of Methods for Singular Spectrum Analysis. **CRAN Repository**. Disponível em: <<https://CRAN.R-project.org/package=Rssa>>. Acesso em 04 jun. 2023.

LANG, D.; SETTERFIELD, M.; SHIKAKI I. Is there scientific progress in macroeconomics? The case of the NAIRU. **European Journal of Economics and Economic Policies: Intervention**, v.17, n.1, p.19-38, 2020.

LIMA, E. C. R. The NAIRU, Unemployment and the Rate of Inflation in Brazil. **Revista Brasileira de Economia**, v.54, n.4, p. 899-930, out. - dez. 2003.

LOGEAY, C.; TOBER, S. HYSTERESIS AND THE NAIRU IN THE EURO AREA. **Scottish Journal of Political Economy**, v.53, n.4, p. 409-429, set. 2006.

LORÍA, E.; VALDEZ, J.; TIRADO, R.; Estimación de la NAIRU para México, 2002Q1-2018Q2. **Investigación Económica**, v.78, n.308, p. 39-62, mai. 2019.

LUCAS, R. E. Expectations and the Neutrality of Money. **Journal of Economic Theory**, v. 4, n. 2, p. 103-124, 1972.

MAO X.; SHANG P. Multivariate singular spectrum analysis for the traffic time series. **Physica A**, v.526, n. 121063, jul. 2019.

MARCELLINO, M.; STOCK, J. H.; WATSON, M. W. A comparison of direct and iterated multistep AR methods for forecasting macroeconomic time series. **Journal of Econometrics**, v.35, n. 1-2, p. 499–526, nov.-dez. 2006.

MARTINEZ, T. S.; CERQUEIRA, V. S. Estrutura da inflação brasileira: determinantes e desagregação do IPCA. **Economia e Sociedade**, v.22, n.2, p. 409-456, ago. 2013.

MENEZES, M. L. **Abordagem PAR(p) e Singular Spectrum Analysis na Modelagem e Geração de Cenários**. 2014. Tese (Doutorado) – Curso de Engenharia Elétrica, Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro, 2014.

MODIGLIANI, F.; PAPADEMOS, L. Targets for Monetary Policy in the Coming Year. **Brookings Papers on Economic Activity**, v.1, p. 141-165, 1975.

MOHEBI, M.; KOMIJANI, A. NAIRU and productivity shocks: evidence from three gigantic economies. **Applied Economic Letters**, v. 25, n.12, p. 847-852, 2018.

NOBREGA, W. C. L.; BESARRIA, C. N.; de OLIVEIRA, F. A. Unemployment Rate and Wage Growth in Brazil: Evidence from a Markov-Switching Model. **Economia Aplicada**, v.24, n.2, p. 171-194, 2020.

OLIVEIRA, L.; PORTUGAL, M. S.; ABRITA, M. B. Taxa de Desemprego Não Aceleradora da Inflação: uma estimação da NAIRU para a economia brasileira no período de 2000 até 2013. **Nova Economia**, v.26, n.2, p. 491-513, 2016.

OKUN, A. M. Potential GNP: Potential GNP: Its Measurement and Significance. **Proceedings of the Business and Economic Statistics Section of the American Statistical Association**, p. 98-104, 1962.

PALMA, A. P.; FERREIRA, D. NAIRU, Inflação e Curva de Phillips no Brasil: novas evidências a partir de um modelo tempo-variante. **Estudos Econômicos**. São Paulo, v.47, n.1, p. 39-63, jan.-mar. 2017.

PELAGATTI, M. M. **Time Series Modelling with Unobserved Components**. 1. Ed. Boca Raton: CRC Press, 2016.

PFAFF, B.; ZIVOT, E.; STIGLER, M. Urca: Unit Root and Cointegration Tests for Time Series Data. **CRAN Repository**. Disponível em: < <https://cran.r-project.org/web/packages/urca/index.html>>. Acesso em: 09 jan. 2024.

PHELPS, E. E. Phillips Curves, Expectations of Inflation and Optimal Unemployment Over Time. **Economica**, v. 34, n.135, p. 254-281, ago. 1967.

PHILLIPS, A. W. The Relation Between Unemployment and the Rate of Change of Money Wage Rates in the United Kingdom, 1851 – 1957. **Economica**, v.25, n.100, p. 283-375, nov. 1958.

PORTUGAL, M. S.; MADALOZZO, R. C. Um Modelo de NAIRU Para o Brasil. **Revista de Economia Política**, v.20, n.4, p. 387-409, out.-dez. 2000.

R FOUNDATION. The R Project for Statistical Computing. **R-project**. Disponível em: <<https://www.r-project.org/>>. Acesso em: 26 jul. 2023.

RODRIGUEZ, G. ESTIMATING OUTPUT GAP, CORE INFLATION, AND THE NAIRU FOR PERU, 1979-2007. **Applied Econometrics and International Development**, v.10, n.1, p. 149-160, 2010.

RODRIGUES, P. C.; MAHMOUDVAND, R. The benefits of multivariate singular spectrum analysis over the univariate version. **Journal of the Franklin Institute**, v.355, p. 544-564, 2018.

ROGERSON, R. Theory Ahead of Language in the Economics of Unemployment. **Journal of Economic Perspectives**, v.11, n.1, p. 73-92, 1997.

SALEMI, M. K. Estimating the natural Rate of Unemployment and Testing the Natural Rate Hypothesis. **Journal of Applied Econometrics**, v.14, n.1, p. 1-25, jan.-fev. 1999.

SALOP, S. C. A model of the Natural Rate of Unemployment. **The American Economic Review**, v.69, n.1, p. 117-125, mar. 1979.

SANTOS, F. S. Ascensão e Queda do Desemprego no Brasil: 1998-2012. In: XLI Encontro Nacional de Economia (Anpec), 2014, Foz do Iguaçu. **Texto para discussão**, p. 1-20, 2014.

SANTOS, M. F. O. *Singular Spectrum Analysis para estimativa de núcleo de inflação no Brasil*, 2022. 91 p. Dissertação (Mestrado em Economia Aplicada) – Universidade Federal de Juiz de Fora, Juiz de Fora. 2022.

SAX, C.; EDDELBUETTEL, D. Seasonal Adjustment by X-13-ARIMA-SEATS in R. **Journal of Statistical Software**, v.87, n.11, p.1-17, 2018.

SAX, C.; EDDELBUETTEL, D. Seasonal: R Interface to X-13-ARIMA-SEATS. **CRAN Repository**. Disponível em: <<https://cran.r-project.org/web/packages/seasonal/index.html>>. Acesso em 20 dez. 2023.

SILVA, E. S.; HASSANI, H.; HERAVI, S. Modelling European industrial production with multivariate singular spectrum analysis: a cross-industry analysis. **Journal of Forecasting**, p.1-14, dez. 2017.

SILVA FILHO, T.N.T. Searching for the Natural Rate of Unemployment in a Large Relative Price Shocks' Economy: The Brazilian Case. **Working Paper Series - BCB**, Brasília, n.163, p. 1-51, mai. 2008.

SILVA FILHO, T.N.T.; FIGUEIREDO, F. M. R. Revisitando as Medidas de Núcleo de Inflação do Banco Central do Brasil. **Trabalhos para Discussão**, Brasília, n. 356, p. 1-31, mai. 2014.

SILVA E. S.; GHODSI Z.; GHODSI M., HERAVI S.; HASSANI H. Cross country relations in European tourist arrivals. **Annals of Tourism Research**, v.63, n.1, p.151-168, mar. 2017.

SMEEKS, S.; WILMS, I. bootUR: An R Package for Bootstrap Unit Root Tests. **Journal of Statistical Software**, v.106, n.12, p.1-39, abr. 2023.

STIGLITZ J. Reflections on the natural Rate Hypothesis. **The Journal of Economic Perspectives**, v.11, n.1, p. 3-8, dez.-mar. 1997.

WICKSELL, K. The Natural Rate of Interest on Capital and the Rate of Interest on Loans. In: WICKSELL, K. **Interest and Prices - A Study of the Causes Regulating the Value of Money**. Londres: Macmillan and Company, cap.8, 1936.

APÊNDICE A – TESTES DE RAÍZ UNITÁRIA PARA AS SÉRIES RELACIONADAS À INFLAÇÃO

O objetivo deste apêndice é apresentar os testes de raiz unitária (RU) realizados, e seus resultados, para as séries utilizadas nos testes do capítulo 5, sendo elas: IPCA, IPCA - Livres, IPCA – Comercializáveis, núcleo EX0, núcleo EX1, núcleo MA, núcleo MS e núcleo DP. Ademais, é necessário ressaltar que, como o hiato do desemprego é a diferença entre a tendência e a série original, a série é, por construção, estacionária.

Para testar a presença – ou não – de raiz unitária nas séries três testes foram utilizados: teste ADF (*Augmented Dickey- Fuller*) (Dickey e Fuller, 1979), Bootstrap ADF e Bootstrap Union Test (Smeeks e Wilms, 2023). Conforme Arltová e Fedorová (2016), o teste ADF é um teste já consolidado na literatura para verificar a existência de raiz unitária em séries econômicas e se mostrou adequado nas simulações dos autores quando aplicado em séries que possuem aproximadamente 50 observações⁷².

No que diz respeito aos testes baseados em bootstrap, Smeeks e Wilms (2023) propuseram estes com execução através do pacote bootUR para a linguagem R. O pacote oferece uma aplicação facilitada dos testes de raiz unitária e calcula um *p-valor* para cada um dos testes do pacote. Um exemplo de aplicação é a incorporação do bootstrap ao teste ADF, que permite a seleção automática das defasagens e, ao realizar diversos testes na mesma amostra, um *p-valor* acurado é apresentado como resultado do teste - em que H_0 corresponde à presença de raiz unitária.

Segundo Smeeks e Wilms (2023), seu trabalho inovou em incorporar o bootstrap na União de Testes com Rejeição de Harvey, Leybourne e Taylor (2012). Ao reunir de forma automatizada os resultados de cinco testes para produzir um único *p-valor*, que testa a hipótese nula para presença de raiz unitária. Esta união de resultados é feita conforme a estatística de teste decorrente da Equação (A.1):

$$UR = \min \left(\frac{s}{c_{QD}^{\mu}(\alpha)} QD^{\mu}, \frac{s}{c_{QD}^{\tau}(\alpha)} QD^{\tau}, \frac{s}{c_{ADF}^{\mu}(\alpha)} ADF^{\mu}, \frac{s}{c_{ADF}^{\tau}(\alpha)} ADF^{\tau} \right) \quad (A.1)$$

Em que QD representa o teste de quase diferença; μ e τ indicam se as séries foram ajustadas, respectivamente, para média ou tendência; $c(\alpha)$ é o passo preliminar do bootstrap conforme o valor crítico α dos quatro testes; s é o fator de escala das estatísticas, sendo -1 no pacote bootUR

⁷² O teste ADF foi realizado no programa Rstudio utilizando o pacote urca (Pfaff, Zivot e Stigler, 2024).

(Smeeks e Wilms, 2023). A Tabela A1 e a Tabela A2 exibem os resultados dos testes de raiz unitária.

Tabela A1 - Testes de raiz unitárias para as séries de inflação e relacionadas acumuladas no trimestre

	ADF		Bootstrap ADF		Bootstrap Union	
	Estatística		Estatística	<i>p-valor</i>	Estatística	<i>p-valor</i>
IPCA	-2,8432*		-2,5990	0,1021	-0,9534	0,1311
COMERCIALIZÁVEIS	-2,6586*		-3,1480**	0,0220	-1,1860**	0,0325
LIVRES	-2,5755		-2,0970	0,1641	-0,8366	0,2431
EX0	-2,8982*		-1,6680	0,3722	-0,6669	0,4137
EX1	-1,8620		-1,6020	0,5028	-0,6317	0,5453
MA	-2,7542*		-1,6920	0,3732	-0,6518	0,5488
MS	-2,5435		-2,1000	0,2096	-0,9498	0,1446
DP	-2,8094*		-1,8860	0,3317	-0,7515	0,3422

Fonte: Elaboração própria. Nota: * caracteriza a rejeição da hipótese nula a 10%; ** caracteriza rejeição da hipótese nula a 5%; *** caracteriza rejeição da hipótese nula a 1%. Os pontos críticos para o teste ADF correspondem ao teste apenas com *drift*.

Tabela A2 - Testes de raiz unitária para as séries relacionadas à inflação acumuladas em 4 trimestres

	ADF		Bootstrap ADF		Bootstrap Union	
	Estatística		Estatística	<i>p-valor</i>	Estatística	<i>p-valor</i>
IPCA	-3,1419**		-1,8210	0,2956	-0,7824	0,3512
COMERCIALIZÁVEIS	-2,7486*		-2,5010*	0,0790	-1,0700*	0,0770
LIVRES	-1,9900		-2,4410*	0,0525	-1,1910**	0,0330
EX0	-1,8379		-1,3910	0,5438	-0,5726	0,5948
EX1	-2,0091		-1,9820	0,2741	-0,8728	0,2171
MA	-2,1491		-1,7590	0,3547	-0,7878	0,3617
MS	-1,7157		-1,5920	0,4977	-0,7106	0,5558
DP	-2,0217		-1,6100	0,4312	-0,7390	0,4737

Fonte: Elaboração própria. Nota: * caracteriza a rejeição da hipótese nula a 10%; ** caracteriza rejeição da hipótese nula a 5%; *** caracteriza rejeição da hipótese nula a 1%. Os pontos críticos para o teste ADF correspondem ao teste apenas com *drift*.

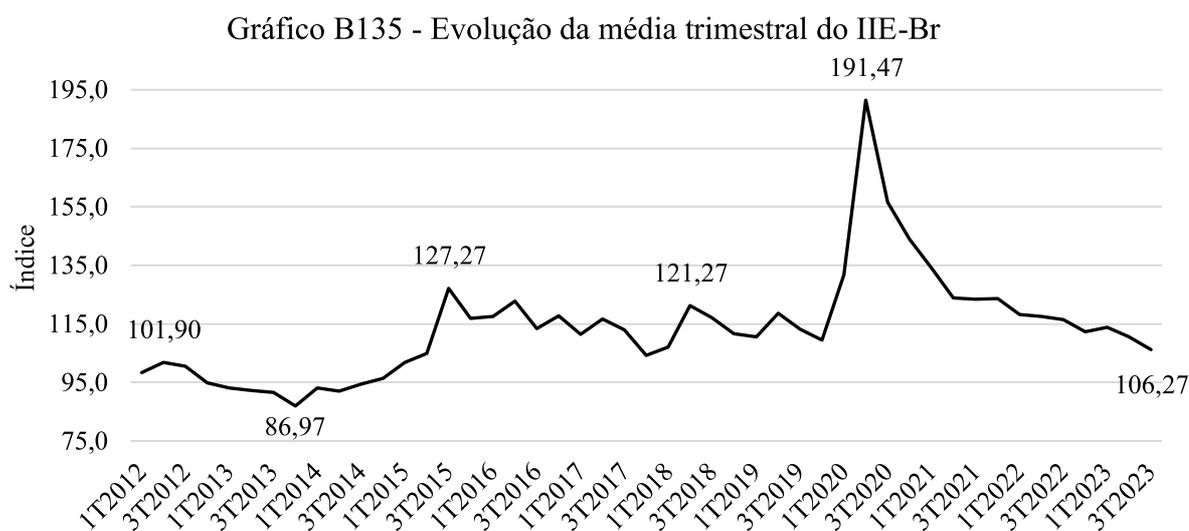
Em relação à Tabela A1, apesar do teste ADF rejeitar a hipótese nula de presença de raiz unitária a um nível de significância de 10%, apenas para a série de Comercializáveis que foi possível rejeitar a hipótese nula nos três testes, rejeição que foi a 5% nos testes de *bootstrap* propostos. Quando testadas as demais séries em primeira diferença, foi possível rejeitar a hipótese nula para todas as séries. Portanto, para o período amostral analisado, apenas a série de comercializáveis se mostrou estacionária dentre as séries acumuladas no trimestre.

Quanto aos resultados das séries acumuladas em 4 trimestres (Tabela A2), apenas as séries do IPCA – Livres e IPCA – Comercializáveis se mostraram estacionárias para os testes

de RU que empregam o *bootstrap* – a um nível de significância a 10%. Já o IPCA, mesmo com o teste ADF acusando estacionariedade a 5% de significância, esta só foi alcançada para os testes *bootADF* e *bootUR* após a primeira diferenciação da série. Portanto, a série do IPCA foi utilizada nos testes da NAIRU com a primeira diferença. Por fim, todas as medidas de núcleo – para todos os testes – só se mostraram estacionárias nos testes utilizados após a segunda diferenciação das séries.

APÊNDICE B – ANÁLISE DO INDICADOR DE INCERTEZA DA ECONOMIA BRASIL ENTRE O 1T2012 E O 3T2023

O intuito do Apêndice B é apresentar a série do IIE-Br citada na seção 5.1. Conforme destacado na seção, para visualizar a evolução trimestral dos níveis de incerteza ao longo do período amostral, foi calculada a média trimestral – entre o 1T2012 e o 3T2023 - do índice que é divulgado com periodicidade mensal pela FGV IBRE. Portanto, o Gráfico B1 exibe a média do IIE-Br para cada trimestre (FGV/IBRE, 2024).



Fonte: Elaboração própria com base nos dados de FGV/IBRE (2024).

Após os 101,9 registrados no segundo trimestre de 2012, a incerteza seguiu tendência de queda até o 1T2014 alcançando uma média de 86,97 pontos. Após 2014, a tendência do índice foi positiva até o pico no 3T2015 com 127,27, em que, a aceleração entre o 2T2015 e o 3T2015 marcou a mudança de patamar do índice, indicando o elevado nível de incerteza da economia brasileira após a crise de 2015 e 2016. Esse valor do 3T2015 só foi superado com a chegada da crise sanitária, culminando na média de 191,47 pontos no 3T2020, entretanto, após esse pico no início da crise, o índice seguiu em tendência de queda, atingindo uma média de 106,27 pontos no último trimestre da amostra. Assim, as duas crises que compõem a amostra também foram marcadas por elevada incerteza – principalmente após a crise fiscal que política de 2015 e 2016, em que o índice não retornou para o mesmo nível dos valores observados à priori.