

UNIVERSIDADE FEDERAL DE SANTA CATARINA  
CAMPUS FLORIANÓPOLIS  
DEPARTAMENTO DE ENGENHARIA ELÉTRICA E ELETRÔNICA  
CURSO ENGENHARIA ELÉTRICA

ALEXANDRE FERREIRA DE CARVALHO FILHO

**CICLOS ECONÔMICOS NOS SUBSETORES DA INDÚSTRIA DE  
TRANSFORMAÇÃO BRASILEIRA: UMA ANÁLISE SOBRE TRÊS MODELOS DE  
PREVISÃO**

Florianópolis  
2023

ALEXANDRE FERREIRA DE CARVALHO FILHO

**CICLOS ECONÔMICOS NOS SUBSETORES DA INDÚSTRIA DE  
TRANSFORMAÇÃO BRASILEIRA: UMA ANÁLISE SOBRE TRÊS MODELOS DE  
PREVISÃO**

Trabalho de Conclusão de Curso submetido ao curso de Engenharia Elétrica do Centro Tecnológico da Universidade Federal de Santa Catarina como requisito parcial para a obtenção do título de Bacharel

Orientador: Prof. Dr Eduardo Luiz Ortiz Batista

Florianópolis

de Carvalho Filho, Alexandre Ferreira  
CICLOS ECONÔMICOS NOS SUBSETORES DA INDÚSTRIA DE  
TRANSFORMAÇÃO BRASILEIRA: UMA ANÁLISE SOBRE TRÊS MODELOS DE  
PREVISÃO / Alexandre Ferreira de Carvalho Filho ; orientadora,  
Eduardo Luiz Ortiz Batista, 2023.

46 p.


2. Ciclos econômicos da indústria de Transformação. 3. Análise  
Espectral Singular; 4. Modelos preditivos. I. Ortiz Batista,  
Eduardo Luiz. II. Universidade Federal de Santa Catarina. . III.  
Título.

Alexandre Ferreira de Carvalho Filho

**CICLOS ECONÔMICOS NOS SUBSETORES DA INDÚSTRIA DE  
TRANSFORMAÇÃO BRASILEIRA: UMA ANÁLISE SOBRE TRÊS MODELOS  
DE PREVISÃO**

Este Trabalho Conclusão de Curso foi julgado adequado para obtenção do Título de  
"Bacharel em Engenharia Elétrica" e aceito, em sua forma final, pelo Curso de  
Graduação em Engenharia Elétrica.

Florianópolis, 17 de julho de 2023.



Documento assinado digitalmente

Miguel Moreto

Data: 20/07/2023 22:00:44 -0300

CPF: \*\*\*.850.108-\*\*


Verifique as assinaturas em <https://s.ufsc.br>

---

Prof. Miguel Moreto, Dr.

Coordenador do Curso de Graduação em Engenharia Elétrica

**Banca Examinadora:**



Documento assinado digitalmente

Eduardo Luiz Ortiz Batista

Data: 20/07/2023 08:20:53 -0300

CPF: \*\*\*.521.889-\*\*


Verifique as assinaturas em <https://s.ufsc.br>

---

Prof. Eduardo Luiz Ortiz Batista, Dr.

Orientador

Universidade Federal de Santa Catarina



Documento assinado digitalmente

Walter Pereira Carpes Junior

Data: 20/07/2023 10:20:06 -0300


CPF: \*\*\*.999.599-\*\*

Verifique as assinaturas em <https://s.ufsc.br>

---

Prof. Walter Carpes Jr., Dr

Universidade Federal de Santa Catarina



Documento assinado digitalmente

Richard Demo Souza

Data: 20/07/2023 10:08:56 -0300

CPF: \*\*\*.267.379-\*\*

Verifique as assinaturas em <https://s.ufsc.br>

---

Prof. Richard Demo Souza, Dr.

Universidade Federal de Santa Catarina

Dedico aos meus pais pela oportunidade, aos meus irmãos pelo companheirismo e aos meus amigos, todos esses que me ajudaram a não desistir da Engenharia Elétrica

"Avião não foi feito para voar, mas para o homem voar"  
(VIEIRA PINTO, 2005, p. 80, v.I)

## RESUMO

Este trabalho consiste em uma análise exploratória dos dados de 52 setores da indústria de transformação do Brasil. A partir da aplicação da transformada de Fourier, foi possível identificar comportamentos sazonais nas séries históricas de produção física desses setores, proporcionando uma visão ampla e sistêmica dos comportamentos comuns entre os setores industriais. Além disso, foram realizadas decomposições das séries em suas componentes, revelando padrões oscilatórios em diferentes escalas de tempo. A análise estatística dos dados revelou uma diversidade de séries temporais, com setores apresentando diferentes níveis de variância. A correlação entre as séries históricas também foi explorada, revelando relações significativas entre alguns setores, tanto relacionadas ao processo produtivo quanto de forma inesperada. Esses insights da análise exploratória forneceram uma base sólida para o desenvolvimento de três modelos preditivos: Análise Espectral Singular Univariada (AES), SARIMA e Holt-Winters (HW). Durante o treinamento dos modelos, foram considerados diferentes métricas de erro, como o erro quadrático médio, erro médio absoluto, percentual médio absoluto e raiz do erro quadrático médio. Os resultados indicaram que o modelo AES apresentou melhores resultados para previsões curtas, até 12 meses, enquanto para previsões maiores o SARIMA apresentou melhores resultado, especialmente em relação a mudanças bruscas na tendência das informações. É importante ressaltar que os dados de teste abrangem um período de crise econômica, o que adiciona uma dimensão desafiadora para a modelagem e previsão das séries.

**Palavras-chave:** Ciclos econômicos da indústria transformação do Brasil; Análise Espectral Singular; SARIMA; Holt-Winters.

## ABSTRACT

This work consists of an exploratory analysis of data from 52 sectors in Brazil's manufacturing industry. By applying the Fourier transform, it was possible to identify seasonal behaviors in the historical time series of physical production within these sectors, providing a broad and systemic understanding of common patterns among industrial sectors. Additionally, the series were decomposed into their components, revealing oscillatory patterns at different time scales. Statistical analysis of the data unveiled a diversity of time series, with sectors exhibiting varying levels of variance. The correlation between historical series was also explored, revealing significant relationships among certain sectors, both related to the production process and in unexpected ways. These insights from the exploratory analysis served as a solid foundation for developing three predictive models: Univariate Singular Spectrum Analysis (SSA), SARIMA, and Holt-Winters (HW). Different error metrics, such as mean-square error, mean absolute error, mean absolute percentage error, and root mean-square error, were considered during model training. The results indicated that the SSA model yielded better performance for prediction purpose until 12 months, while SARIMA outperformed predictions with more than one year, particularly for abrupt changes in trend. It is important to note that the test data encompass a period of economic crisis, which adds a challenging dimension to the modeling and forecasting of the series.

**Keywords:** Economic cycles of the manufacturing industry of Brazil; Singular Spectral Analysis; SARIMA; Holt-Winters.



## Lista de Figuras

Figura 1: Ciclos econômicos .....	15
Figura 2 Comportamento das componentes para escolha do tipo de decomposição.....	21
Figura 3 Produção física: celulose (17.1), máquina agropecuária (28.3), carroceria (29.3) .....	27
Figura 4 Valores Singulares vs r (com e sem a primeira componente).....	28
Figura 5 As 12 primeiras Componentes .....	29
Figura 6 Scatterplots dos 12 primeiros pares de vetores singulares V conectados .....	29
Figura 7 Espectro de potência (por período): Alimentos animais (10.6), Defensivos agrícolas (20.5), Leite (10.5), Bebida não alcoólicas (11.2) .....	30
Figura 8 Espectro de potência (por período): Carne (10.1), café (10.8), Bebida alcoólicas (11.1), Madeira (16.2), Papel (17.1), Petróleo (19.2), Máquinas Agrícolas (28.3), Caminhões e Ônibus (29.2) .....	31
Figura 9 Comparação entre as amostras de teste e as previsões dos 3 modelos, para os setores (10.6;32.9;26.2) .....	36
Figura 10 Comparação entre as amostras de teste e as previsões dos 3 modelos, para os setores (20.6;13.3;28.5) .....	37

## Lista de Tabelas

Tabela 1 Equações Holt-Winters (aditivo e multiplicativo).....	20
Tabela 2 Métricas de avaliação da previsão .....	24
Tabela 3 Média e Variância de cada setor .....	25
Tabela 4 Pares de Correlação maiores que 0,8.....	32
Tabela 5 Quantidade de casos em que cada modelo apresentou menor erro (treinamento e teste) – com 25 amostras de teste.....	34
Tabela 6 Erro de previsão para horizontes de 1, 6, 9 e 12 meses – com 25 amostras de teste.....	34
Tabela 7 Quantidade de casos em que cada modelo apresentou menor erro (treinamento e teste) - com 60 amostras de teste .....	38
Tabela 8 Erro de previsão para horizontes de 1, 6, 9 e 12 meses – com 60 amostras de teste.....	38
Tabela 9 Quantidade de casos em que cada modelo apresentou menor erro (treinamento e teste) - com 30 e 60 amostras de teste (SSA) .....	39
Tabela 10 Erro de previsão para horizontes de 1, 6, 9 e 12 meses – com 30 e 60 amostras de teste (SSA).....	39

## SUMÁRIO

1. INTRODUÇÃO .....	12
2. REVISÃO BIBLIOGRÁFICA .....	14
3. METODOLOGIA .....	17
3.1 MATERIAIS.....	17
3.2 MODELOS DE PREVISÃO .....	19
3.2.1 SARIMA .....	19
3.2.2 Holt Winters .....	20
3.2.3 Análise Espectral Singular .....	22
3.3 AVALIAÇÃO.....	24
4. ANÁLISE EXPLORATÓRIA .....	25
4.1 DECOMPOSIÇÃO DAS SÉRIES.....	27
5. ANÁLISE USANDO MODELOS PREDITIVOS .....	33
6. CONCLUSÃO .....	40
REFERÊNCIAS .....	41
APÊNDICE A - LISTA DE SETORES DA INDÚSTRIA DE TRANSFORMAÇÃO.....	44
APÊNDICE B – ESBOÇO DAS SÉRIES TEMPORAIS .....	46
APÊNDICE C – ESPECTRO DE POTÊNCIA (POR PERÍODO).....	49
APÊNDICE D – PARÂMETROS DOS MODELOS (MÉTRICA MSE) .....	52
APÊNDICE E.1 – ERRO ABSOLUTO NA PREVISÃO PARA OS HORIZONTE DE 1,6,9 E 12 MESES (MÉTRICA MSE).....	53
APÊNDICE E.2 – ERRO NORMALIZADO NA PREVISÃO PARA OS HORIZONTE DE 1,6,9 E 12 MESES (MÉTRICA MSE).....	55
APÊNDICE F.1 – ERRO ABSOLUTO NA PREVISÃO DAS AMOSTRAS DE TREINAMENTO E DE TESTE (MÉTRICA MSE COM 25 AMOSTRAS DE TESTE).....	57
APÊNDICE F.2 – ERRO NORMALIZADO NA PREVISÃO DAS AMOSTRAS DE TREINAMENTO E DE TESTE (MÉTRICA MSE COM 25 AMOSTRAS DE TESTE).....	58

## 1. INTRODUÇÃO

Este trabalho tem como objetivo utilizar 52 séries temporais da produção física da indústria de transformação do Brasil para testar e avaliar três modelos de previsão. Os modelos selecionados são o Holt-Winters (aditivo e multiplicativo), SARIMA (Seasonal Autoregressive Integrated Moving Average) e o Modelo de Análise Espectral Singular Univariado (AES).

Antes de aplicar os modelos de previsão, é importante realizar uma análise exploratória dos dados. Essa análise visa visualizar e inferir informações relevantes sobre as séries históricas dos 52 setores da indústria de transformação no período de 2002 a 2022. A partir da aplicação da transformada de Fourier, é possível identificar comportamentos sazonais nas séries de produção física desses setores, o que proporciona uma visão ampla e sistêmica dos comportamentos comuns entre eles, bem como dos ciclos econômicos.

Além disso, a análise exploratória envolve a decomposição das séries em suas componentes utilizando a análise espectral da transformada de Fourier e o SVD. Além disso, investigasse a correlação entre as séries temporais. Isso permite identificar padrões oscilatórios em diferentes escalas de tempo e entender as relações entre os setores industriais.

Ao analisar estatisticamente os dados, é observada uma diversidade de séries temporais, com setores apresentando diferentes níveis de variância. Essas variações podem estar relacionadas às características específicas de cada setor econômico e à ocorrência de crises econômicas. Durante os períodos de crises, como a crise de 2008, crise política de 2014 e a crise da pandemia de Covid-19, são observadas variações significativas nos setores, com impactos diferentes em cada um deles.

Por tanto, a análise exploratória fornece informações valiosas sobre os comportamentos sazonais, as relações entre os setores industriais e os efeitos das crises econômicas. Essas informações são fundamentais para o desenvolvimento de modelos preditivos.

Após a análise exploratória, serão montados e ajustados os parâmetros dos modelos de previsão selecionados. O modelo Holt-Winters (HW) será aplicado tanto na forma aditiva quanto na forma multiplicativa, considerando a decomposição da série em

seus componentes. O modelo SARIMA será utilizado para capturar os padrões de dependência temporal e a sazonalidade periódica presentes nos dados. Além disso, o Modelo de Análise Espectral Singular Univariado (AES) será aplicado, considerando as características não estacionárias e as complexas componentes sazonais das séries.

Por fim, serão avaliados os resultados dos modelos de previsão com base em métricas de erro. Serão utilizadas as métricas de Erro Médio Absoluto (MAE), Erro Quadrático Médio (MSE), Erro Quadrático Acumulado (EQA), Erro Percentual Médio Absoluto (MAPE) e Raiz do Erro Quadrático Médio (RMSE) para avaliar a qualidade das previsões obtidas pelos modelos.

Ao realizar essas etapas, espera-se obter conhecimentos valiosos sobre as características das séries temporais da produção física da indústria de transformação do Brasil e verificar a eficácia dos modelos de previsão selecionados. Essas análises e previsões podem fornecer informações relevantes para auxiliar na tomada de decisões e no planejamento estratégico no contexto da indústria de transformação.

## 2. REVISÃO BILIOGRÁFICA

O estudo sobre ciclos econômicos ou ciclos de negócio, suas características, condicionantes, determinações e consequências tem sido um tema amplamente discutido dentro da academia por praticamente todas as escolas de pensamento econômico: marxistas, keynesianos e clássicos. Parece haver consenso que eles existem. No entanto, as divergências estão relacionadas à interpretação desses ciclos.

Nesse sentido, é importante fazer uma distinção entre o ciclo, ondas com períodos mais curtos, e a tendência, que são as mais compridas. A fronteira, do que seria um ciclo ou uma tendência não estão delimitadas, e irá depender da metodologia usada em cada pesquisa. Na obra de Burns e Mitchel (1946), um ciclo de negócios corresponde a durações entre 1,5 e 8 anos, por isso dentro de seu trabalho, ele aplica um filtro passa faixa que seleciona estes períodos, excluindo assim o impacto das tendências (períodos acima de 8 anos).

Ainda sobre os ciclos econômicos, no trabalho do economista francês Clement Juglar (1862) este detecta ciclos econômicos nas principais economias capitalistas (Inglaterra, França, Estado Unidos), com duração de 7 à 11 anos. Tais ciclos são conhecidos como ciclos Juglarianos em sua homenagem. Para ele, esses ciclos poderiam estar relacionados a renovação dos maquinários e técnicas dentro do processo produtivo. Além de Juglar, Marx (1985) observa o mesmo fenômeno econômico em seu tempo, concordando com a hipótese levantada com o francês e a usando como aporte para sua teoria da “Lei Geral da Acumulação Capitalista”. No entanto, para além da hipótese ligada ao maquinário, afirma também haver, uma explicação para o ciclo intrinsecamente ligada a forma de produção capitalista e como a acumulação do capital ocorre.

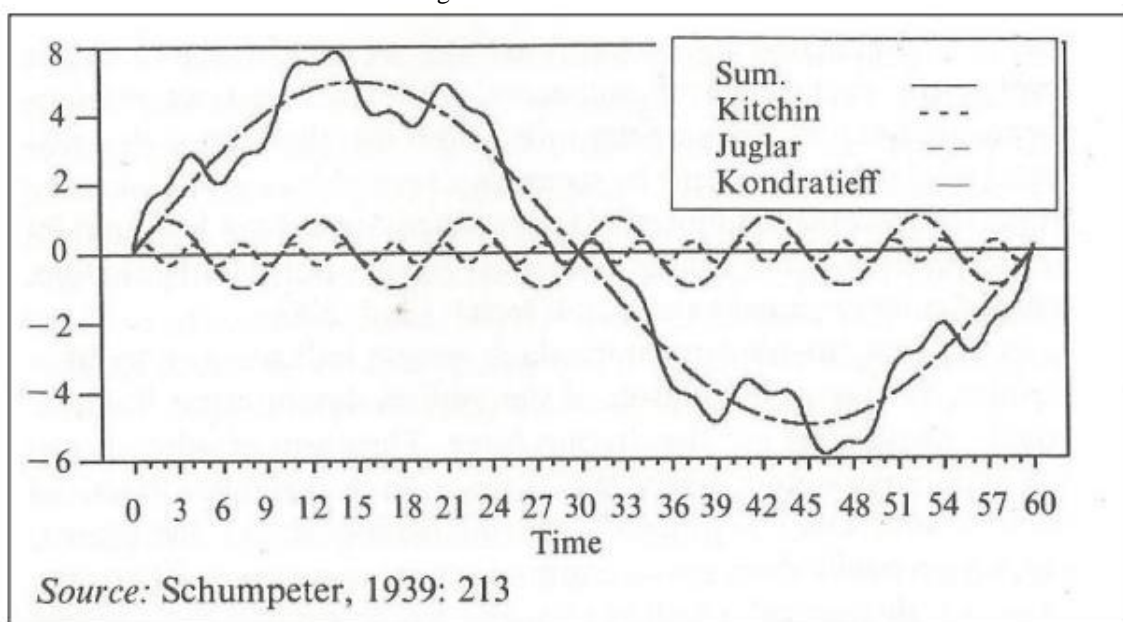
Além desses ciclos, há também o ciclo de Kitchin de em média 40 à 59 meses, aproximadamente 3 a 5 anos. Segundo Romyantseva (2003 apud KOROTAYEV E TSIREL, 2010, p.12, tradução nossa):

A lógica deste ciclo pode ser descrita de uma maneira bastante clara através das leis neoclássicas de equilíbrio de mercado e é explicada pelos atrasos na movimentação das informações que afetam a tomada de decisão das empresas comerciais. Como é bem conhecido, as empresas reagem à melhoria da situação comercial aumentando a produção por meio do pleno emprego dos ativos fixos de capital. Como resultado, dentro de um certo período de tempo (variando entre alguns meses e dois anos), o mercado fica inundado de commodities cuja quantidade gradualmente se torna excessiva. A demanda diminui, os

preços caem, as commodities produzidas se acumulam nos inventários, o que informa os empresários da necessidade de reduzir a produção. No entanto, esse processo leva algum tempo."

Já Schumpeter (1939), fez um apanhado destes ciclos para colaborar com sua teoria de ciclos de negócio e o conceito de “destruição criativa”, no qual se refere ao processo pelo qual uma inovação destrói uma indústria recente, criando espaço para uma nova. Nesse sentido, ele desenvolveu um esquemático utilizando os 3 principais ciclos econômicos: Kitchen(3 à 5 anos), Juglar(7 à 11 anos) e Kondratieff(40 à 60 anos), vide Figura 1.

Figura 1: Ciclos econômicos



Fonte: Schumpeter (1939)

Com base na conceitualização dos ciclos econômicos, é possível abordar com maior facilidade os métodos de previsão e suas estratégias para lidar com séries temporais da economia. Nesse projeto, destacam-se dois trabalhos relacionados aos métodos de previsão da produção industrial: um aborda dados dos setores industriais do Brasil, enquanto o outro trata de três países europeus (Alemanha, França e Grã-Bretanha) (ALBERTO ORGE PINHEIRO, DE SENNA, 2015; HASSANI, HERAVI, ZHIGLJAVSKY, 2009).

Sobre a escolha de um modelo e o principal problema em suas previsões, diz Martins e Martinelli (2010 apud ALBERTO ORGE PINHEIRO, DE SENNA, 2015, p.28):

O principal problema sobre a previsão reside nas grandes oscilações que ocorrem em razão dos fatores climáticos, mercadológicos e conjunturais que promovem incerteza de renda para os produtores, armazenadores, exportadores bem como processadores dos produtos

Logo, qualquer método que se proponha útil para estudar esse tipo de dados, deve saber lidar com o fenômeno da sazonalidade, ou por assim dizer, com os ciclos econômicos. Nesse sentido, podem ser verificados três métodos que apresentam os melhores resultados para dados com sazonalidade, eles são o Holt-Winters (HW), SARIMA e a análise espectral singular univariada (AES).

O Holt-Winters é um tipo de modelo de suavização exponencial no domínio do tempo. Esse método já possui mais de 60 anos, mas ainda é amplamente utilizado e validado. Consiste em realizar uma decomposição da série temporal, seja aditiva ou multiplicativa, separando os dados em três componentes: tendência, sazonalidade e ruído, cada um com seus respectivos pesos.

A análise espectral singular, AES para o univariado e AESM para o multivariado, vem sendo aplicada em problemas de análise, previsão para séries não estacionárias e com complexas componentes sazonais, e número reduzido de amostras (HASSANI, HERAVI, ZHIGLJAVSKY, 2009). Os problemas que envolvem as séries desse tipo podem ser encontrados na meteorologia, na física e na economia (GHIL, ALLEN, DETTINGER, 2012; VAUTARD, YIOU, GHIL, 1992; HASSANI, ZHIGLJAVSKY, 2008).

O método SARIMA (Seasonal Autoregressive Integrated Moving Average) é um modelo tradicional amplamente utilizado na análise de séries temporais. Ele é capaz de lidar com a distinção entre tendência e sazonalidade, ao incorporar componentes autorregressivos e de diferenciação. Essa abordagem permite capturar tanto os padrões de dependência temporal presentes nos dados quanto a sazonalidade periódica. Ao considerar os componentes autorregressivos, o SARIMA leva em conta a influência dos valores passados da série para prever os valores futuros. Além disso, ao realizar a diferenciação, ele é capaz de remover tendências e padrões não estacionários, tornando os dados mais adequados para a modelagem e previsão.



### 3. METODOLOGIA

Esta secção é dedicada a apresentar os materiais usados nesse projeto, softwares e banco de dados; além de apresentar e contextualizar os três modelos preditivos usados, SARIMA, HW e AES, além de apresentar os métodos de avaliação das previsões.

#### 3.1 MATERIAIS

O Instituto Brasileiro de Geografia e Estatística (IBGE) realiza duas pesquisas que sumarizam informações sobre os setores industriais, a Pesquisa Industrial Mensal (PIM) e a anual (PIA). Uma análise exploratória no banco de tabelas estatísticas do Sistema IBGE de Recuperação Automática (SIDRA) foi realizada, buscando priorizar tabelas que possam superar certas limitações amostrais típicas de países subdesenvolvidos, como baixo nível de desagregação, curto horizonte de tempo e baixas frequências de amostragem (intervalos anuais) (GADELHA, 2018).

Nesse sentido, as tabelas da PIM foram priorizadas por apresentarem uma maior frequência de amostragem e por terem séries com períodos semelhantes à da PIA. Foram destacadas 3 tabelas que relacionam a produção física industrial entre janeiro de 2002 e dezembro de 2022 (252 amostras), diferenciando-se apenas pelo nível de desagregação das atividades econômicas e a regionalização, sendo elas:

- a) 8159: 28 categorias econômicas (CNAE), sendo indústria geral e extrativa, e 26 subdivisões da indústria de transformação, com dados sobre o Brasil e 14 estados Bahia, Minas Gerais, Espírito Santo, Rio de Janeiro, São Paulo, Paraná, Santa Catarina, Rio Grande do Sul, Mato Grosso, Goiás, Amazonas, Pará, Ceará, Pernambuco;
- b) 7511: 103 categorias econômicas (CNAE) relacionadas à indústria de transformação, com dados apenas do Brasil. Sendo que 29 setores apresentam dados apenas entre 2012 e 2022, dividindo ainda os 74 setores restantes com maior histórico (2002-2022) em duas categorias: macro setores, com 52, e micro setores, com 22 (nomenclatura adotada pelo autor);
- c) 8158: 24 grandes categorias econômicas, uma agregação feita pelos técnicos do IBGE que agrega o CNAE em 3 grandes categorias: Bens de Capital, Bens Intermediários, Bens de Consumo.

Sabe-se que para análise de comovimentos entre setores ou regiões, os dados mais agregados tendem a superestimar as relações entre os diferentes ciclos de cada setor, podendo gerar correlações falsas (Engle, 1987). Além disso, a relação entre ciclos econômicos da indústria, em período semelhante, já foi explorada entre 7 estados do Brasil (Silva et al., 2020). Dessa forma optou-se por trabalhar com a tabela 7511, com apenas os dados dos macro setores.

O indicador utilizado na pesquisa é o indexador de produção física, normalizado pela média de 2012 que corresponde ao número 100. O procedimento de cálculo dos índices é uma adaptação do método de Laspeyres de base fixa em cadeia, com atualização e ponderação, por último é realizado um procedimento de ajustamento sazonal utilizando o método X-12-Arima (IBGE,2015).

Além do banco de dados mencionado, o trabalho será desenvolvido em Python, utilizando as bibliotecas numpy, pandas, matplotlib, pySSA e o statsmodels. Como já citado, os dados serão extraídos do SIDRA, Sistema IBGE de Recuperação Automática.

## 3.2 MODELOS DE PREVISÃO

### 3.2.1 SARIMA

O modelo SARIMA (*Seasonal Autoregressive Integrated Moving Average*) será usado nesse projeto como uma referência de modelo mais tradicional (BOX; JENKINS, 1976). No caso, ele é um modelo que deriva do modelo ARIMA, porém ele é mais robusto para trabalhar com séries que apresentam forte comportamento sazonal, que é o caso do projeto. Equação que descreve o SARIMA é a seguinte:

$$\phi_p(B)\Phi_P(B^s)[\Delta^d \Delta^D - \mu]Y_t = \theta_q(B)\Theta_Q(B)\epsilon_t \quad (1)$$

onde  $Y_t$ ,  $\epsilon_t$  e  $\mu$ , que são respectivamente os valores da série temporal, do seu erro (ruído) e sua média, além do operador de diferença atrasada  $B$ , onde  $BY_t = Y_{t-1}$  e o operador diferença sazonal de ordem  $D$ , onde  $\Delta_S^D = (1 - B^s)^D Y_t$ . Há também os operadores autorregressivos da série temporal e da sua versão sazonal (indicados com um  $s$ , que é a periodicidade), de ordem  $p$  e  $P$  respectivamente, eles também são chamados de polinômios estacionários autorregressivos, os seus equacionamentos são dados da seguinte maneira:

$$\phi_p(B) = (1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p)$$

$$\Phi_P(B^s) = (1 - \Phi_1 B^s - \Phi_2 B^{2s} - \dots - \Phi_P B^{Ps})$$

Há ainda os operadores de média móvel, também da série não sazonal e sua versão sazonal, também conhecidos como coeficientes da média móvel, de ordem  $q$  e  $Q$  respectivamente, onde:

$$\theta_q(B) = (1 + \theta_1 B + \theta_2 B^2 + \dots + \theta_q B^q)$$

$$\Theta_Q(B) = (1 + \Theta_1 B^s + \Theta_2 B^{2s} + \dots + \Theta_Q B^{Qs})$$

De forma objetiva, o modelo é montado com base em 6 parâmetros  $(p, q, d) \times (P, Q, D)$ , que serão ajustados de modo a diminuir o erro entre as previsões e as amostras de teste.

### 3.2.2 Holt Winters

O modelo Holt-Winters (ALBURQUERQUE, SERRA, 2006) é um método que considera três componentes principais: nível, tendência e sazonalidade, onde, nível representa o valor médio da série temporal, a tendência representa a direção e o padrão de crescimento ou decrescimento da série ao longo do tempo, sazonalidade captura os padrões periódicos e repetitivos que ocorrem em intervalos fixos. Essas componentes são combinadas para modelar o comportamento da série temporal ao longo do tempo, e podem ser encontradas conforme a Tabela 1.

Tabela 1 Equações Holt-Winters (aditivo e multiplicativo)

	<b>Holt-Winters Aditivo</b>	<b>Holt-Winters Multiplicativo</b>
<b>Nível</b>	$L = \alpha(Y_t - S_{t-s}) + (1 - \alpha)(L_{t-1} + b_{t-1})$	$L_t = \alpha \frac{Y_t}{S_{t-s}} + (1 - \alpha)(L_{t-1} + b_{t-1})$
<b>Tendência</b>	$b_t = \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1}$	$b_t = \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1}$
<b>Sazonalidade</b>	$S_t = \gamma(Y_t - L_t) + (1 - \gamma)S_{t-s}$	$S_t = \gamma \left( \frac{Y_t}{L_t} \right) + (1 - \gamma)S_{t-s}$
<b>Previsão</b>	$F_{t+m} = (L_t + b_t m) + S_{t-s+m}$	$F_{t+m} = (L_t + b_t m) S_{t-s+m}$

Fonte: Adaptado de “Previsão da produção brasileira de biodiesel por meio de modelos de previsão” (CRUZ, et al., 2016)

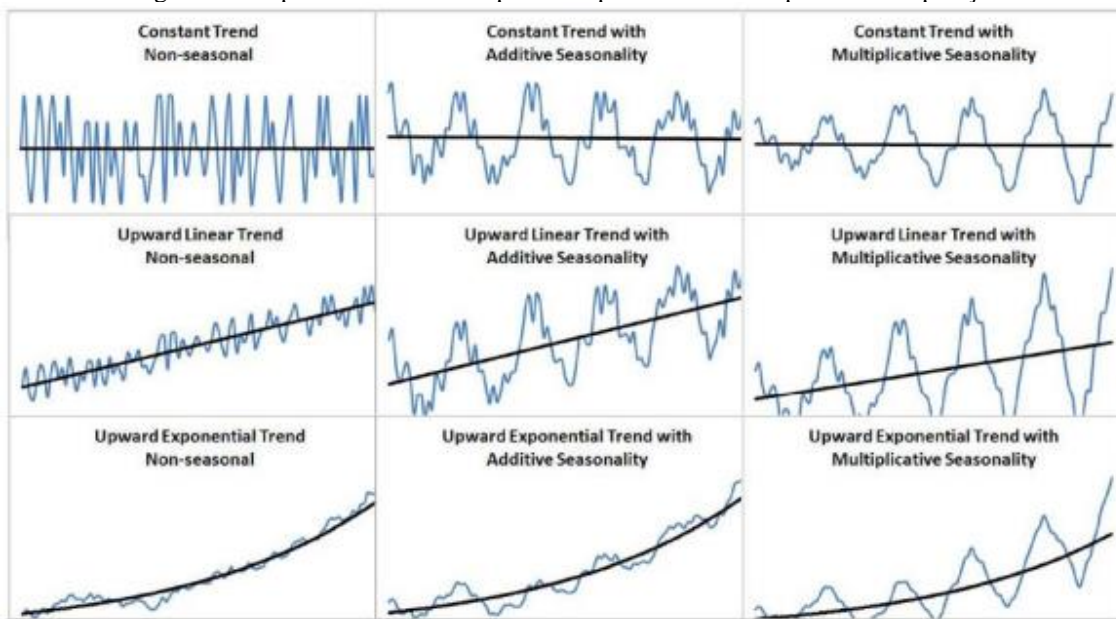
A forma de combinar as componentes na decomposição e reconstrução de uma série temporal pode ser do tipo aditivo ou multiplicativo. No método aditivo, as componentes são somadas, enquanto no método multiplicativo, elas são multiplicadas. A escolha entre os dois métodos está relacionada ao comportamento da tendência e da sazonalidade.

Na Figura 2, é possível observar que a tendência pode ser linear ou exponencial. No caso da tendência linear, em que a taxa de crescimento é constante ao longo do tempo, o método aditivo é mais adequado. Por outro lado, no caso da tendência exponencial, em que a taxa de crescimento aumenta de forma exponencial com o passar do tempo, o método multiplicativo é mais apropriado.

No que diz respeito à sazonalidade, a escolha entre o método aditivo e multiplicativo está relacionada à taxa de crescimento da amplitude dessa componente ao longo do tempo. Novamente, se a taxa de crescimento da amplitude for constante, o

método aditivo é mais adequado. Caso contrário, se a taxa de crescimento da amplitude não for constante, o método multiplicativo é mais indicado.

Figura 2 Comportamento das componentes para escolha do tipo de decomposição



Fonte: Material de aula Professor João Ferreira Netto, USP, Processos Estocásticos

No ajuste do modelo HW, são utilizados três parâmetros principais: os métodos de decomposição para a tendência e a sazonalidade, e o tamanho da janela ou período da sazonalidade. A escolha desses parâmetros é realizada com o objetivo de encontrar o conjunto que minimize o erro quadrático médio, ou AIC (Akaike Information Criterion) ou o BIC (Bayesian Information Criterion), dependendo do critério escolhido.

Para avaliar a diminuição do erro, é necessário dividir os dados em amostras de treinamento e teste. O modelo é ajustado aos dados de treinamento e, em seguida, são feitas previsões para os dados de teste. A métrica utilizada para avaliar o erro neste trabalho será o erro quadrático médio será utilizado como métrica para avaliar o desempenho do modelo.

$$Y_t = L_t S_t + b_t + \epsilon_t$$

$$Y_t = L_t + S_t + b_t + \epsilon_t$$

### 3.2.3 Análise Espectral Singular

Análise espectral singular pode ser do tipo univariada e multivariada (GOLYANDINA, NEKRUTKIN, ZHIGLJAVSKI, 2002). Para esse projeto, o foco estará no primeiro caso. A álgebra desse método está dividida em duas partes a decomposição e a reconstrução (HASSANI, ZHIGLJAVSKY, 2008). O primeiro passo consiste em mapear os valores de uma série temporal univariado,  $Y_t = [y_1, \dots, y_N]$ , para a matriz:

$$(X_{ij})_{(i,y=1)}^{L,K} = (X_1, X_2 \dots X_K) = \begin{pmatrix} y_1 & y_2 & \dots & y_L \\ y_2 & y_3 & \dots & y_{L+1} \\ \vdots & \ddots & \vdots & \vdots \\ y_k & y_{k+1} & \dots & y_T \end{pmatrix}$$

onde,  $K = N - L + 1$ , sendo  $N$  tamanho do vetor unidimensional e  $L$  a janela de interesse. Logo para cada série temporal, se tem uma matriz Hankel, diagonais secundárias com valores iguais, ou para cada diagonal  $y + j = constante$ , seus elementos são iguais, esse resultado também é chamado de matriz trajetória. O caso multivariado consiste em mapear para  $M$  séries,  $Y_t^{(i)}$ , sendo  $i = 1, \dots, M$  a sua correspondente matriz trajetória  $X^{(i)}$ , incorporando essa matriz em uma nova,  $X_v = (X^{(1)}, \dots, X^{(M)})^T$ . Para os próximos passos, seja para  $X$  ou  $X_v$ , se realizará os mesmos procedimentos.

Tendo em mãos as matrizes de trajetórias, é possível montar a matriz covariância que será igual a  $XX^t$  ou  $X_vX_v^t$ , a depender do tipo de caso univariado ou multivariado. Com essa matriz usa-se a decomposição em valores singulares (SVD), para encontrar os respectivos valores singulares, vetores singulares e o sistema ortonormal associado a ele,  $(\lambda_i, V_i, U_i)$ , ou também chamado suas autotriplas. A quantidade de componentes será dos “ $d$ ” valores singulares maiores que zeros, ou seja, o posto da matriz, logo será possível decompor a matriz  $X$  como a soma de suas componentes (autotriplas), onde  $X = X_1 + X_2 + \dots + X_d$  de modo que  $X_i = \sqrt{\lambda_i} U_i V_i^T$  e  $V_i = X^T U_i / \sqrt{\lambda_i}$ , posicionando as componentes na ordem do maior valor singular para o menor, de forma que  $\lambda_1 > \lambda_2 > \dots > \lambda_d$ .

Para etapa de reconstrução foi adotado um método em que se divide cada componente em dois grupos, um que configura o sinal e outra que configura ruído, de

forma que o sinal reconstruído, quando passar por um processo de recorrência (será explicado nos próximos parágrafos), poderá ser usado como um modelo de previsão.

O processo usado para escolher quais componentes pertence ao sinal consiste em analisar o  $erro(f)$ , ou seja, a diferença entre a previsão e as amostras de teste, de modo que  $f$  seja a quantidade de componentes que são adicionadas ao grupo sinal, onde  $f = 1, 2, \dots, d$ , logo  $erro(1)$  é o erro com o sinal sendo formado pela primeira auto tripla (valor singular maior),  $erro(2)$  é a mesma operação para a soma das duas primeiras autotriplas e assim por diante. Se  $erro(f)$  for plotado, se observará que o valor do erro vai diminuir com o aumento de  $f$ , até que em certo momento se interrompe o declínio, em  $f = r$ , sendo esse valor a linha de corte entre as componentes que formam o sinal e o ruído.

Dessa forma será possível construir uma aproximação da matriz  $X$  de modo que:  $\tilde{X} = \sum_{i=1}^r X_i$ . Agora se necessita voltar para  $Y_t$ , para a isso  $\tilde{X}$ , deve passar por um processo de *Hankelization*, onde, como o nome diz, consiste em fazer com que a matriz se torne de Hankel.

Para isso é feito um processo de média das diagonais, de modo que seu resultado, passará pelo processo inverso do mapeamento realizado no início desse capítulo, encontrando assim  $\tilde{Y}_t$ .

O método que será usado para fazer previsões, é uma aproximação que satisfaz uma fórmula linear recorrente, (2). O algoritmo que permite fazer a recorrência parte do vetor singular  $U_i$ , seleciona as  $L - 1$  primeiras componentes, denota-se como  $U_i^A$ . Depois é possível definir  $v^2 = (\pi_1^2 + \dots + \pi_r^2)$ , onde  $\pi_i$  é o último elemento de cada componente de  $U_i$ . Sabe-se que toda última componente de um vetor pode ser descrita como a combinação linear das primeiras componentes, da seguinte maneira que:  $y_L = (a_1 y_{L-1}, \dots, a_{L-1} y_1)$ , onde os coeficientes de  $A = (a_1, \dots, a_{L-1})$ , podem se encontrados com a seguinte equação:  $A = \sum_{i=1}^r \pi_i U_i^A / (1 - v^2)$ . De forma que seja possível descrever a previsão das amostras, assim  $\widehat{y_{(T+1)}}$ ,  $\dots$ ,  $\widehat{y_{(T+h)}}$ , sendo  $h$  quantidade de amostras que se deseja prever.

$$\sum_{i=1}^r \pi_i U_i^A / (1 - v^2) \quad (2)$$

### 3.3 AVALIAÇÃO

Para avaliar os modelos será usado a seguinte medida de erro,  $e_t = Y_t - \tilde{Y}_t$ , de modo que as seguintes métricas poderão avaliadas.:

Tabela 2 Métricas de avaliação da previsão

Erro médio absoluto (MAE)	$MAE = \frac{1}{T} \sum_{t=1}^T  e_t $
Erro percentual médio absoluto (MAPE)	$MAPE = \frac{1}{T} \sum_{t=1}^T \left  \frac{e_t}{y_t} \right  \times 100$
Erro quadrático médio (MSE)	$MSE = \frac{1}{T} \sum_{t=1}^T e_t^2$
Erro quadrático acumulado (EQA)	$EQA = \sum_{t=1}^T e_t^2$
Raiz do erro quadrático médio (RMSE)	$RMSE = \sqrt{\frac{1}{T} \sum_{t=1}^T e_t^2}$

Fonte: Autor (2023)



#### 4. ANÁLISE EXPLORATÓRIA

Com o objetivo de visualizar e inferir informações relevantes sobre as séries históricas dos setores da Indústria de Transformação, serão apresentados alguns exemplos que abordam a decomposição das séries em suas componentes e a correlação entre as séries históricas. Esses exemplos foram selecionados com base no intuito de contextualizar certos aspectos dos modelos de previsão que serão utilizados posteriormente, além de colaborarem para o entendimento dos ciclos econômicos e sua relação.

Os dados deste trabalho são provenientes de 52 setores da indústria de transformação, abrangendo o período entre os anos de 2002 e 2022. A análise estatística realizada, que inclui a média e a variância das séries, ver Tabela 3, apresenta uma ampla diversidade de séries temporais. Destacam-se três setores com as maiores variâncias: 19.3, 32.1 e 27.4, respectivamente. São eles: fabricação de biodiesel; artigos de joalheria, bijuteria e produtos similares; e fabricação de lâmpadas e outros equipamentos de iluminação. Por outro lado, os setores com as menores variâncias são: 17.2, 10.1 e 10.6, respectivamente, fabricação de papel, cartolina e papel-cartão; produtos de carne; e produtos amiláceos e alimentos para animais. É importante ressaltar que você encontrará no Apêndice A os nomes dos setores associados aos seus respectivos códigos.

Tabela 3 Média e Variância de cada setor

<b>Setor (ID)</b>	<b>Média</b>	<b>Variância</b>	<b>Setor (ID)</b>	<b>Média</b>	<b>Variância</b>
10.1	101,2	41,5	22.1	95,8	106,7
10.3	84,4	1587,9	22.2	89,4	91,2
10.4	102,7	195,1	23.1	102,2	102,9
10.5	95,0	108,4	23.2	83,0	178,4
10.6	97,5	42,9	23.3	80,3	239,8
10.7	100,2	3984,4	23.4	90,9	148,0
10.8	93,1	328,2	23.9	92,3	185,2
11.1	92,0	234,4	24.1	94,8	287,1
11.2	85,8	282,7	24.2	93,4	156,8
13.1	109,5	1046,4	24.5	99,1	514,4
13.2	102,3	846,7	25.3	86,4	226,6
13.3	83,3	458,0	25.4	87,8	204,4
14.1	98,7	717,1	26.2	82,5	850,8
14.2	85,4	559,3	26.4	94,4	667,3
15.1	97,2	305,1	27.4	102,9	4291,3

16.2	101,9	151,5	27.5	81,7	284,8
17.1	104,1	591,3	28.1	89,7	180,3
17.2	96,0	40,2	28.3	90,0	402,2
17.3	94,0	46,1	28.5	82,8	673,2
17.4	87,9	107,3	28.6	102,7	539,4
19.2	93,4	57,9	29.1	77,9	446,0
19.3	115,8	4879,5	29.2	91,6	1112,7
20.1	96,9	193,8	29.3	84,2	596,5
20.5	98,2	2174,1	29.4	86,0	424,0
20.6	96,9	112,1	31.0	82,3	186,9
20.7	81,2	334,8	32.1	100,8	4854,8

Fonte: Autor (2023)


A variância das séries pode estar associada a diferentes motivos, dois deles são a característica do setor econômico e a ocorrência de crises econômicas. Em relação à característica do setor econômico, alguns desses estão sujeitos a alta sazonalidade, o que influencia diretamente a variância das séries. Por exemplo, os setores de biodiesel e refino de açúcar (19.3 e 10.7) possuem uma forte dependência dos ciclos agrícolas, o que gera flutuações sazonais em relação aos insumos desses setores. Outro fator que pode contribuir para uma alta variância é o grande crescimento de determinados setores como é o caso da produção de defensivos agrícolas e desinfetantes domissanitários (20.5). O contrário também é válido, uma vez que o decréscimo também ocasiona alta variância. Como exemplo há o setor fabricação de lâmpadas e outros equipamentos de iluminação (27.4), que desde a crise de 2008 vem gradualmente diminuindo o seu volume de produção.

No que diz respeito às crises econômicas, estas também podem resultar em um aumento na variância das séries. Durante períodos de instabilidade econômica, os setores enfrentam desafios como redução na demanda, restrições financeiras e incertezas generalizadas. Nas amostras utilizadas, é possível observar os períodos recessivos nos setores industriais durante as crises de 2008 entre setembro desse ano e março de 2009, a crise política de 2014, entre março desse ano e dezembro de 2016 e a crise da pandemia de covid, entre fevereiro e junho de 2020 (FGV,2023). Observe os efeitos das crises usando como exemplo o setor 29.3 na Figura 3, além do Apêndice B, que contém essa análise para todos os setores.

No entanto, nem todos os setores foram impactados com a mesma intensidade durante as crises. Um exemplo é o setor de fabricação de papel (17.1), que, apesar de

apresentar variações negativas durante os períodos de crise, manteve uma tendência positiva, ver Figura 3. Além disso, alguns setores se destacaram pelo impacto abrupto das crises, como é o caso dos setores associados aos números 28 e 29, relacionados a máquinas e veículos, respectivamente, nos quais as três crises foram claramente observáveis.

Figura 3 Produção física: celulose (17.1), máquina agropecuária (28.3), carroceria (29.3)



Fonte: Autor (2023)


#### 4.1 DECOMPOSIÇÃO DAS SÉRIES

Conforme já descrito na Secção 3, os modelos Holt Winters e a Análise Espectral Singular (AES) usam de decomposições em suas abordagens. Nesse sentido, foram realizados alguns testes usando as decomposições aditiva e multiplicativa, além de analisar as componentes da matriz trajetória usando SVD.

Usando como exemplo o setor de fabricação de produtos de material plástico (22.2), foi construída a matriz de trajetória correspondente e aplicada a decomposição em valores singulares (SVD), obtendo assim as autotriplas singulares  $(\lambda_i, V_i, U_i)$ . Na Figura 4, foi apresentado o gráfico dos valores singulares em cada componente. É importante

observar que o primeiro valor singular é significativamente maior do que os demais, motivo pelo qual foram fornecidas duas visualizações: uma com a primeira componente e outra sem ela, permitindo uma análise mais detalhada do comportamento dos demais valores singulares. Além disso, na figura 4, é possível ver o gráfico do vetor singular  $U_i$  para cada componente. Repare, no primeiro quadro, que a componente principal (1) concentra 94,89% do sinal, representado pela razão entre  $\lambda_1$  e a soma de todos os outros valores singulares.

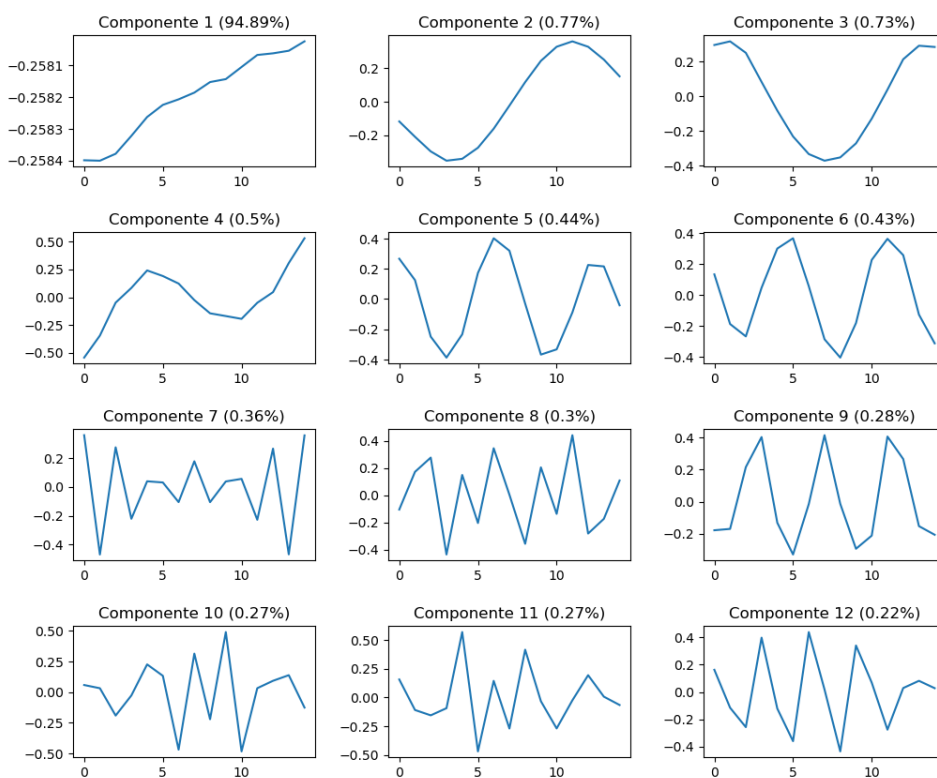
Figura 4 Valores Singulares vs r (com e sem a primeira componente)



Fonte: Autor (2023)

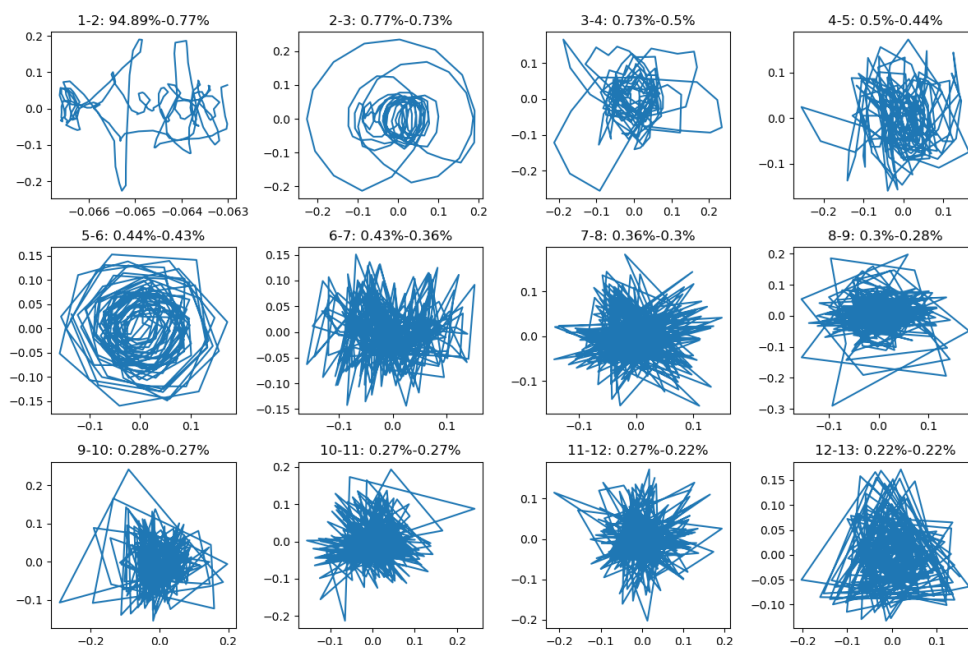
Um comportamento interessante pode ser observado na Figura 4; as componentes que têm valores singulares próximos, comumente indicam que elas compartilham alguma harmônica. Para verificar isso foram plotados os pares dos vetores singulares  $V_i$  consecutivos de forma a conectar suas linhas, formando os gráficos da Figura 5. Repare que, se os pares forem harmônicos entre si, eles tendem a formar padrões nos desenhos e o contrário também é válido. Veja como exemplo o par 1-2 que não formam padrões indicando que não são harmônicos entre si. Porém os pares 2-3, 5-6, 12-13 formam objetos próximos a círculos, quadrados e triângulos, ou seja, indicando um comportamento oscilatório constante indicando que esses pares são harmônicos (HASSANI, ZHIGLJAVSKY, 2009).

Figura 5 As 12 primeiras Componentes



Fonte: Autor (2023)

Figura 6 Scatterplots dos 12 primeiros pares de vetores singulares V conectados




Fonte: Autor (2023)

Ainda sobre decomposição, a Transformada Discreta de Fourier (DFT) também foi empregada na interpretação das séries temporais. Uma versão da análise dos espectros

de cada setor pode ser encontrada no Apêndice C, a seguir serão destacados alguns casos interessantes. Vale ressaltar que essas séries não foram plotadas em termos de frequência, mas sim em relação ao período, seguindo a abordagem adotada por Korotayev e Tsirel (2010). Essa abordagem facilita a interpretação direta da duração em meses de cada ciclo.

É interessante notar o acúmulo de ruído dentro da faixa de 0 a 20 meses. Além disso, foi percebido um componente próximo a um ano que apareceu em praticamente todos os sinais. Uma hipótese é que esse componente esteja relacionado aos próprios efeitos da sazonalidade anual na economia. No entanto, os setores que apresentam essa componente de forma proporcionalmente maior em relação às outras, pode indicar que há uma relação com a natureza, como é o caso das indústrias agrícolas e de extração mineral. Por exemplo, a família de código 10, relacionada à agricultura, e a família 23, que engloba a produção de vidro e cimento, apresentam essa componente de forma mais evidente. Além disso, é possível verificar esse ciclo sincronizado em setores correlatos, como é o exemplo produção de alimentos para animais e defensivos agrícolas (10.6 e 20.5), e também da produção de leite e a fabricação de bebidas não alcoólicas (10.5 e 11.2) ver Figura 7.

Figura 7 Espectro de potência (por período): Alimentos animais (10.6), Defensivos agrícolas (20.5), Leite (10.5), Bebida não alcoólicas (11.2)

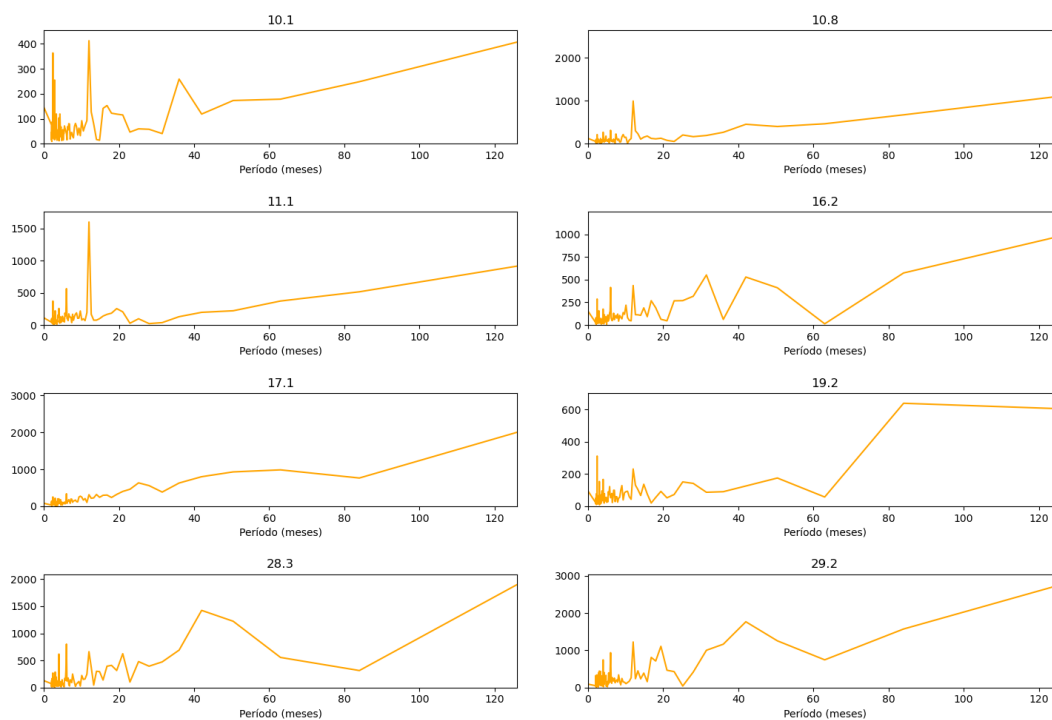


Fonte: Autor (2023)

Outro componente observado abrange a faixa de 40 a 60 meses, e pode ser observado em quase todas as séries econômicas. A primeira hipótese está associada aos ciclos Kitchin mencionados nas referências bibliográficas. No entanto, é importante ressaltar um viés nas amostras coletadas, que é o fato de terem ocorrido três crises econômicas espaçadas entre 4 e 6 anos.

É interessante observar as componentes na faixa de 6 a 10 anos, associadas ao ciclo de Juglar. Essas componentes não são uniformes entre os setores, mas é notável que os setores que apresentam componentes significativas nessa faixa e uma taxa de variação crescente em direção a períodos maiores que 10 anos. Parecem estar relacionados a setores industriais que o país tem vantagens comparativas. Alguns exemplos incluem a indústria da carne (10.1); bebidas alcoólicas (11.1); café (10.8); madeira, excluindo móveis (16.2); papel (17.1), petróleo (19.2), máquinas agrícolas (28.3) e caminhões e ônibus (29.2), ver na Figura 8. Uma possível explicação para isso é a capacidade desses setores no Brasil de realizar investimentos significativos na substituição de maquinários e no aumento da produção, considerando a competição no comércio internacional pode haver uma sincronização com as cadeias produtivas dos países centrais, onde os ciclos de Juglar já foram observados.

Figura 8 Espectro de potência (por período): Carne (10.1), café (10.8), Bebida alcoólicas (11.1), Madeira (16.2), Papel (17.1), Petróleo (19.2), Máquinas Agrícolas (28.3), Caminhões e Ônibus (29.2)



Fonte: Autor (2023)

Em relação ao ciclo de Kondratiev, esse não pode ser identificado já que as amostras utilizadas são de apenas 20 anos, e esse ciclo é de em média 50 anos, logo não possível detectar essas componentes.

Já em relação às correlações entre os dados, é interessante observar a Tabela 4, que representa as relações entre as indústrias de transformação. Embora este trabalho não aborde modelos multivariados, é importante conhecer as diferentes relações entre essas indústrias. Algumas delas apresentam uma interrelação bastante associada à proximidade dentro do processo produtivo. Por exemplo, as indústrias de biodiesel e açúcar (10.7 e 19.3), bebidas alcoólicas e não alcoólicas (11.1 e 11.2), tecidos e roupas (13.1 e 14.1) apresentam correlações significativas. Por outro lado, algumas correlações são mais difíceis de explicar, o que pode indicar que são espúrias, por exemplo, observa-se uma autocorrelação entre a indústria de tintas e eletrodomésticos (20.7 e 27.5), tecidos e aparelhos de pedra (13.3 e 23.9), entre outros. Esses dados sobre as correlações entre as indústrias podem ser úteis para auxiliar na seleção de determinados setores ou segmentos para análise mais aprofundada ou tomada de decisões estratégicas.

Tabela 4 Pares de Correlação maiores que 0,8

Par de Setores		Correlação	Par de Setores		Correlação
13.1	13.2	0,95	20.7	27.5	0,82
13.1	27.4	0,94	22.1	29.4	0,82
10.7	19.3	0,93	22.1	25.3	0,82
13.2	27.4	0,93	23.9	24.2	0,83
13.2	13.3	0,89	13.1	14.1	0,82
29.2	29.3	0,88	25.3	25.4	0,82
11.1	11.2	0,88	13.3	25.4	0,82
25.4	29.4	0,87	13.3	23.9	0,82
23.9	25.4	0,86	24.2	25.3	0,81
13.2	14.1	0,85	24.2	24.5	0,81
22.2	31.0	0,85	11.2	20.7	0,81
10.8	20.6	0,84	13.1	13.3	0,81
23.9	29.4	0,84	22.1	24.2	0,81
13.3	29.4	0,84	28.5	29.2	0,81
13.3	14.1	0,84	20.7	23.4	0,80
25.3	29.4	0,84	22.1	28.1	0,80
24.2	29.4	0,83	15.1	17.1	-0,80
28.1	29.4	0,83	13.1	17.1	-0,85
20.7	23.2	0,83	17.1	27.4	-0,86

Fonte: Autor (2023)



## 5. ANÁLISE USANDO MODELOS PREDITIVOS

O primeiro passo antes de analisar os modelos, foi passar os dados para uma base logarítmica, procedimento padrão nos artigos referenciados. Em seguida, foram criados dois subconjuntos um para treinamento e outro para teste, de modo que esse último tivesse 25 amostras partindo de dezembro de 2022 para trás, enquanto treinamento ficou com as restantes 227 amostras. Para cada modelo, foram definidos ranges de variação dos parâmetros, para se encontrar combinações que diminuíssem os erros entre as amostras de teste e as amostras previstas usando o subconjunto de treinamento.

Em seguida, foram definidos os limites dos parâmetros. O primeiro deles foi um de “janelamento”, com características parecidas entre os três modelos, mas funções diferentes em cada um. Esses são  $L, s, T$  respectivamente do AES, SARIMA e o Holt Winters, seguindo a orientação de se buscar janelas proporcionais aos períodos sazonais de cada setor (HASSANI, H., ZHIGLJAVSKY, 2009). Conforme já mencionado a sazonalidade anual, foi uma componente observada em praticamente todas as séries, por isso se definiu tamanhos proporcionais a 12. Num primeiro momento, optou-se por rodar valores de “janelamento” de 1 há 72 meses (6 anos), no entanto os modelos levaram um tempo significativo para serem processados, com exceção do HW que rodou em cerca de uma hora, já para o AES optou-se por dividir em 6 possibilidade de  $L$  proporcionais a 12 (12,24,36,48,60,72), porém para SARIMA usou-se 12 apenas devido à demora para processar, cerca de 10 horas, mas isso não prejudicou tanto a sua previsão já que o modelo apresentou bons resultados para a previsão das amostras de teste.

Já os parâmetros  $(p,d,q)(P,D,Q)$  foram ajustados para seguintes faixas (0-3,0-2,0-3)(0-3,0-2,0-3), lembrando que essas são as ordens de dois polinômios e quantidade de diferenciação. Da análise dos dados, foi visto que o processo de estacionarização das séries já era feito com duas diferenciações, enquanto os sinais visualmente não pareciam precisar de um polinômio de quarto grau.

As decomposições das componentes de tendência e sazonalidade no modelo HW foram ajustadas com duas possibilidades: aditiva e multiplicativa. Além disso, o valor de  $r$  foi definido como até 25, levando em consideração que raramente o modelo precisa reconstruir com mais de 25 componentes.

Após treinar e testar os modelos usando a métrica MSE, foram definidos os parâmetros (Apêndice D) e, em seguida, as previsões foram avaliadas usando outras

métricas. Inicialmente, as previsões foram avaliadas em relação aos dados de treinamento (*in-sample*) e aos dados de teste (*out-of-sample*), conforme descrito no Apêndice F.1.

No caso dos dados de treinamento, o modelo SSA obteve os menores erros, ganhando em 60% dos casos. Em seguida, o HW teve uma taxa de acerto de 31%, enquanto o SARIMA obteve o pior desempenho, com apenas 10% de acertos, ver Tabela 5. Porém, ao avaliar as previsões nos dados de teste, a situação se inverteu. O SARIMA teve o melhor desempenho, acertando 48% dos casos. O AES obteve 29% de acertos, enquanto o HW ficou em último lugar com 23%.

Tabela 5 Quantidade de casos em que cada modelo apresentou menor erro (treinamento e teste) – com 25 amostras de teste

<b>MSE - 25 AMOSTRAS</b>	<b>SSA</b>	<b>SARIMA</b>	<b>HW</b>
<b>IN-SAMPLE (TREINAMENTO)</b>	31	5	16
	60%	10%	31%
<b>OUT-OF-SAMPLE (TESTE)</b>	15	25	12
	29%	48%	23%

Fonte: Autor (2023)

Em seguida, os testes foram refeitos considerando amostras de previsão de 1, 6, 9 e 12 meses, conforme Apêndice E.1. Nesse caso, observou-se uma melhora no desempenho do modelo AES em relação aos outros dois modelos. Ao considerar as 208 combinações entre os 52 setores e 4 horizontes de previsão, a proporção de acertos do AES foi de 69%, enquanto o HW obteve 18% e o SARIMA ficou com 13% de acertos, ver Tabela 6. Quando analisados separadamente os horizontes de previsão, AES continua sendo o melhor modelo para todos os horizontes de previsão. No entanto, as proporções de acertos variaram. Enquanto o AES teve uma proporção maior de acertos à medida que o horizonte de previsão aumentava, HW e o SARIMA viram sua proporção diminuir. Observe que no horizonte de 12 mês, AES alcança o seu maior valor com 81% dos melhores casos.

Tabela 6 Erro de previsão para horizontes de 1, 6, 9 e 12 meses – com 25 amostras de teste

<b>PREVISÃO-MSE 25</b>	<b>1</b>		<b>6</b>		<b>9</b>		<b>12</b>		<b>TODOS OS CASOS</b>	
	QT	%	QT	%	QT	%	QT	%	QT	%
<b>SSA</b>	25	48%	36	69%	41	79%	42	81%	144	69%
<b>SARIMA</b>	16	31%	7	13%	2	4%	1	2%	26	13%
<b>HW</b>	11	21%	9	17%	9	17%	9	17%	38	18%

Fonte: Autor (2023)

Observando esses dados, algumas interpretações foram possíveis. A primeira delas é o fato de o AES ter apresentado os melhores resultados para previsão nos 4 horizontes de tempo estabelecidos e na avaliação sobre os dados de treinamento, indo ao encontro do que há na literatura (ALBERTO ORGE PINHEIRO, DE SENNA, 2015; HASSANI, HERAVI, ZHIGLJAVSKY, 2009). No entanto, quando se considera todo o espaço das amostras de teste o SARIMA se torna o melhor modelo, seguido de AES e HW que estão próximos.

Uma hipótese levantada pelo autor para que o modelo SARIMA apresente melhores resultados quando se considera todo o universo das amostras de teste, está em que AES como observado foi muito melhor nas previsões do passado (amostras de treinamento), porém com uma menor capacidade de generalização em relação ao SARIMA. Um outro motivo para isso é o fato de as amostras de teste terem sido colocadas logo depois da crise de 2020 do Covid 19, momento de grande incerteza e já que o SARIMA tem um sistema de realimentação devido aos seus vetores autorregressivos, esse encontrou os melhores resultados nas previsões.

Ainda sobre esse caso, foi realizada uma segunda análise, conforme apresentado nos Apêndices F.2 e E.2. Nessa análise, os resultados dos erros foram normalizados de forma que o valor do menor erro encontrado para um setor ou para um dos horizontes de tempo seja considerado 0, representado nas tabelas por um travessão (-). Os demais valores são apresentados como proporções em relação ao menor erro medido. Por exemplo, se em determinado setor um modelo apresenta o valor de 0,15, isso significa que seu erro é 15% maior do que o menor erro registrado. Essa abordagem permite uma comparação mais justa entre os modelos, destacando claramente as diferenças de desempenho entre eles em cada setor e horizonte de tempo.

A partir dessas tabelas, foi possível encontrar alguns casos interessantes o primeiro deles é a previsão dos setores 10.6, 32.9 e 26.2, respectivamente os setores de alimentos para animais, produtos diversos, produtos de informática, na Figura 9 pode-se visualizar as previsões para cada setor para o horizonte das amostras de testes (25 amostras). Esses setores apresentaram as previsões mais próximas entre os 3 modelos, ou seja, nenhum dos modelos apresentou um erro maior que 16% do erro mínimo registrado para o setor.

Figura 9 Comparação entre as amostras de teste e as previsões dos 3 modelos, para os setores (10.6;32.9;26.2)



Fonte: Autor (2023)

Outros três casos apresentam diferenças significativas nos erros dos modelos de previsão. No setor 20.6 (Fabricação de sabão, detergente e higiene pessoal), os modelos AES e HW apresentaram erros de 191% e 647%, respectivamente, superiores ao erro do modelo SARIMA. No setor 13.3 (Fabricação de Tecidos), os modelos SARIMA e HW tiveram erros de 234% e 65%, maiores que o erro do modelo AES. Por fim, no setor 28.5 (Fabricação de máquinas e equipamentos de uso na extração mineral e na construção), os

modelos AES e SARIMA exibiram erros de 176% e 340%, respectivamente, maiores que o erro do modelo HW. A previsão desses modelos pode ser visualizada na Figura 10

Figura 10 Comparação entre as amostras de teste e as previsões dos 3 modelos, para os setores (20.6;13.3;28.5)



Fonte: Autor (2023)

Para investigar os efeitos do aumento das amostras de teste no erro do modelo AES, foi realizado outro treinamento usando a métrica MSE e 60 amostras para teste. A primeira análise é avaliar o desempenho entre o modelo AES e o HW usando os dois com 25 e 60 amostras, ver Tabelas 8 e 9. A segunda análise consiste em investigar se o modelo AES treinado usando 25 amostras para teste, apresenta melhores resultados ao mesmo modelo usando 60 amostras, ver Tabelas 7 e 8. Importante salientar que o modelo SARIMA parou de funcionar para 60 amostras de teste e o motivo não foi encontrado até o fim desse projeto. Assim desconsiderando esse modelo essa análise

Tabela 7 Quantidade de casos em que cada modelo apresentou menor erro (treinamento e teste) - com 60 amostras de teste

MSE	25		60	
	SSA	HW	SSA	HW
IN-SAMPLE	32	20	40	12
	62%	38%	77%	23%
OUT-OF-SAMPLE	29	23	32	20
	56%	44%	62%	38%

Fonte: Autor (2023)

Tabela 8 Erro de previsão para horizontes de 1, 6, 9 e 12 meses – com 60 amostras de teste

PREVISÃO	1		6		9		12		TODOS OS CASOS	
	QT	%	QT	%	QT	%	QT	%	QT	%
SSA - 25	37	71%	38	73%	42	81%	42	81%	159	76%
HW - 25	15	29%	14	27%	10	19%	10	19%	49	24%
SSA - 60	24	46%	31	60%	31	60%	27	52%	113	54%
HW - 60	28	54%	21	40%	21	40%	25	48%	95	46%

Fonte: Autor (2023)

Na primeira análise é possível observar que o desempenho tanto do erro de treinamento quanto o de teste, mostra que o AES com 60 amostras é superior ao HW também com 60 amostras. Além disso, note que a proporção de melhores caso de treinamento e teste no AES com 25 amostras (62% e 56%) aumenta usando 60 amostras (77% e 62%), em relação a HW. Para as previsões nos horizontes de 1, 6, 9 e 12 meses, observa-se o fenômeno oposto, AES diminui a proporção de acertos, contra o HW, quando passa de 25 para 60 amostras de teste 76% para 54%.

Tabela 9 Quantidade de casos em que cada modelo apresentou menor erro (treinamento e teste) - com 30 e 60 amostras de teste (SSA)

<b>MSE</b>	<b>SSA-25</b>	<b>SSA-60</b>
<b>IN-SAMPLE</b>	15	37
	29%	71%
<b>OUT-OF-SAMPLE</b>	49	3
	94%	6%

Fonte: Autor (2023)

Tabela 10 Erro de previsão para horizontes de 1, 6, 9 e 12 meses – com 30 e 60 amostras de teste (SSA)

<b>Previsão -MSE</b>	<b>1</b>		<b>6</b>		<b>9</b>		<b>12</b>		<b>TODOS OS CASOS</b>	
	QT	%	QT	%	QT	%	QT	%	QT	%
<b>SSA-25</b>	22	42%	31	60%	28	54%	26	50%	107	51%
<b>SSA-60</b>	30	58%	21	40%	24	46%	26	50%	101	49%

Fonte: Autor (2023)

Já para segunda análise, na Tabela 9, é possível ver que o modelo SSA com 60 amostras acerta mais em relação ao homólogo com 25, quando se fala das amostras de treinamento, enquanto nas de teste diminui os acertos. Sobre esse último caso, isso é esperado, já que é mais difícil ter um erro reduzido quando se aumenta o número de amostras de teste para o modelo prever, enquanto se diminui as amostras de treinamento do modelo. Já em relação a previsão com diferentes horizontes de tempo, considerando todos os horizontes os dois modelos, mantem quantidade total de melhores casos muito próximas (107 e 101), no entanto para uma previsão de um mês o modelo com 60 amostras de teste acerta mais (58%), ao passo que com 6 amostras de previsão, o modelo com 25 amostras de teste melhora seus acertos (60%).

Por último, ressalta-se que o uso de outras métricas no cálculo de erro das previsões usando o modelo já treinado em MSE não mostrou uma diferença brusca entre as proporções dos 3 modelos.

## 6. CONCLUSÃO

Ao fim deste trabalho, foi possível realizar a análise exploratória dos dados, que permitiu não só uma visão mais ampla sobre cada setor individualmente, como também uma visão sistêmica dos comportamentos comuns entre os setores industriais, aportando para uma aplicação mais consciente dos modelos preditivos (Holt-Winters, SARIMA e Modelo de Análise Espectral Singular Univariado), no que se refere a escolha de parâmetros.

Ainda sobre a análise exploratória, foi interessante observar o uso da ferramenta da transformada de Fourier para identificar ciclos econômicos, uma aplicação interdisciplinar interessante e que pode ser usada nos estudos econômicos, já que permite uma visualização diferente sobre os setores econômicos, e pode encontrar seus paralelos em conceitos como de continuidade e descontinuidade da ciência humanas, ou seja, entender os fenômenos que se repetem e aqueles deixam de existir.

A avaliação dos erros de previsão para cada modelos permite inferir que o modelo AES apresenta melhores resultados ao problema dos 4 horizontes de previsão, e a descrição do passado (amostras de treino), do que o HW e o SARIMA. No entanto, em relação à diminuição do erro nas amostras de testes o modelo SARIMA apresentou melhores resultados.

Como sugestão de melhoria para este trabalho, sugere-se a aplicação de outros modelos, como é o exemplo da análise espectral singular multivariada, no intuito de investigar as interrelações entre os setores e verificar se isso melhora o desempenho das previsões.



## REFERÊNCIAS

- ALBUQUERQUE, J. C. S.; SERRA, C. M. V. Utilização de modelos de Holt-Winters para a previsão de séries temporais de consumo de refrigerantes no Brasil. In: XXVI ENEGEP, Fortaleza, Anais... Rio de Janeiro: ABEPRO, 2006.
- AUGUSTO DE PAULA LEITE, João; SABIONI LOPES, Luckas; ROBERTO DE MACEDO, Leandro. Flutuações econômicas brasileiras: uma proposta de datação para os trimestres entre 1947 e 2016. **Revista de Desenvolvimento e Políticas Públicas**, [s. l.], v. 3, n. 2, p. 63-74, 2019. DOI 10.31061/redepp.v3n2.63-74. Disponível em: <https://doi.org/10.31061/redepp.v3n2.63-74>. Acesso em: 4 fev. 2023.
- ARAÚJO, E.; CARPENA, L.; CUNHA, A.. Brazilian Business Cycles and Growth from 1850 to 2000. **Estudos Econômicos**, v. 38, n. 3, p. 557-581, 2008. DOI: 10.1590/S0101-41612008000300005. Disponível em: <https://www.scielo.br/j/ee/a/Sd6CHddshSy9dXypsF8BCfC/?lang=en&format=pdf>. Acesso em: 4 fev. 2023
- ALBERTO ORGE PINHEIRO, Carlos; DE SENNA, Valter. Previsão da produção industrial por meio da análise espectral multivariada. **Exacta**, [s. l.], v. 12, n. 1, p. 27-43, 2015. DOI 10.5585/ExactaEP.v13n1.5388. Disponível em: <https://www.redalyc.org/articulo.oa?id=81041502003>. Acesso em: 28 maio 2023.
- BOX, G.E.P; JENKINS, G.M. Time Series Analysis: Forecasting and Control. San Francisco, California: Holden Day, 1976. 575 p.
- BURNS, A. F.; MITCHELL, W. C. Measuring business cycles. Nber Books, 1946.
- CANOVA, F. Detrending and business cycle facts. **Journal of Monetary Economics**, v. 41, n. 3, p. 475-
- CRUZ, Karina Souza et al. Previsão da produção brasileira de biodiesel por meio de modelos de previsão. *Espacios*, Vol. 37 (Nº 27), 2016, p. 4.
- DA COSTA DA SILVA, Cristiano; TROMPIERI NETO, Nicolino; CASTELAR, Ivan; LIMA DA COSTA GADELHA, João. CARACTERIZAÇÃO DOS CICLOS DE NEGÓCIOS DOS SETORES PRODUTIVOS DA INDÚSTRIA BRASILEIRA. Disponível em: <https://caen.ufc.br/wp-content/uploads/2018/11/caracterizacao-dos-ciclos-de-negocios-dos-setores-produtivos-da-industria-brasileira.pdf>. Acesso em: 01 de fevereiro de 2023.
- DA COSTA DA SILVA, Cristiano; TROMPIERI NETO, Nicolino; CASTELAR, Ivan; VANESSA ALVES DA SILVA, Erika. Ciclos econômicos na atividade industrial brasileira: uma análise no domínio do tempo e da frequência. **Nova Economia**, v. 30, n. Nova econ., 2020 30(2), maio 2020. Disponível em: <https://www.scielo.br/j/neco/a/GhP5GvMXwL6DRykqbJNBPPg/abstract/?lang=pt#>. Acesso em: 2 fev. 2023.
- ENGLE, E. M. R. A. A unified approach to the study of sums, products, time-aggregation and other functions of ARMA processes, **Journal of Time Series Analysis**, v.5, p.159–171, 1984.
- FERREIRA NETTO, João. Introdução à Previsão de Demanda, Processos Estocásticos. Universidade de São Paulo (USP). Disponível em: [https://edisciplinas.usp.br/pluginfile.php/5701849/mod\\_resource/content/1/PNV%203421\\_IntroducaoPrevisaoDemanda.pdf](https://edisciplinas.usp.br/pluginfile.php/5701849/mod_resource/content/1/PNV%203421_IntroducaoPrevisaoDemanda.pdf). Acesso em: [23/06/2023].

FGV. Comitê de datação de ciclos econômicos - CODACE. **Comunicado de janeiro de 2023**. [S. l.], 2 fev. 2023. Disponível em: [https://portalibre.fgv.br/sites/default/files/2023-02/comunicado-do-comite-de-datacao-de-ciclos-economicos-31\\_01\\_2023\\_minuta.pdf](https://portalibre.fgv.br/sites/default/files/2023-02/comunicado-do-comite-de-datacao-de-ciclos-economicos-31_01_2023_minuta.pdf). Acesso em: 6 jul. 2023.

GOLYANDINA, Nina; NEKRUTKIN, VLADIMIR; ZHIGLJAVSKI, ANATOLY. Analysis of time series structure: SSA and related techniques. Boca Raton, Florida: Chapman & Hall/CRC, 2002. 309 p.

Hassani, H., Zhigljavsky, A. Singular spectrum analysis: methodology and application to economics data. *Journal of Systems Science and Complexity* volume, 372–394 (2009). <https://doi.org/10.1007/s11424-009-9171-9>

Hassani, Hossein. (2007). Singular Spectrum Analysis: Methodology and Comparison. University Library of Munich, Germany, MPRA Paper. 5. 10.6339/JDS.2007.05(2).396.

HASSANI, Hossein; HERAVI, Saeed; ZHIGLJAVSKY, Anatoly. Forecasting European industrial production with singular spectrum analysis. *International Journal of Forecasting*, [s. l.], v. 25, ed. 1, p. 103-118, 2009. DOI 10.1016/j.ijforecast.2008.09.007. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0169207008001040?via%3Dihub>. Acesso em: 25 maio 2023.

IBGE. Relatórios metodológicos, ISSN 0101-2843 ; v. 31. Série Relatórios Metodológicos: Indicadores Conjunturais da Indústria - Produção, [S. l.], 6 jul. 2023.

IBGE (comp.). Pesquisa Industrial Mensal - Produção Física. 2002 - 2022. Disponível em: <https://sidra.ibge.gov.br/tabela/7511>. Acesso em: 15 fev. 2023.

Juglar C. 1862. Des Crises Commerciales et de leur retour périodique en France, en Angleterre et aux États-Unis. Paris: Guillaumin.

Kitchin J. 1923. Cycles and Trends in Economic Factors. *Review of Economic Statistics* 5: 10–16.

KONDRATIEV, Nicolai. Ondas longas da conjuntura. *Rev. de Occidente*, Madrid, 1946 (1926)

KOROTAYEV, Andrey V; TSIREL, Sergey V. A Spectral Analysis of World GDP Dynamics: Kondratieff Waves, Kuznets Swings, Juglar and Kitchin Cycles in Global Economic Development, and the 2008–2009 Economic Crisis. *Structure and Dynamics*, [s. l.], v. 4, ed. 1, 1 jul. 2010. DOI <https://doi.org/10.1590/0103-6351/4711>. Disponível em: <https://escholarship.org/uc/item/9jv108xp>. Acesso em: 18 jan. 2023.

LIMA DA COSTA GADELHA, João. **Caracterização dos ciclos de negócios nos setores produtivos da indústria brasileira**. Orientador: Prof. Dr. Nicolino Trompieri Neto. 2018. 33 f. Dissertação (MESTRADO EM ECONOMIA DO SETOR PÚBLICO) - Universidade Federal do Ceará, [S. l.], 2018. Disponível em: <http://www.repositorio.ufc.br/handle/riufc/34780>. Acesso em: 5 fev. 2023.

MAMIGONIAN, Armen. Kondratieff, ciclos médios e organização do espaço. *Geosul*, v.14, n.28, p152-157, jul./dez, Florianópolis, 1999b. p.152-157

MARX, Karl. O Capital: crítica da economia política. Volume III. Tradução de Reginaldo Sant'Anna. **São Paulo: Nova Cultural**, 1985. Capítulo XV - A Lei Geral da Acumulação Capitalista.

MARTINELLI, Dante Pinheiro; MARTINS, Talita Mauad. Ciclos e previsão Cíclica dos Preços das Commodities: um modelo de indicador antecedente para a commodity açúcar. *Revista de Administração, Contabilidade e Economia*, [s. l.], v. 2, p. 2-12, 2010. DOI <https://doi.org/10.13059/racef.v1i2.22>. Disponível em: <https://www.fundace.org.br/revistaracef/index.php/racef/article/view/22>. Acesso em: 14 jun. 2023.

M. Ghil, M. R. Allen, M. D. Dettinger, K. Ide, D. Kondrashov, et al.. Advanced spectral methods for climatic time series. *Reviews of Geophysics*, 2002, 40 (1), pp.3. [ff10.1029/2000rg000092](https://doi.org/10.1029/2000rg000092).hal-03222744

SCHUMPETER, Joseph. *Business Cycles: A Theoretical, Historical, and Statistical Analysis of the Capitalist Process*. **New York: McGraw-Hill Book Company, Inc.**, 1939.

SCHEURER, Stefan; NAUMER, Hans-Jörg; NACKEN, Dennis. *The sixth Kondratieff – long waves of prosperity*. Frankfurt: Allianz Global Investor, 2010

PINTO, Álvaro Vieira et al. *O Conceito de Tecnologia*. Rio de Janeiro: Contraponto, 2005. 531 p.

VAUTARD, R; YIOU, P; GHIL, M. Singular-spectrum analysis: A toolkit for short, noisy chaotic signals. *Physica D*, [s. l.], 58, p. 95-126, 1992. DOI [https://doi.org/10.1016/0167-2789\(92\)90103-T](https://doi.org/10.1016/0167-2789(92)90103-T). Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/016727899290103T>. Acesso em: 30 maio 2023.

## APÊNDICE A - LISTA DE SETORES DA INDÚSTRIA DE TRANSFORMAÇÃO

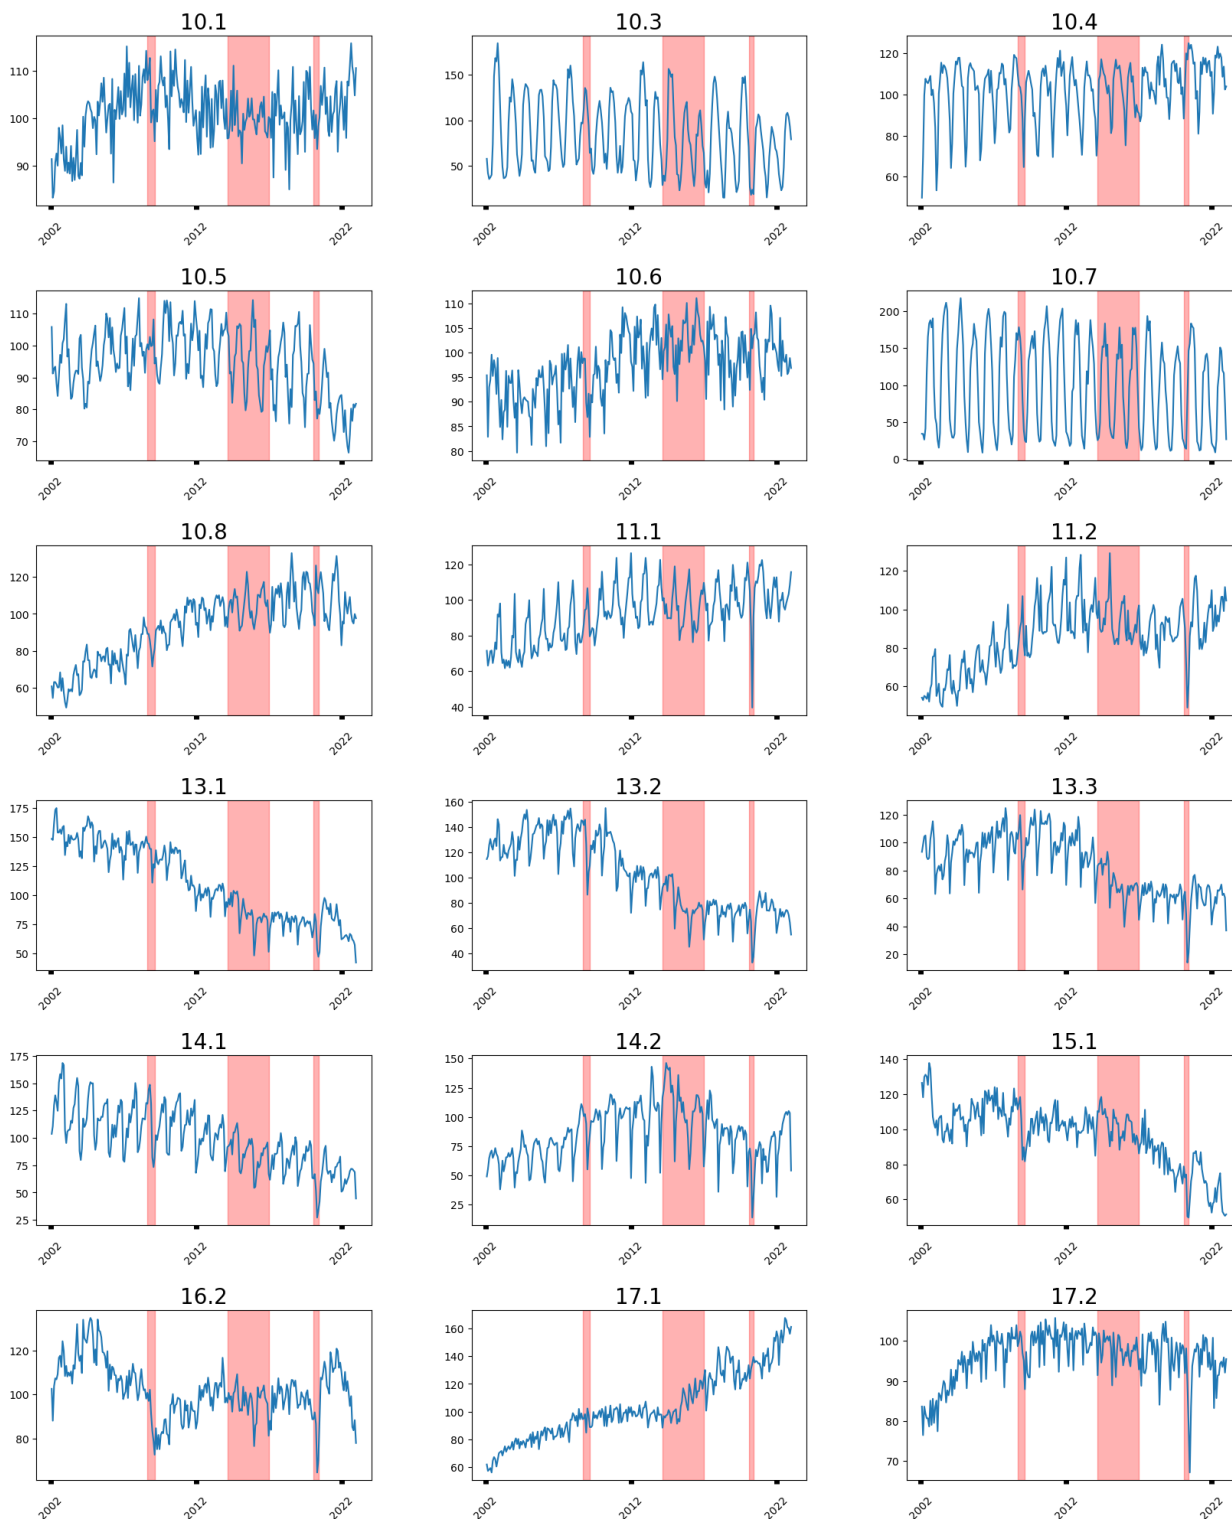
A tabela a seguir consiste na lista dos 52 setores da indústria de transformação econômicos usados nesse projeto, em uma coluna há o código do CNAE do setor e em seguida o nome dele.



















ID	SUBSETOR DA INDÚSTRIA DE TRANSFORMAÇÃO
10.1	Abate e fabricação de produtos de carne
10.3	Fabricação de conservas de frutas, legumes e outros vegetais
10.4	Fabricação de óleos e gorduras vegetais e animais
10.5	Laticínios
10.6	Moagem, fabricação de produtos amiláceos e de alimentos para animais
10.7	Fabricação e refino de açúcar
10.8	Torrefação e moagem de café
11.1	Fabricação de bebidas alcoólicas
11.2	Fabricação de bebidas não alcoólicas
13.1	Preparação e fiação de fibras têxteis
13.2	Tecelagem, exceto malha
13.3	Fabricação de tecidos de malha
14.1	Confecção de artigos do vestuário e acessórios
14.2	Fabricação de artigos de malharia e tricotagem
15.1	Curtimento e outras preparações de couro
16.2	Fabricação de produtos de madeira, cortiça e material trançado, exceto móveis
17.1	Fabricação de celulose e outras pastas para a fabricação de papel
17.2	Fabricação de papel, cartolina e papel-cartão
17.3	Fabricação de embalagens de papel, cartolina, papel-cartão e papelão ondulado
17.4	Fabricação de produtos diversos de papel, cartolina, papel-cartão e papelão ondulado
19.2	Fabricação de produtos derivados do petróleo
19.3	Fabricação de biocombustíveis
20.1	Fabricação de produtos químicos inorgânicos
20.5	Fabricação de defensivos agrícolas e desinfestantes domissanitários
20.6	Fabricação de sabões, detergentes, produtos de limpeza, cosméticos, produtos de perfumaria e de higiene pessoal
20.7	Fabricação de tintas, vernizes, esmaltes, lacas e produtos afins
22.1	Fabricação de produtos de borracha
22.2	Fabricação de produtos de material plástico
23.1	Fabricação de vidro e de produtos do vidro
23.2	Fabricação de cimento
23.3	Fabricação de artefatos de concreto, cimento, fibrocimento, gesso e materiais semelhantes
23.4	Fabricação de produtos cerâmicos
23.9	Aparelhamento de pedras e fabricação de outros produtos de minerais não metálicos
24.1	Produção de ferro-gusa e de ferroligas
24.2	Siderurgia
24.5	Fundição
25.3	Forjaria, estamparia, metalurgia do pó e serviços de tratamento de metais
25.4	Fabricação de artigos de cutelaria, de serralheria e ferramentas



















26.2	Fabricação de equipamentos de informática e periféricos
26.4	Fabricação de aparelhos de recepção, reprodução, gravação e amplificação de áudio e vídeo
27.4	Fabricação de lâmpadas e outros equipamentos de iluminação
27.5	Fabricação de eletrodomésticos
28.1	Fabricação de motores, bombas, compressores e equipamentos de transmissão
28.3	Fabricação de tratores e de máquinas e equipamentos para a agricultura e pecuária
28.5	Fabricação de máquinas e equipamentos de uso na extração mineral e na construção
28.6	Fabricação de máquinas e equipamentos de uso industrial específico
29.2	Fabricação de caminhões e ônibus
29.3	Fabricação de cabines, carrocerias e reboques para veículos automotores
29.4	Fabricação de peças e acessórios para veículos automotores
31.0	Fabricação de móveis
32.1	Fabricação de artigos de joalheria, bijuteria e semelhantes
32.9	Fabricação de produtos diversos

## APÊNDICE B – ESBOÇO DAS SÉRIES TEMPORAIS

Esboço das séries históricas de cada setor, entre o período de 2002 há 2022, e com as crises de 2008, 2014 e da COVID de 2020 pintado de vermelho.



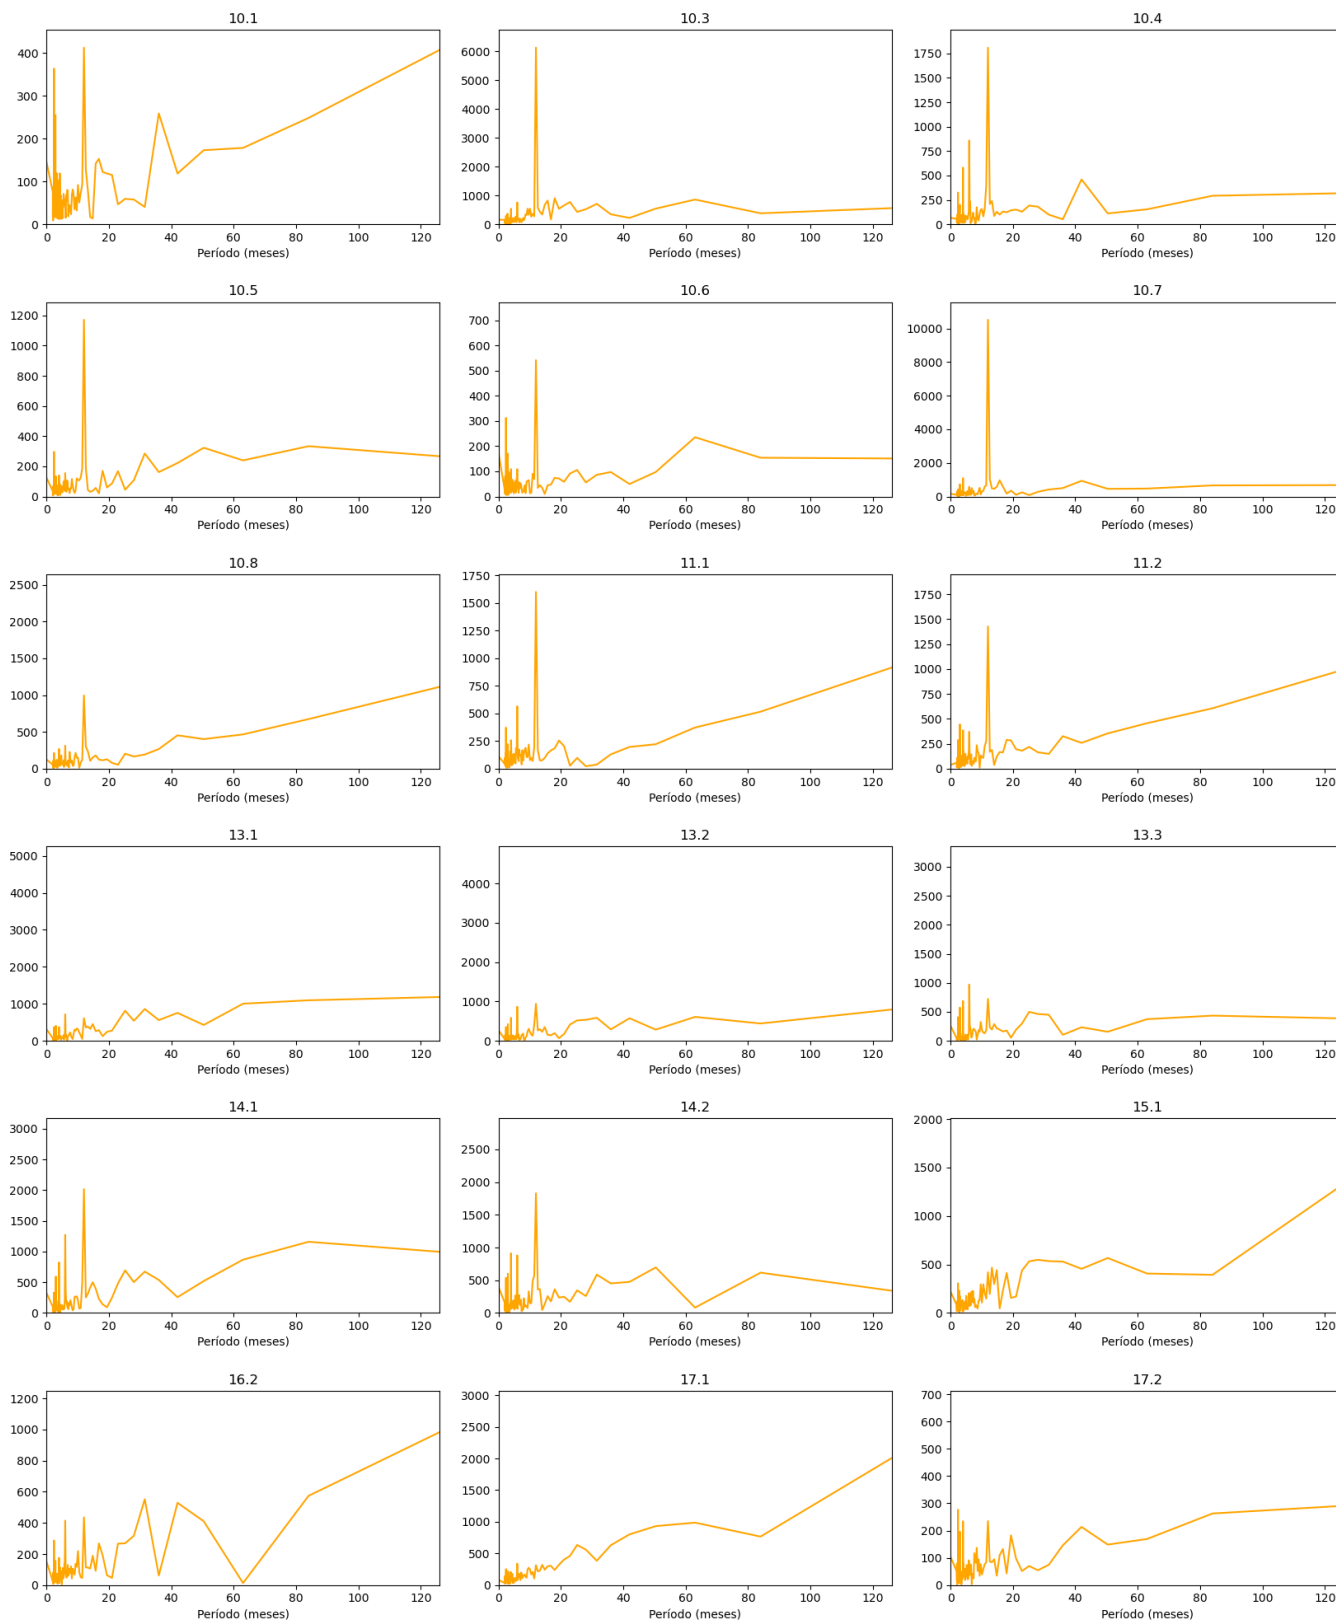


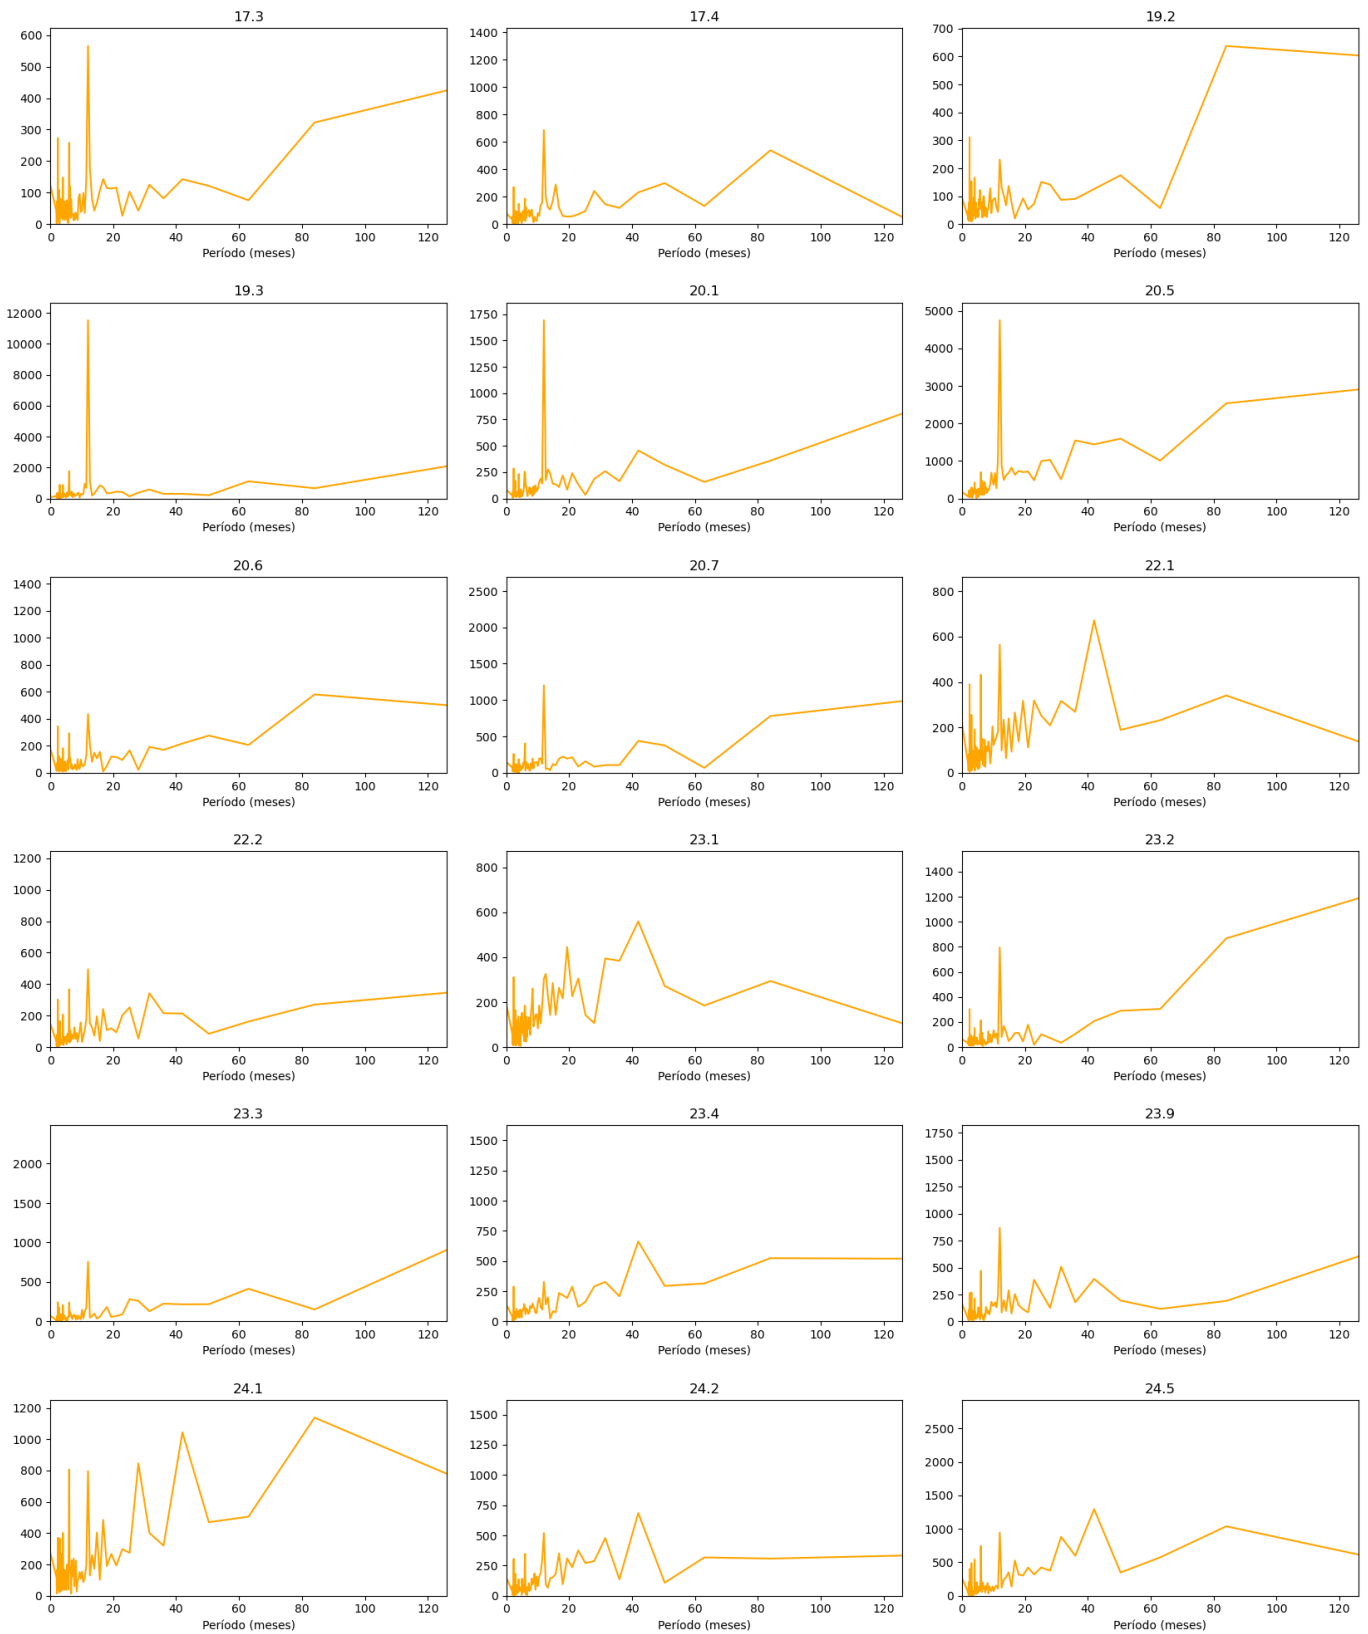


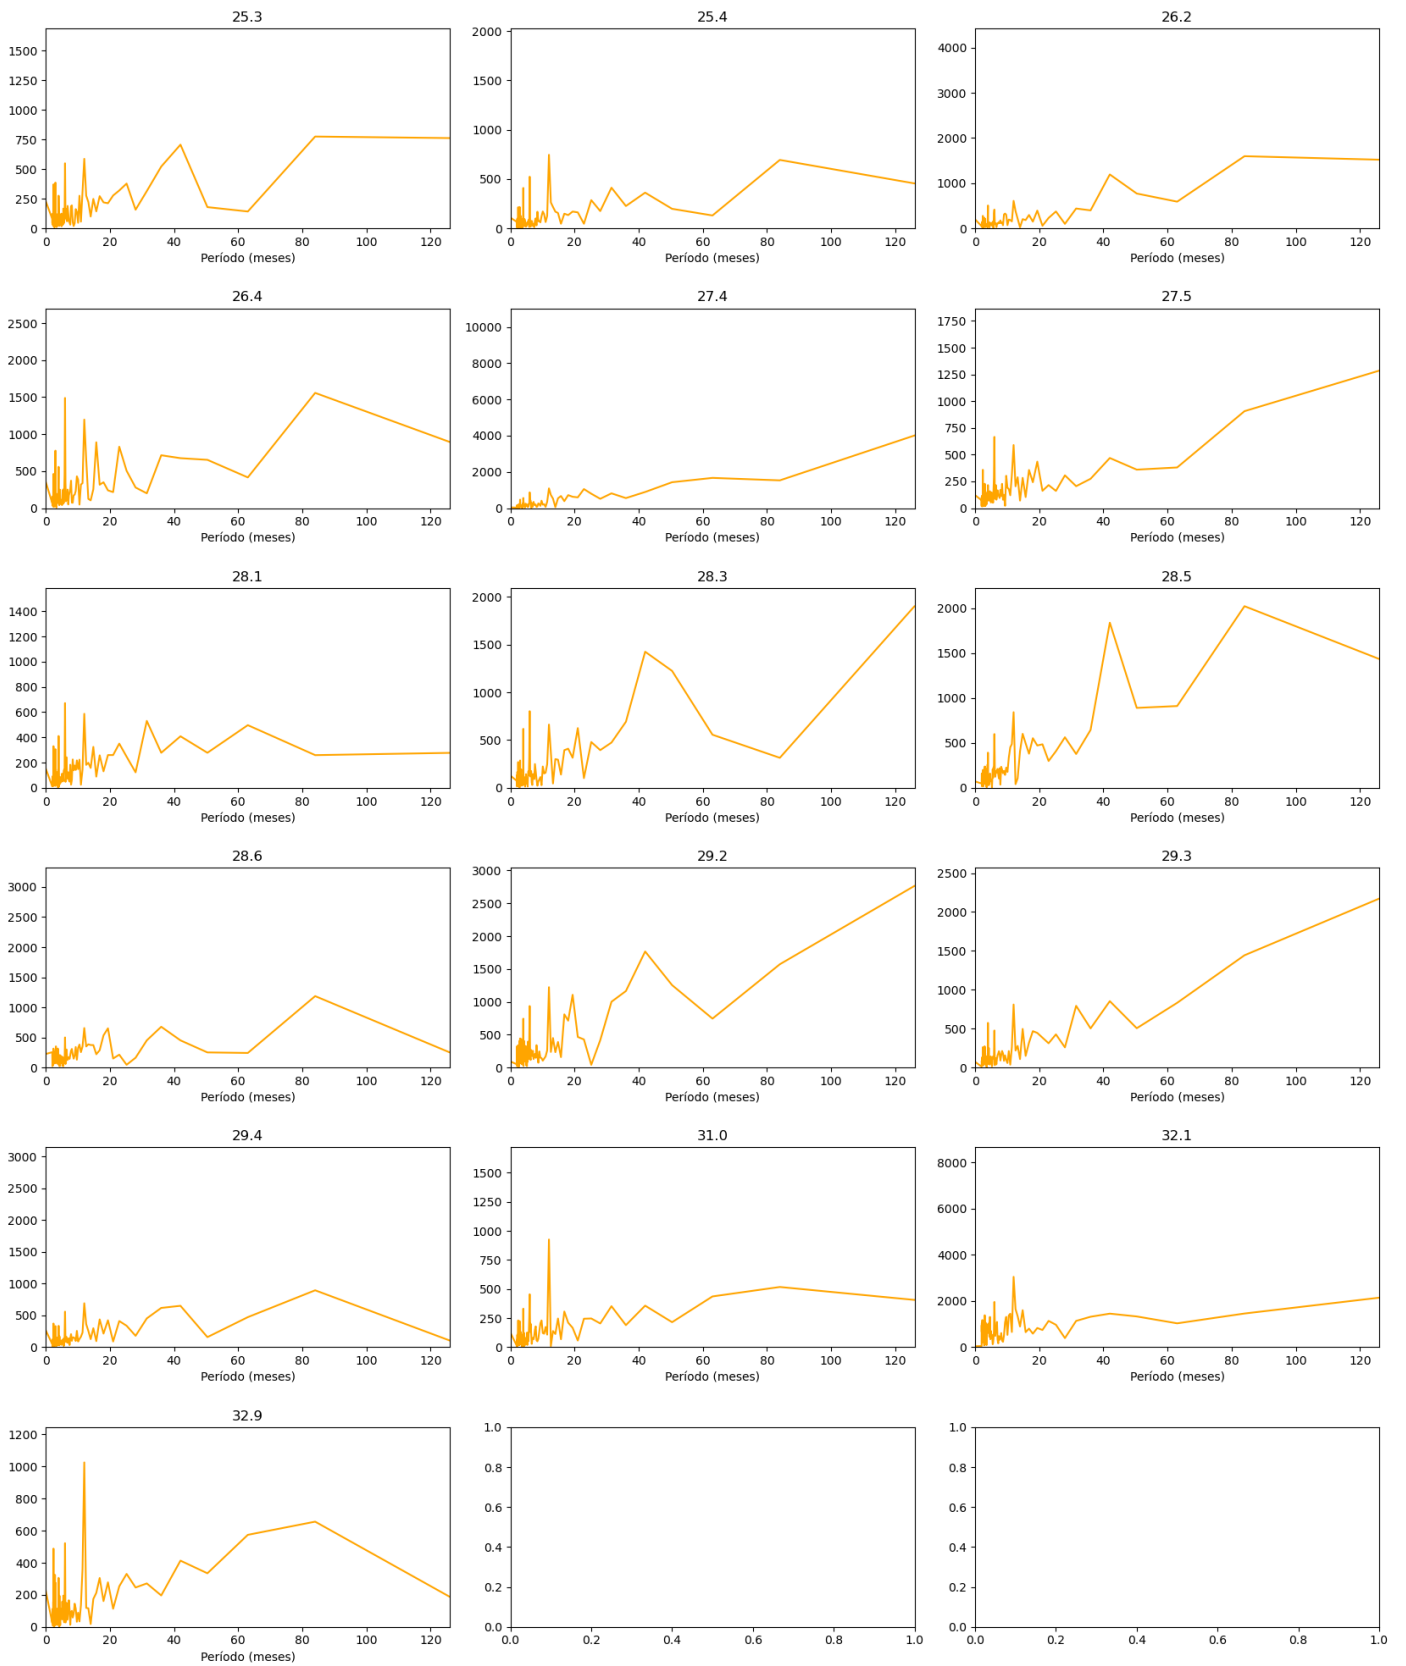


## APÊNDICE C – ESPECTRO DE POTÊNCIA (POR PERÍODO)

AS imagens a seguir são os espectros de potência de cada um dos setores da indústria de transformação. Os gráficos estão plotados em relação ao período, de 0 a 12 meses







**APÊNDICE D – PARÂMETROS DOS MODELOS (MÉTRICA MSE)**

A tabela a seguir consiste na lista dos parâmetros encontrados para cada modelo nos 52 setores econômicos usados nesse projeto, de modo que  $L$  e  $r$  sejam os parâmetros do modelo de Análise Espectral Singular Univariado;  $(p,d,q)(P,D,Q,s)$  sejam do SARIMA; Trend, Seasonal e T os parâmetros de Holt Winters.

Setor	L	r	(p,d,q)	(P,D,Q,s)	Trend	Seasonal	T	Setor	L	r	(p,d,q)	(P,D,Q,s)	Trend	Seasonal	T
10.1	36	5	(1, 1, 0)	(1, 1, 2, 12)	add	mul	12	22.1	60	3	(2, 0, 0)	(1, 0, 2, 12)	mul	mul	12
10.3	72	5	(1, 1, 1)	(1, 0, 1, 12)	add	add	12	22.2	48	1	(1, 1, 1)	(1, 0, 1, 12)	mul	add	37
10.4	24	16	(2, 1, 1)	(1, 0, 2, 12)	mul	mul	12	23.1	48	1	(2, 1, 1)	(1, 0, 1, 12)	mul	add	38
10.5	24	17	(1, 1, 0)	(0, 1, 0, 12)	mul	add	36	23.2	36	3	(2, 0, 2)	(1, 1, 2, 12)	mul	mul	12
10.6	72	11	(1, 0, 1)	(1, 0, 0, 12)	add	mul	24	23.3	60	19	(1, 0, 0)	(1, 0, 1, 12)	add	mul	12
10.7	24	9	(0, 1, 0)	(0, 1, 1, 12)	add	add	12	23.4	60	1	(2, 0, 1)	(0, 0, 0, 12)	mul	add	32
10.8	24	7	(0, 1, 2)	(1, 1, 0, 12)	mul	add	12	23.9	72	18	(1, 1, 2)	(1, 0, 1, 12)	mul	add	12
11.1	48	4	(2, 1, 2)	(0, 0, 0, 12)	add	add	36	24.1	60	19	(1, 0, 0)	(0, 1, 1, 12)	add	add	42
11.2	72	15	(1, 0, 2)	(1, 0, 1, 12)	add	add	36	24.2	60	10	(1, 1, 0)	(0, 0, 0, 12)	mul	add	28
13.1	60	2	(1, 1, 2)	(0, 1, 2, 12)	add	add	37	24.5	12	2	(1, 1, 0)	(0, 0, 0, 12)	mul	mul	34
13.2	12	2	(2, 0, 1)	(1, 0, 2, 12)	mul	add	32	25.3	24	4	(2, 0, 1)	(1, 0, 1, 12)	mul	add	37
13.3	12	2	(2, 0, 0)	(1, 0, 2, 12)	mul	mul	12	25.4	72	1	(2, 1, 1)	(1, 0, 1, 12)	mul	add	37
14.1	72	7	(1, 1, 2)	(1, 0, 1, 12)	mul	add	24	26.2	24	4	(0, 1, 0)	(0, 0, 0, 12)	add	add	3
14.2	36	3	(1, 0, 1)	(1, 1, 2, 12)	add	mul	36	26.4	72	8	(2, 1, 2)	(1, 1, 2, 12)	mul	add	36
15.1	72	5	(2, 1, 2)	(1, 1, 2, 12)	mul	add	37	27.4	60	19	(1, 1, 1)	(0, 1, 1, 12)	add	add	37
16.2	36	4	(1, 0, 2)	(0, 1, 1, 12)	mul	mul	32	27.5	48	5	(1, 1, 1)	(0, 0, 0, 12)	mul	mul	24
17.1	12	2	(0, 1, 2)	(0, 1, 0, 12)	mul	add	45	28.1	72	1	(2, 0, 2)	(1, 0, 1, 12)	mul	add	12
17.2	72	4	(2, 0, 1)	(1, 0, 1, 12)	mul	mul	24	28.3	12	2	(0, 1, 0)	(1, 0, 0, 12)	add	mul	34
17.3	60	6	(2, 0, 0)	(0, 1, 1, 12)	mul	mul	36	28.5	48	12	(1, 1, 2)	(0, 1, 2, 12)	add	mul	45
17.4	24	18	(1, 0, 1)	(1, 1, 1, 12)	add	mul	12	28.6	24	2	(0, 0, 2)	(1, 0, 1, 12)	mul	mul	39
19.2	36	3	(1, 1, 1)	(1, 0, 0, 12)	add	add	24	29.2	12	2	(0, 1, 0)	(0, 0, 0, 12)	add	add	45
19.3	24	12	(0, 1, 1)	(1, 0, 1, 12)	mul	add	12	29.3	48	13	(2, 0, 2)	(0, 0, 0, 12)	mul	add	6
20.1	48	18	(1, 0, 0)	(1, 0, 1, 12)	mul	mul	12	29.4	24	1	(1, 0, 2)	(1, 0, 2, 12)	mul	add	18
20.5	36	12	(1, 1, 1)	(1, 1, 0, 12)	add	mul	19	31.0	72	2	(1, 1, 1)	(1, 0, 1, 12)	mul	add	24
20.6	24	14	(0, 1, 0)	(1, 1, 0, 12)	mul	add	24	32.1	-	-	(2, 1, 2)	(1, 1, 2, 12)	add	mul	36
20.7	24	1	(1, 1, 2)	(0, 0, 0, 12)	mul	add	36	32.9	60	17	(2, 0, 0)	(1, 0, 1, 12)	mul	mul	24

**APÊNDICE E.1 – ERRO ABSOLUTO NA PREVISÃO PARA OS HORIZONTE DE 1,6,9 E 12  
MESES (MÉTRICA MSE)**

A tabela a seguir consiste na lista dos erros de previsão (MSE) para 4 horizontes de previsão diferentes, 1, 6, 9 e 12 meses, em cada setor econômico e para cada método. O modelo usado para cada indústria, usou os parâmetros apresentados no Apêndice D e utiliza 25 amostras de teste. Em Negrito estão os menores valores de erro encontrado para cada setor.

Setor	h	AES	SARIMA	HW	Setor	AES	SARIMA	HW	Setor	SSA	SARIMA	HW
10.1	1	<b>1,17E-03</b>	4,50E-03	8,97E-03	17.2	4,88E-03	<b>4,07E-03</b>	7,16E-03	24.2	9,97E-03	<b>9,23E-03</b>	1,64E-02
	6	<b>7,33E-04</b>	3,86E-03	6,20E-03		<b>2,44E-03</b>	5,09E-03	6,98E-03		<b>9,45E-03</b>	2,09E-02	1,65E-02
	9	<b>6,52E-04</b>	4,13E-03	4,81E-03		<b>3,22E-03</b>	6,14E-03	7,09E-03		<b>1,09E-02</b>	2,30E-02	2,04E-02
	12	<b>2,03E-03</b>	6,38E-03	6,99E-03		<b>2,57E-03</b>	6,16E-03	6,08E-03		<b>1,05E-02</b>	2,51E-02	1,93E-02
10.3	1	<b>3,65E-03</b>	1,76E-02	1,76E-02	17.3	<b>2,98E-03</b>	6,24E-03	1,39E-02	24.5	<b>7,45E-05</b>	2,72E-02	2,43E-02
	6	6,40E-02	<b>4,68E-02</b>	5,98E-02		<b>3,64E-03</b>	6,51E-03	9,85E-03		1,76E-02	3,27E-02	<b>1,68E-02</b>
	9	7,75E-02	4,77E-02	<b>4,68E-02</b>		<b>2,50E-03</b>	7,75E-03	9,11E-03		2,37E-02	3,13E-02	<b>1,84E-02</b>
	12	8,04E-02	5,96E-02	<b>4,71E-02</b>		<b>2,10E-03</b>	1,50E-02	9,40E-03		1,98E-02	3,26E-02	<b>1,51E-02</b>
10.4	1	<b>2,55E-03</b>	5,07E-03	8,67E-03	17.4	1,01E-02	<b>9,57E-03</b>	1,92E-02	25.3	4,02E-02	<b>1,91E-02</b>	2,36E-02
	6	<b>1,46E-03</b>	9,87E-03	1,69E-02		<b>4,68E-03</b>	1,00E-02	1,13E-02		3,23E-02	2,24E-02	<b>2,16E-02</b>
	9	<b>1,07E-03</b>	1,01E-02	1,52E-02		<b>3,68E-03</b>	1,30E-02	8,96E-03		3,17E-02	2,36E-02	<b>2,10E-02</b>
	12	<b>2,15E-03</b>	1,08E-02	1,28E-02		<b>3,16E-03</b>	2,30E-02	8,60E-03		2,86E-02	5,02E-02	<b>2,06E-02</b>
10.5	1	7,55E-03	<b>1,11E-03</b>	1,57E-02	19.2	<b>8,74E-04</b>	4,70E-03	2,03E-03	25.4	<b>8,85E-03</b>	1,60E-02	1,22E-02
	6	<b>3,30E-03</b>	6,58E-03	1,75E-02		<b>5,27E-03</b>	1,14E-02	1,63E-02		1,84E-02	<b>1,70E-02</b>	1,79E-02
	9	<b>3,28E-03</b>	8,30E-03	2,12E-02		<b>3,62E-03</b>	1,20E-02	1,37E-02		<b>1,66E-02</b>	1,89E-02	1,74E-02
	12	<b>4,94E-03</b>	1,10E-02	2,30E-02		<b>3,49E-03</b>	1,45E-02	1,28E-02		<b>1,31E-02</b>	3,05E-02	1,70E-02
10.6	1	3,82E-03	5,48E-03	<b>1,76E-03</b>	19.3	5,29E-02	<b>2,65E-02</b>	8,72E-02	26.2	2,61E-02	<b>1,68E-02</b>	1,98E-02
	6	<b>1,59E-03</b>	6,28E-03	3,73E-03		<b>1,17E-02</b>	3,17E-02	2,79E-02		<b>1,40E-02</b>	1,45E-02	1,97E-02
	9	<b>1,56E-03</b>	6,42E-03	4,83E-03		<b>8,60E-03</b>	3,01E-02	2,04E-02		<b>1,42E-02</b>	1,82E-02	1,85E-02
	12	<b>1,26E-03</b>	1,01E-02	4,31E-03		<b>2,23E-02</b>	6,54E-02	2,89E-02		<b>1,16E-02</b>	1,98E-02	1,45E-02
10.7	1	<b>2,33E-02</b>	3,78E-02	1,49E-01	20.1	<b>5,26E-03</b>	1,06E-02	2,37E-02	26.4	3,26E-02	<b>2,95E-02</b>	4,92E-02
	6	<b>1,94E-02</b>	5,25E-02	7,19E-02		<b>2,45E-03</b>	1,20E-02	1,70E-02		<b>1,45E-02</b>	3,37E-02	2,65E-02
	9	<b>1,99E-02</b>	4,78E-02	5,47E-02		<b>2,33E-03</b>	1,19E-02	1,50E-02		<b>1,77E-02</b>	2,98E-02	2,51E-02
	12	6,68E-02	1,23E-01	<b>6,49E-02</b>		<b>1,98E-03</b>	1,43E-02	1,27E-02		<b>1,79E-02</b>	3,93E-02	3,52E-02
10.8	1	<b>3,51E-05</b>	5,65E-03	1,22E-02	20.5	3,51E-02	<b>1,68E-02</b>	9,36E-02	27.4	<b>8,78E-05</b>	3,41E-02	3,95E-02
	6	<b>2,52E-03</b>	8,08E-03	9,84E-03		<b>2,70E-02</b>	2,79E-02	9,07E-02		<b>2,62E-03</b>	3,84E-02	2,62E-02
	9	<b>6,65E-03</b>	1,16E-02	1,44E-02		<b>2,25E-02</b>	2,85E-02	6,45E-02		<b>3,03E-03</b>	4,16E-02	2,62E-02
	12	<b>6,77E-03</b>	1,21E-02	1,45E-02		<b>1,84E-02</b>	3,16E-02	5,83E-02		<b>1,18E-02</b>	5,46E-02	2,17E-02
11.1	1	<b>5,12E-03</b>	1,58E-02	1,30E-02	20.6	<b>2,18E-05</b>	5,78E-03	5,79E-04	27.5	3,48E-02	2,24E-03	<b>1,53E-03</b>
	6	<b>7,42E-03</b>	1,57E-02	1,44E-02		<b>2,73E-03</b>	5,89E-03	3,74E-03		2,99E-02	1,52E-02	<b>9,37E-03</b>

	9	<b>6,02E-03</b>	1,57E-02	1,26E-02		<b>2,71E-03</b>	8,08E-03	4,26E-03		2,52E-02	1,61E-02	<b>1,06E-02</b>
	12	<b>5,10E-03</b>	1,80E-02	1,23E-02		<b>2,69E-03</b>	6,93E-03	7,94E-03		2,03E-02	<b>1,81E-02</b>	1,95E-02
11.2	1	1,25E-02	<b>7,33E-03</b>	2,65E-02	20.7	8,90E-03	1,12E-02	2,67E-05	28.1	<b>1,66E-03</b>	1,03E-02	2,39E-02
	6	<b>7,57E-03</b>	1,14E-02	2,41E-02		<b>2,64E-03</b>	1,23E-02	9,31E-03		<b>5,13E-03</b>	1,09E-02	1,00E-02
	9	<b>6,91E-03</b>	1,23E-02	2,23E-02		<b>3,72E-03</b>	1,32E-02	6,99E-03		<b>6,51E-03</b>	1,20E-02	8,34E-03
	12	<b>5,19E-03</b>	1,24E-02	2,18E-02		<b>4,15E-03</b>	1,41E-02	1,27E-02		<b>6,88E-03</b>	2,42E-02	8,54E-03
13.1	1	4,54E-02	2,99E-02	<b>1,13E-02</b>	22.1	<b>1,97E-04</b>	8,09E-03	1,94E-02	28.3	<b>8,62E-03</b>	1,13E-02	1,56E-02
	6	3,76E-02	3,24E-02	<b>1,79E-02</b>		<b>6,95E-03</b>	9,14E-03	1,00E-02		<b>1,18E-02</b>	2,91E-02	1,67E-02
	9	3,75E-02	3,51E-02	<b>1,88E-02</b>		<b>7,44E-03</b>	9,11E-03	9,30E-03		<b>1,37E-02</b>	3,21E-02	1,99E-02
	12	3,21E-02	5,18E-02	<b>1,64E-02</b>		<b>6,10E-03</b>	1,71E-02	8,70E-03		<b>1,15E-02</b>	3,25E-02	2,07E-02
13.2	1	<b>4,70E-04</b>	1,61E-02	3,26E-03	22.2	<b>6,45E-03</b>	1,44E-02	1,32E-02	28.5	<b>4,97E-03</b>	3,62E-02	1,13E-02
	6	<b>3,06E-03</b>	1,56E-02	7,99E-03		<b>8,15E-03</b>	1,58E-02	1,24E-02		<b>1,27E-02</b>	3,97E-02	1,42E-02
	9	<b>2,89E-03</b>	2,03E-02	1,23E-02		<b>5,78E-03</b>	1,58E-02	1,48E-02		<b>1,13E-02</b>	4,14E-02	1,23E-02
	12	<b>2,47E-03</b>	6,31E-02	1,26E-02		<b>4,75E-03</b>	2,01E-02	1,35E-02		1,69E-02	4,75E-02	<b>1,42E-02</b>
13.3	1	1,26E-01	<b>2,45E-02</b>	3,53E-02	23.1	2,98E-03	1,17E-02	<b>2,89E-03</b>	28.6	3,15E-02	1,97E-02	<b>3,93E-03</b>
	6	2,39E-02	2,78E-02	<b>2,30E-02</b>		3,59E-03	9,80E-03	<b>3,11E-03</b>		<b>2,21E-02</b>	2,42E-02	4,41E-02
	9	<b>1,80E-02</b>	3,36E-02	2,17E-02		<b>2,49E-03</b>	1,10E-02	4,16E-03		<b>1,96E-02</b>	2,44E-02	4,81E-02
	12	<b>1,54E-02</b>	3,89E-02	1,91E-02		<b>2,15E-03</b>	1,45E-02	5,44E-03		<b>2,28E-02</b>	2,55E-02	4,20E-02
14.1	1	4,59E-02	<b>1,55E-02</b>	4,10E-02	23.2	<b>1,33E-03</b>	8,09E-03	2,57E-02	29.2	3,51E-02	2,28E-02	<b>1,44E-02</b>
	6	3,85E-02	<b>1,79E-02</b>	3,13E-02		9,64E-03	<b>8,10E-03</b>	8,68E-03		2,15E-02	3,02E-02	<b>1,33E-02</b>
	9	2,67E-02	<b>2,48E-02</b>	3,16E-02		9,26E-03	9,07E-03	<b>7,98E-03</b>		2,75E-02	3,17E-02	<b>2,11E-02</b>
	12	<b>2,24E-02</b>	4,82E-02	2,94E-02		<b>7,22E-03</b>	2,44E-02	8,29E-03		2,16E-02	3,24E-02	<b>2,13E-02</b>
14.2	1	2,66E-01	2,59E-02	<b>1,85E-02</b>	23.3	<b>4,72E-04</b>	2,06E-03	3,23E-03	29.3	1,60E-02	<b>6,67E-03</b>	2,20E-02
	6	7,78E-02	<b>2,32E-02</b>	4,78E-02		<b>4,66E-03</b>	9,32E-03	1,20E-02		<b>6,07E-03</b>	7,61E-03	1,05E-02
	9	5,52E-02	<b>2,86E-02</b>	3,73E-02		<b>3,72E-03</b>	1,03E-02	1,16E-02		<b>5,26E-03</b>	7,00E-03	1,06E-02
	12	4,20E-02	3,69E-02	<b>3,68E-02</b>		<b>3,15E-03</b>	1,09E-02	1,04E-02		<b>6,42E-03</b>	9,65E-03	8,71E-03
15.1	1	4,81E-02	1,36E-02	<b>8,70E-03</b>	23.4	<b>4,69E-03</b>	9,60E-03	5,88E-03	29.4	<b>1,73E-03</b>	1,41E-02	6,47E-03
	6	4,08E-02	1,57E-02	<b>1,04E-02</b>		<b>3,85E-03</b>	1,18E-02	6,06E-03		<b>2,47E-03</b>	1,49E-02	1,26E-02
	9	3,05E-02	2,04E-02	<b>1,45E-02</b>		<b>4,76E-03</b>	1,22E-02	6,53E-03		<b>1,80E-03</b>	1,88E-02	1,24E-02
	12	<b>2,37E-02</b>	2,52E-02	2,90E-02		<b>4,80E-03</b>	1,41E-02	6,29E-03		<b>3,07E-03</b>	3,13E-02	1,46E-02
16.2	1	<b>1,69E-05</b>	8,45E-03	1,67E-02	23.9	<b>8,70E-05</b>	1,55E-02	2,12E-02	31.0	2,28E-02	1,31E-02	<b>4,99E-03</b>
	6	<b>5,75E-03</b>	1,46E-02	1,31E-02		<b>6,64E-04</b>	1,90E-02	1,41E-02		<b>1,26E-02</b>	1,39E-02	2,01E-02
	9	<b>8,34E-03</b>	1,47E-02	1,24E-02		<b>1,14E-03</b>	2,23E-02	1,24E-02		<b>1,05E-02</b>	1,64E-02	2,07E-02
	12	<b>8,59E-03</b>	1,43E-02	1,10E-02		<b>1,46E-03</b>	2,39E-02	1,38E-02		<b>9,53E-03</b>	1,84E-02	2,66E-02
17.1	1	1,34E-02	<b>5,67E-03</b>	1,86E-02	24.1	1,35E-02	<b>3,41E-03</b>	4,07E-02	32.1	1,57E-01	1,53E-01	<b>1,45E-01</b>
	6	<b>2,92E-03</b>	1,05E-02	7,20E-03		8,32E-03	<b>7,89E-03</b>	1,74E-02		1,79E-01	1,66E-01	<b>1,41E-01</b>
	9	<b>3,97E-03</b>	1,04E-02	8,03E-03		<b>7,16E-03</b>	1,43E-02	2,55E-02		2,13E-01	1,72E-01	<b>1,59E-01</b>
	12	<b>3,44E-03</b>	1,92E-02	8,66E-03		<b>8,62E-03</b>	1,59E-02	2,68E-02		2,26E-01	2,63E-01	<b>1,54E-01</b>
									32.9	1,97E-02	<b>1,54E-02</b>	2,79E-02
										2,40E-02	<b>2,06E-02</b>	4,09E-02
										<b>1,69E-02</b>	2,28E-02	3,38E-02
										<b>1,41E-02</b>	3,04E-02	2,93E-02

**APÊNDICE E.2 – ERRO NORMALIZADO NA PREVISÃO PARA OS HORIZONTE DE 1,6,9 E  
12 MESES (MÉTRICA MSE)**

A tabela a seguir consiste na lista dos erros de previsão (MSE) para 4 horizontes de previsão diferentes, 1, 6, 9 e 12 meses, em cada setor econômico e para cada método. O modelo usado para cada indústria, usou os parâmetros apresentados no Apêndice D e utiliza 25 amostras de teste. Os valores foram normalizados de modo que o valor do menor erro por setor e horizonte de tempo seja 0 ou (-) e para os outros dois seja uma proporção do menor erro.

Setor	h	AES	SARIMA	HW	Setor	AES	SARIMA	HW	Setor	SSA	SARIMA	HW
10.1	1	-	2,84	6,66	17.2	0,20	-	0,76	24.2	0,08	-	0,77
	6	-	4,26	7,45		-	1,09	1,86		-	1,21	0,75
	9	-	5,32	6,38		-	0,91	1,21		-	1,12	0,88
	12	-	2,14	2,44		-	1,40	1,37		-	1,39	0,84
10.3	1	-	3,83	3,81	17.3	-	1,09	3,67	24.5	-	363,44	325,37
	6	0,37	-	0,28		-	0,78	1,70		0,05	0,95	-
	9	0,66	0,02	-		-	2,10	2,65		0,29	0,70	-
	12	0,71	0,27	-		-	6,13	3,47		0,32	1,16	-
10.4	1	-	0,99	2,40	17.4	0,06	-	1,01	25.3	1,11	-	0,24
	6	-	5,78	10,61		-	1,14	1,41		0,50	0,04	-
	9	-	8,40	13,19		-	2,55	1,44		0,51	0,12	-
	12	-	4,03	4,96		-	6,27	1,72		0,39	1,43	-
10.5	1	5,81	-	13,14	19.2	-	4,37	1,33	25.4	-	0,81	0,38
	6	-	0,99	4,31		-	1,16	2,10		0,08	-	0,05
	9	-	1,53	5,47		-	2,31	2,77		-	0,14	0,05
	12	-	1,22	3,66		-	3,16	2,66		-	1,32	0,30
10.6	1	1,17	2,10	-	19.3	1,00	-	2,29	26.2	0,56	-	0,18
	6	-	2,94	1,34		-	1,71	1,38		-	0,03	0,40
	9	-	3,11	2,09		-	2,51	1,38		-	0,28	0,30
	12	-	6,97	2,42		-	1,94	0,30		-	0,71	0,25
10.7	1	-	0,62	5,42	20.1	-	1,01	3,50	26.4	0,11	-	0,67
	6	-	1,71	2,71		-	3,90	5,95		-	1,32	0,83
	9	-	1,41	1,75		-	4,09	5,43		-	0,68	0,42
	12	0,03	0,90	-		-	6,21	5,41		-	1,19	0,96
10.8	1	-	159,93	347,12	20.5	1,09	-	4,56	27.4	-	386,86	448,53
	6	-	2,20	2,90		-	0,03	2,36		-	13,68	9,02
	9	-	0,75	1,16		-	0,27	1,86		-	12,73	7,67
	12	-	0,78	1,14		-	0,71	2,16		-	3,62	0,84
11.1	1	-	2,09	1,55	20.6	-	263,78	25,54	27.5	21,83	0,47	-
	6	-	1,11	0,95		-	1,16	0,37		2,19	0,63	-

	9	-	1,60	1,10		-	1,98	0,57		1,38	0,52	-	
	12	-	2,53	1,42		-	1,58	1,96		0,12	-	0,08	
11.2	1	0,71	-	2,61	20.7	332,47	417,33	-	28.1	-	5,20	13,42	
	6	-	0,50	2,19		-	3,67	2,53		-	1,13	0,95	
	9	-	0,78	2,22		-	2,55	0,88		-	0,84	0,28	
	12	-	1,40	3,20		-	2,40	2,05		-	2,52	0,24	
13.1	1	3,00	1,64	-	22.1	-	40,18	97,86	28.3	-	0,31	0,80	
	6	1,10	0,81	-		-	0,31	0,44		-	1,46	0,41	
	9	0,99	0,87	-		-	0,23	0,25		-	1,34	0,45	
	12	0,95	2,15	-		-	1,80	0,43		-	1,83	0,80	
13.2	1	-	33,35	5,93	22.2	-	1,24	1,04	28.5	-	6,28	1,26	
	6	-	4,11	1,61		-	0,94	0,53		-	2,13	0,12	
	9	-	6,03	3,27		-	1,73	1,56		-	2,66	0,09	
	12	-	24,55	4,11		-	3,23	1,84		-	0,19	2,34	-
13.3	1	4,16	-	0,44	23.1	0,03	3,03	-	28.6	7,02	4,02	-	
	6	0,04	0,21	-		0,15	2,16	-		-	0,10	1,00	
	9	-	0,86	0,21		-	3,41	0,67		-	0,24	1,46	
	12	-	1,53	0,24		-	5,73	1,53		-	0,12	0,84	
14.1	1	1,95	-	1,64	23.2	-	5,08	18,28	29.2	1,44	0,58	-	
	6	1,15	-	0,74		0,19	-	0,07		-	0,61	1,26	-
	9	0,07	-	0,27		0,16	0,14	-		-	0,30	0,50	-
	12	-	1,15	0,31		-	2,37	0,15		-	0,01	0,52	-
14.2	1	13,36	0,40	-	23.3	-	3,37	5,85	29.3	1,39	-	2,30	
	6	2,35	-	1,06		-	1,00	1,57		-	0,25	0,73	
	9	0,93	-	0,30		-	1,77	2,11		-	0,33	1,02	
	12	0,14	0,00	-		-	2,47	2,29		-	0,50	0,36	
15.1	1	4,53	0,56	-	23.4	-	1,05	0,25	29.4	-	7,11	2,73	
	6	2,92	0,51	-		-	2,08	0,58		-	5,05	4,10	
	9	1,11	0,41	-		-	1,57	0,37		-	9,44	5,91	
	12	-	0,07	0,23		-	1,94	0,31		-	9,21	3,77	
16.2	1	-	498,17	988,15	23.9	-	177,49	243,15	31.0	3,57	1,62	-	
	6	-	1,53	1,28		-	27,59	20,29		-	0,10	0,60	
	9	-	0,76	0,49		-	18,52	9,85		-	0,56	0,98	
	12	-	0,66	0,29		-	15,39	8,48		-	0,93	1,79	
17.1	1	1,37	-	2,28	24.1	2,97	-	10,93	32.1	0,08	0,05	-	
	6	-	2,60	1,46		0,05	-	1,20		-	0,27	0,17	-
	9	-	1,63	1,02		-	1,00	2,56		-	0,34	0,08	-
	12	-	4,59	1,52		-	0,85	2,12		-	0,47	0,71	-
									32.9	0,28	-	0,82	
										0,17	-	0,99	
										-	0,35	1,00	
										-	1,15	1,07	



**APÊNDICE F.1 – ERRO ABSOLUTO NA PREVISÃO DAS AMOSTRAS DE TREINAMENTO E DE TESTE (MÉTRICA MSE COM 25 AMOSTRAS DE TESTE)**

A tabela a seguir consiste na lista dos erros de previsão (MSE) para as amostras de treinamento e para as de teste em cada setor econômico e usando cada método. Em negrito estão os menores valores encontrados de erro para cada setor.

MSE	IN-SAMPLE			OUT-OF-SAMPLE			Setor	IN-SAMPLE			OUT-OF-SAMPLE		
	SSA	SARIMA	HW	SSA	SARIMA	HW		SSA	SARIMA	HW	SSA	SARIMA	HW
10.1	<b>1,4E-03</b>	2,4E-02	1,6E-03	2,1E-03	<b>1,7E-03</b>	1,9E-03	22.1	8,7E-03	5,9E-03	<b>5,1E-03</b>	8,5E-03	<b>2,3E-03</b>	2,7E-03
10.3	4,2E-02	4,4E-02	<b>4,0E-02</b>	5,4E-02	<b>2,5E-02</b>	2,6E-02	22.2	6,1E-03	<b>2,5E-03</b>	4,4E-03	5,6E-03	<b>4,9E-03</b>	1,4E-02
10.4	<b>2,8E-04</b>	4,6E-03	4,0E-03	1,7E-03	<b>1,7E-03</b>	2,7E-03	23.1	1,0E-02	<b>5,4E-03</b>	6,0E-03	2,9E-03	<b>2,1E-03</b>	2,6E-03
10.5	<b>1,7E-04</b>	2,7E-02	1,4E-03	6,0E-03	<b>2,6E-03</b>	1,7E-02	23.2	3,0E-03	8,2E-01	<b>2,3E-03</b>	6,2E-03	<b>1,9E-03</b>	2,4E-03
10.6	<b>8,0E-04</b>	1,9E-03	9,8E-04	<b>1,1E-03</b>	1,1E-03	1,2E-03	23.3	<b>1,0E-03</b>	4,3E-03	3,0E-03	4,0E-03	<b>2,4E-03</b>	2,6E-03
10.7	<b>1,4E-02</b>	9,0E-02	5,2E-02	7,0E-02	<b>6,6E-02</b>	9,5E-02	23.4	9,9E-03	8,8E-03	<b>7,0E-03</b>	8,2E-03	6,7E-03	<b>4,6E-03</b>
10.8	<b>1,9E-03</b>	2,5E-02	3,1E-03	6,2E-03	<b>4,7E-03</b>	7,6E-03	23.9	<b>2,0E-03</b>	3,9E-03	3,3E-03	<b>3,7E-03</b>	5,2E-03	8,5E-03
11.1	7,2E-03	1,3E-02	<b>6,4E-03</b>	6,5E-03	<b>5,7E-03</b>	7,5E-03	24.1	<b>5,2E-03</b>	8,7E-01	1,7E-02	4,5E-02	<b>3,7E-02</b>	4,8E-02
11.2	<b>2,2E-03</b>	6,0E-03	4,7E-03	<b>6,0E-03</b>	6,9E-03	9,5E-03	24.2	<b>3,2E-03</b>	6,4E-03	5,4E-03	8,1E-03	9,7E-03	<b>7,4E-03</b>
13.1	1,1E-02	3,0E-02	<b>9,7E-03</b>	2,8E-02	<b>2,0E-02</b>	3,9E-02	24.5	<b>1,2E-02</b>	2,3E-02	1,9E-02	1,8E-02	2,5E-02	<b>1,4E-02</b>
13.2	9,9E-03	<b>6,4E-03</b>	1,2E-02	1,3E-02	1,1E-02	<b>8,7E-03</b>	25.3	<b>8,8E-03</b>	9,8E-03	1,5E-02	1,9E-02	<b>9,4E-03</b>	1,0E-02
13.3	1,8E-02	1,5E-02	<b>1,3E-02</b>	2,8E-02	1,4E-02	<b>8,4E-03</b>	25.4	1,5E-02	<b>5,3E-03</b>	7,8E-03	<b>9,2E-03</b>	1,2E-02	2,1E-02
14.1	1,0E-02	8,4E-03	<b>6,8E-03</b>	1,6E-02	<b>5,9E-03</b>	1,7E-02	26.2	<b>9,7E-03</b>	2,1E-02	1,9E-02	1,2E-02	1,1E-02	<b>1,1E-02</b>
14.2	3,6E-02	7,9E-01	<b>2,1E-02</b>	7,7E-02	5,7E-02	<b>4,1E-02</b>	26.4	2,2E-02	3,9E-02	<b>1,6E-02</b>	<b>1,9E-02</b>	3,2E-02	4,0E-02
15.1	<b>5,5E-03</b>	3,1E-02	6,0E-03	<b>1,9E-02</b>	3,1E-02	5,7E-02	27.4	<b>3,0E-03</b>	3,8E-02	1,3E-02	1,6E-02	<b>1,4E-02</b>	3,6E-02
16.2	<b>3,1E-03</b>	9,9E-01	4,2E-03	<b>7,0E-03</b>	1,2E-02	1,1E-02	27.5	<b>1,2E-02</b>	1,9E-02	1,4E-02	2,2E-02	<b>2,1E-02</b>	7,6E-02
17.1	<b>2,0E-03</b>	2,3E-02	2,6E-03	3,9E-03	<b>3,0E-03</b>	3,9E-03	28.1	1,9E-02	7,8E-03	<b>6,8E-03</b>	1,2E-02	3,9E-03	<b>3,5E-03</b>
17.2	1,9E-03	1,7E-03	<b>1,2E-03</b>	2,2E-03	<b>1,6E-03</b>	2,0E-03	28.3	<b>1,1E-02</b>	1,8E-02	1,9E-02	<b>1,2E-02</b>	2,3E-02	1,2E-02
17.3	1,5E-03	9,0E-01	<b>1,3E-03</b>	2,4E-03	<b>1,6E-03</b>	3,8E-03	28.5	<b>7,1E-03</b>	3,5E-02	1,7E-02	3,3E-02	5,3E-02	<b>1,2E-02</b>
17.4	<b>9,5E-05</b>	8,1E-01	2,5E-03	2,6E-03	<b>1,7E-03</b>	1,8E-03	28.6	<b>1,1E-02</b>	2,3E-01	1,1E-02	<b>3,0E-02</b>	3,0E-02	5,7E-02
19.2	1,8E-03	2,2E-03	<b>1,6E-03</b>	<b>2,6E-03</b>	2,9E-03	3,4E-03	29.2	<b>4,5E-02</b>	9,9E-02	6,5E-02	3,1E-02	4,7E-02	<b>2,7E-02</b>
19.3	<b>1,0E-02</b>	8,3E-02	6,0E-02	4,2E-02	<b>2,8E-02</b>	5,6E-02	29.3	<b>6,8E-03</b>	2,3E-02	2,1E-02	9,0E-03	7,1E-03	<b>5,9E-03</b>
20.1	<b>6,9E-04</b>	3,1E-03	2,5E-03	<b>3,6E-03</b>	4,2E-03	5,9E-03	29.4	3,2E-02	<b>2,0E-02</b>	2,2E-02	1,5E-02	<b>1,1E-02</b>	1,4E-02
20.5	<b>5,7E-03</b>	4,8E-02	4,2E-02	<b>6,0E-02</b>	1,2E-01	1,0E-01	31.0	1,6E-02	8,3E-03	<b>7,8E-03</b>	<b>1,4E-02</b>	2,1E-02	5,5E-02
20.6	<b>3,7E-04</b>	2,4E-02	1,8E-03	3,1E-03	<b>1,1E-03</b>	8,0E-03	32.1	<b>1,8E-01</b>	2,4E-01	1,8E-01	2,5E-01	2,3E-01	<b>2,1E-01</b>
20.7	1,4E-02	1,0E-02	<b>5,2E-03</b>	<b>7,0E-03</b>	8,5E-03	2,1E-02	32.9	<b>2,5E-03</b>	9,4E-03	7,0E-03	<b>1,3E-02</b>	1,4E-02	1,5E-02

**\*\*Em Negrito estão os menores valores de erro encontrado para cada setor**

**APÊNDICE F.2 – ERRO NORMALIZADO NA PREVISÃO DAS AMOSTRAS DE  
TREINAMENTO E DE TESTE (MÉTRICA MSE COM 25 AMOSTRAS DE TESTE)**

A tabela a seguir consiste na lista dos erros de previsão (MSE) para as amostras de treinamento e para as de teste em cada setor econômico e usando cada método. Os valores foram normalizados de modo que o valor do menor erro por setor seja 0 ou (-) e para os outros dois seja uma proporção do menor erro

MSE	IN-SAMPLE			OUT-OF-SAMPLE			Setor	IN-SAMPLE			OUT-OF-SAMPLE		
	SSA	SARIMA	HW	SSA	SARIMA	HW		SSA	SARIMA	HW	SSA	SARIMA	HW
10.1	-	15,91	0,15	0,27	-	0,16	22.1	0,73	0,16	-	2,67	-	0,18
10.3	0,05	0,11	-	1,16	-	0,04	22.2	1,46	-	0,79	0,15	-	1,78
10.4	-	15,38	13,30	0,02	-	0,59	23.1	0,94	-	0,12	0,35	-	0,21
10.5	-	152,30	7,25	1,34	-	5,76	23.2	0,34	360,54	-	2,24	-	0,22
10.6	-	1,33	0,23	-	0,02	0,08	23.3	-	3,24	1,93	0,71	-	0,09
10.7	-	5,26	2,63	0,06	-	0,45	23.4	0,41	0,25	-	0,78	0,47	-
10.8	-	12,53	0,67	0,31	-	0,62	23.9	-	1,02	0,67	-	0,41	1,31
11.1	0,13	1,11	-	0,13	-	0,30	24.1	-	165,66	2,29	0,20	-	0,28
11.2	-	1,77	1,17	-	0,15	0,58	24.2	-	1,01	0,69	0,08	0,30	-
13.1	0,11	2,13	-	0,45	-	0,99	24.5	-	0,94	0,59	0,36	0,82	-
13.2	0,55	-	0,92	0,51	0,24	-	25.3	-	0,11	0,67	0,98	-	0,09
13.3	0,36	0,14	-	2,34	0,65	-	25.4	1,82	-	0,49	-	0,31	1,31
14.1	0,50	0,23	-	1,65	-	1,93	26.2	-	1,20	0,95	0,16	0,05	-
14.2	0,70	36,02	-	0,89	0,40	-	26.4	0,38	1,39	-	-	0,74	1,13
15.1	-	4,66	0,08	-	0,68	2,05	27.4	-	11,88	3,36	0,19	-	1,63
16.2	-	316,07	0,33	-	0,77	0,54	27.5	-	0,59	0,22	0,04	-	2,69
17.1	-	10,82	0,35	0,31	-	0,28	28.1	1,86	0,15	-	2,44	0,10	-
17.2	0,52	0,35	-	0,39	-	0,27	28.3	-	0,56	0,66	-	0,90	0,04
17.3	0,20	708,04	-	0,45	-	1,30	28.5	-	3,96	1,38	1,76	3,40	-
17.4	-	8.540,00	25,35	0,56	-	0,10	28.6	-	20,27	0,01	-	0,003	0,91
19.2	0,13	0,41	-	-	0,10	0,32	29.2	-	1,21	0,45	0,13	0,72	-
19.3	-	7,21	4,92	0,52	-	1,01	29.3	-	2,41	2,08	0,52	0,19	-
20.1	-	3,49	2,59	-	0,19	0,65	29.4	0,64	-	0,13	0,34	-	0,24
20.5	-	7,39	6,44	-	0,91	0,72	31.0	1,01	0,05	-	-	0,44	2,77
20.6	-	64,16	3,95	1,91	-	6,47	32.1	-	0,34	0,01	0,21	0,07	-
20.7	1,66	0,94	-	-	0,21	1,95	32.9	-	2,74	1,81	-	0,05	0,14