

**UNIVERSIDADE ESTADUAL PAULISTA**  
**"JULIO DE MESQUITA FILHO"**  
**FACULDADE DE CIÊNCIAS FARMACÊUTICAS**  
**CÂMPUS DE ARARAQUARA**  
**PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE BIOMATERIAIS E BIOPROCESSOS**  
**MESTRADO PROFISSIONAL**

**DADOS HISTÓRICOS PARA PREVISÃO DE SUPRIMENTO DE SUCO DE**  
**LARANJA PARA EXPORTAÇÃO: UMA ANÁLISE ESTATÍSTICA**

**PAULO CESAR TREVISOLLI**

**ORIENTADOR: Prof. Dr. JORGE MANUEL VIEIRA CAPELA**

**ARARAQUARA - SP**

**2021**

UNIVERSIDADE ESTADUAL PAULISTA  
"JULIO DE MESQUITA FILHO"  
FACULDADE DE CIÊNCIAS FARMACÊUTICAS  
CÂMPUS DE ARARAQUARA

DADOS HISTÓRICOS PARA PREVISÃO DE SUPRIMENTO DE SUCO DE  
LARANJA PARA EXPORTAÇÃO: UMA ANÁLISE ESTATÍSTICA

PAULO CESAR TREVISOLLI

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia de Biomateriais e Bioprocessos (Mestrado Profissional), Área de Biomateriais, Bioprocessos, Bioprodutos da Faculdade de Ciências Farmacêuticas, UNESP, como parte dos requisitos para obtenção do Título de Mestre em Engenharia de Biomateriais e Bioprocessos.

ORIENTADOR: Prof. Dr. JORGE MANUEL VIEIRA CAPELA

ARARAQUARA - SP

2021

---

**T814d** Trevisolli, Paulo Cesar.  
Dados históricos para previsão de suprimento de suco de laranja  
para exportação: uma análise estatística / Paulo Cesar Trevisolli. –  
Araraquara: [S.n.], 2021.  
72 f. : il.

Dissertação (Mestrado Profissional) – Universidade Estadual  
Paulista. "Júlio de Mesquita Filho". Faculdade de Ciências Farmacêuticas.  
Programa de Pós Graduação em Engenharia de Biomateriais e  
Bioprocessos. Área de Biomateriais, Bioprocessos, Bioprodutos.

Orientador: Jorge Manuel Vieira Capela.

1. Suco de laranja. 2. Previsão. 3. Exportação. 4. Séries temporais.  
5. Dados históricos. 6. Linguagem R. Porto de Santos. I. Capela, Jorge  
Manuel Vieira, orient. II. Título.

**CERTIFICADO DE APROVAÇÃO**

**TÍTULO DA DISSERTAÇÃO:** DADOS HISTÓRICOS PARA PREVISÃO DE SUPRIMENTO DE SUCO DE LARANJA PARA EXPORTAÇÃO: UMA ANÁLISE ESTATÍSTICA

**AUTOR:** PAULO CESAR TREVISOLLI

**ORIENTADOR:** JORGE MANUEL VIEIRA CAPELA

Aprovado como parte das exigências para obtenção do Título de Mestre em ENGENHARIA DE BIOMATERIAIS E BIOPROCESSOS, área: Biomateriais, Bioprocessos, Bioprodutos pela Comissão Examinadora:

Prof. Dr. JORGE MANUEL VIEIRA CAPELA (Participação Virtual)  
Departamento de Engenharia, Física e Matemática / Instituto de Química - UNESP - Araraquara

Prof. Dr. IRIS BENTO DA SILVA (Participação Virtual)  
Departamento de Engenharia Mecânica / Escola de Engenharia de São Carlos - USP

Prof. Dr. RONDINELLI DONIZETTI HERCULANO (Participação Virtual)  
Departamento de Engenharia de Bioprocessos e Biotecnologia / Faculdade de Ciências Farmacêuticas - UNESP - Araraquara

Araraquara, 26 de fevereiro de 2021

Dedico este trabalho a todos aqueles que me acompanharam nesta caminhada, ora apenas observando meus passos, ora me ajudando a caminhar. Aos meus pais João Trevisolli e Maria Luiza Trevisolli (*in memoriam*), minha esposa Thais e meus filhos, Enzo e Alice, que me fortaleceram nos momentos mais importantes, e me fizeram ter paciência e entender que tudo acontece no tempo certo.

*“A tarefa não é tanto ver aquilo que ninguém viu, mas pensar o que ninguém ainda pensou sobre aquilo que todo mundo vê”.*

*Arthur Schopenhauer*

## **AGRADECIMENTOS**

Primeiro, gostaria de agradecer a Deus, a quem tudo devemos, pois sem essa força divina, nada seria possível, principalmente quando olho à minha volta, e sinto o privilégio de ter uma família saudável, bons amigos e a grande oportunidade de estudar.

À minha mãe, Maria Luiza (in memorian), que não mediu esforços na educação de cada um dos 09 filhos, e nos conduziu no caminho do bem, sempre nos amparou com um sorriso no rosto e apoio incondicional; e, ao meu pai, João Trevisolli, hoje com 92 anos, que já cruzou tantos acontecimentos da história, e que, com a sua luta, humildade e trabalho, é um dos grandes responsáveis por presenciar e tornar essa jornada possível: é pra vocês!

À minha esposa Thaís, meus filhos Enzo e Alice, por tamanha compreensão nas ausências e apoio em tantos momentos difíceis desta caminhada. Obrigado pelo amor e apoio incondicional.

A um grande amigo que tenho, desde que me conheço por gente, Flávio Appolinário, que me apresentou essa instituição e que segue minha caminhada, desde a época da pré-escola. Gratidão.

Ao Prof. Dr. Rondinelli Donizetti Herculano, por me acolher na instituição, acreditar na idéia, e nortear meu trajeto, através de todo o conhecimento cedido, da disponibilidade e presteza, desde a escrita do projeto, até a realização deste trabalho, o meu muito obrigado.

Ao meu orientador, Prof. Dr. Jorge Manuel Vieira Capela, por toda a orientação prestada, pelo incentivo, disponibilidade e apoio que sempre demonstrou. Aqui lhe exprimo a minha gratidão.

À professora Dra. Marisa Veiga Capela, pelos ensinamentos em Estatística, pela didática, paciência, compreensão, e todo o suporte e orientação durante a jornada.

A elaboração deste trabalho não teria sido possível sem a colaboração, estímulo e empenho de vocês. Obrigado por permitirem que esta dissertação seja uma realidade.



## RESUMO

A previsão de demanda, pelo seu potencial de auxílio nas tomadas de decisões do setor industrial, tanto em nível operacional como em nível estratégico, vem se tornando elemento fundamental para o progresso da organização. O mercado externo é o destino da grande maioria do suco de laranja e de seus subprodutos (óleos essenciais e farelos), produzidos pelas indústrias brasileiras. A concorrência interna, os elevados custos com o controle da matéria prima, processo produtivo, carga tributária, industrialização e logística, fazem com que seja necessário o aprimoramento de técnicas para redução dos custos, dentre elas, a previsão de demanda. No presente estudo é realizada a previsão da quantidade necessária de suco de laranja em estoque para exportação, investigando a eficácia da capacidade preditiva, para os próximos meses, aumentando o tempo hábil para tomada de decisão, utilizando-se da técnica estatística de Séries Temporais (ST), baseando-se em dados históricos da exportação de sucos cítricos, no período de 2002 a 2019. Foi realizada pesquisa na literatura que também abrange a previsão de demanda de produto e, a partir dos dados obtidos nos resultados comparados, é proposto que o modelo estatístico utilizado seja o Holt-Winters aditivo, utilizado no presente trabalho, se ajustando melhor aos dados e obtendo uma acurácia menor, o que evidencia que os dados previstos neste estudo estão mais próximos dos dados realizados.

**Palavras-chave:** Suco de laranja. Previsão. Exportação. Séries temporais. Dados históricos. Linguagem R. Porto de Santos.

## **ABSTRACT**

Demand forecasting, due to its potential to aid decision making in the industrial sector, both at the operational and strategic levels, has become a fundamental element for the organization's progress. The foreign market is the destination of the vast majority of orange juice and its by-products (essential oils and bran), produced by Brazilian industries. Internal competition, high costs with the control of raw materials, the production process, tax burden, industrialization and logistics, make it necessary to improve techniques to reduce costs, including demand forecasting. In the present study, the forecast quantity of orange juice in stock for export is carried out, investigating the effectiveness of the predictive capacity for the coming months, increasing the time needed for decision making, using the Time Series statistical technique ( ST), based on historical data on the export of citrus juices, in the period from 2002 to 2019. Research was carried out in the literature that also covers the forecast of product demand and, based on the data obtained in the compared results, it is proposed that the statistical model used is the additive Holt-Winters, used in the present work, adjusting better to the data and obtaining a lower accuracy, which shows that the data foreseen in this study are closer to the data performed.

**Keywords:** Orange juice. Forecast. Export. Time series. Historical data. R language. Port of Santos

## SUMÁRIO

|          |                                               |    |
|----------|-----------------------------------------------|----|
| 1.       | INTRODUÇÃO .....                              | 19 |
| 2.       | OBJETIVOS .....                               | 21 |
| 2.1.     | Objetivo Geral .....                          | 21 |
| 2.2.     | Objetivos Específicos.....                    | 21 |
| 3.       | POTENCIAL DE INOVAÇÃO .....                   | 22 |
| 3.1.     | Escopo .....                                  | 22 |
| 3.2.     | Justificativa .....                           | 22 |
| 4.       | REVISÃO BIBLIOGRÁFICA.....                    | 24 |
| 4.1.     | O Porto de Santos.....                        | 24 |
| 4.2.     | Dados Históricos.....                         | 24 |
| 4.3.     | Cutrale .....                                 | 25 |
| 4.4.     | Subprodutos da Laranja .....                  | 26 |
| 4.4.1.   | Farelo de polpa cítrica .....                 | 27 |
| 4.4.2.   | Óleos essenciais.....                         | 28 |
| 4.5.     | Fatores Intangíveis .....                     | 29 |
| 4.6.     | A Linguagem R.....                            | 29 |
| 4.7.     | Séries Temporais .....                        | 30 |
| 5.       | MATERIAIS E MÉTODOS .....                     | 32 |
| 5.1.     | Fonte de dados.....                           | 32 |
| 5.2.     | Seleção do pacote computacional .....         | 32 |
| 5.3.     | Representação gráfica da série temporal ..... | 33 |
| 5.4.     | Decomposição da série temporal.....           | 34 |
| 5.5.     | Suavização exponencial simples .....          | 36 |
| 5.6.     | Suavização exponencial de Holt-Winters .....  | 38 |
| 5.7.     | Box-Jenkins ou modelos ARIMA.....             | 40 |
| 5.7.1.   | Identificação .....                           | 42 |
| 5.7.2.   | Estimativa dos parâmetros.....                | 43 |
| 5.7.3.   | Diagnóstico ou verificação .....              | 44 |
| 5.7.3.1. | Teste de autocorrelação residual .....        | 44 |
| 5.7.3.2. | Teste de Box-Pierce e Ljung e Box.....        | 44 |
| 5.7.4.   | Análise da série .....                        | 45 |
| 5.7.4.1. | Gráfico da série .....                        | 45 |

|            |                                                                          |    |
|------------|--------------------------------------------------------------------------|----|
| 5.7.4.2.   | Teste de estacionariedade .....                                          | 46 |
| 5.7.4.2.1. | Teste KPSS .....                                                         | 46 |
| 5.7.4.3.   | Identificação do modelo ARIMA com o software R .....                     | 49 |
| 6.         | RESULTADOS E DISCUSSÃO .....                                             | 50 |
| 6.1.       | Resultados do ajustamento dos modelos e previsão da série temporal ..... | 52 |
| 6.2.       | Critérios para avaliação de desempenho dos modelos .....                 | 55 |
| 6.3.       | Comparação entre os métodos .....                                        | 58 |
| 6.3.1.     | Método Holt-Winters x ARIMA .....                                        | 60 |
| 6.4.       | Comparação com a literatura.....                                         | 62 |
| 7.         | CONCLUSÃO .....                                                          | 64 |
|            | REFERÊNCIAS.....                                                         | 66 |
|            | ANEXOS .....                                                             | 71 |

## LISTA DE FIGURAS

|                                                                                              |    |
|----------------------------------------------------------------------------------------------|----|
| Figura 1 - Total de publicações "forecast" + "orange" desde 1981 .....                       | 23 |
| Figura 2 - Total de publicações "forecast" + "orange juice" desde 1994.....                  | 23 |
| Figura 3 - Rendimentos da Laranja .....                                                      | 26 |
| Figura 4 - Destinos do produto ( óleos essenciais, matérias de perfume e sabor ) .....       | 28 |
| Figura 5 - Série simulada de suavização exponencial simples - SES .....                      | 37 |
| Figura 6 - Estratégia para avaliação dos métodos de previsão .....                           | 39 |
| Figura 7 - Identificação da estacionariedade da série “exportações” .....                    | 47 |
| Figura 8 - Comparação série temporal original e com diferenciação de 1a ordem .....          | 48 |
| Figura 9 - Identificação da estacionariedade da série “exportações” após diferenciação ..... | 49 |
| Figura 10 - Série temporal das exportações de suco de laranja de 2002 a 2019.....            | 50 |
| Figura 11 - Decomposição da série exportações, admitindo-se um modelo aditivo .....          | 51 |
| Figura 12 - Decomposição da série temporal exportações utilizando filtro HP .....            | 52 |
| Figura 13 - Exportações - Dados de treino (2002 a 2017) e validação (2018 a 2019) .....      | 54 |
| Figura 14 – Validação comum: fluxo de dados de treinamento, validação e previsão .....       | 54 |
| Figura 15 - Modelo de previsão HWM2 - Validação x Previsão .....                             | 57 |
| Figura 16 - Modelo de previsão ARW2 - Validação x Previsão .....                             | 57 |
| Figura 17 - Modelo de previsão HWA2 - Validação x Previsão .....                             | 58 |
| Figura 18 – Resíduos do modelo ARIMA (arw2).....                                             | 61 |
| Figura 19 – Exportações 2002 a 2019 - Tendência.....                                         | 61 |

## LISTA DE TABELAS

|                                                                                                                                                                     |    |
|---------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| Tabela 1 - Exportações dos Subprodutos Cítricos.....                                                                                                                | 27 |
| Tabela 2 - Subdivisão dos dados da série temporal para aplicação dos modelos .....                                                                                  | 53 |
| Tabela 3 - Medidas de acurácia para a previsão de demanda dos modelos .....                                                                                         | 56 |
| Tabela 4 - Comparação dos valores de erros e coeficientes calculados para todos os<br>modelos de suavização exponencial possíveis de serem aplicados aos dados..... | 62 |

## LISTA DE QUADROS

|                                                                               |    |
|-------------------------------------------------------------------------------|----|
| Quadro 1 - Mensário Estatístico - Janeiro de 2020.....                        | 25 |
| Quadro 2 – Valores de exportações mensais do ano de 2019 – por método .....   | 58 |
| Quadro 3 – Acurácia dos modelos em Toneladas.....                             | 59 |
| Quadro 4 – Comparação Holt-Winters x ARIMA.....                               | 60 |
| Quadro 5 – Diferença da acurácia entre o presente estudo e a literatura ..... | 63 |

## LISTA DE ANEXOS

|                                                                                         |    |
|-----------------------------------------------------------------------------------------|----|
| Anexo 1 - Série histórica de dados de Exportações - Jan/2002 a Dez/2019.....            | 71 |
| Anexo 2 - Criação da série temporal – Exportações de suco de laranja de 2002 2019 ..... | 71 |
| Anexo 3 - Comandos de decomposição da série.....                                        | 71 |
| Anexo 4 - Comandos de decomposição da série com o Filtro HP .....                       | 72 |
| Anexo 5 - Comandos para criação da série simulada SES.....                              | 72 |
| Anexo 6 - Comandos para validação da estacionariedade da série - Teste KPSS.....        | 72 |
| Anexo 7 - Comandos para validação da quantidade de diferenciações necessárias .....     | 72 |
| Anexo 8 - Comando para diferenciação de primeira ordem da série temporal .....          | 72 |



## LISTA DE ABREVIATURAS E SIGLAS

ACF – Do inglês *Auto Correlation Function*: função de autocorrelação

ARIMA – Do Inglês *Auto-Regressive Integrated Moving Average*: Modelo autoregressivo integrado de médias móveis

AST – Análise de Séries Temporais

AUTO.ARIMA – Método de ajuste automático dos parâmetros do modelo ARIMA

COMEXVIS – Sistema oficial de consulta aos dados do comércio exterior brasileiro

COMMODITY – Produto que funciona como matéria prima, geralmente estocada sem perder a qualidade e produzido em larga escala.

DECOMPOSE – Decompor, dividir em partes.

FCOJ – Do inglês *Frozen Concentrated Orange Juice*: suco de laranja concentrado e congelado

FORECAST - Previsão

GETAE – Gerência de Tarifas e Estatísticas

ISI WEB OF SCIENCE - Portal de Periódicos

MACHINE LEARNING: Aprendizado de Máquina

MAE: Do inglês *Mean Absolute Error*: Erro Absoluto Médio

MAPE: Do inglês *Mean Absolute Percentage Error*: Erro Percentual Médio Absoluto

MDIC – Ministério do Desenvolvimento, Indústria e Comércio Exterior

ME: Do inglês *Mean Error*: Erro Médio

MPE: Do inglês *Mean Percentage Error*: Erro Percentual Médio

NFC – Do inglês *Not From Concentrate*: suco de laranja não concentrado

OBSERVED – Observado

ORANGE – Laranja

ORANGE JUICE – Suco de laranja

PACF – Do Inglês *Partial Auto Correlation Function*: função de autocorrelação parcial

PDF – Do Inglês *Portable Document Format*: Formato de documento portátil

PS – Porto de Santos

RANDOM – Aleatório, randômico

RESIDUALS – Resíduos

RMSE: Do inglês *Root Mean Square Error*: Erro Quadrático Médio

SE – Suavização Exponencial

SEASONAL – Sazonal, próprio de uma estação

SEHWA – Suavização Exponencial de Holt-Winters Aditivo

SEHWM – Suavização Exponencial de Holt-Winters Multiplicativo

SES – Suavização Exponencial Simples

ST - Séries Temporais (ou, em inglês, TS – Time Series)

TREND – Tendência

## LISTA DE EQUAÇÕES

|                                                                          |    |
|--------------------------------------------------------------------------|----|
| Equação 1 - Modelo aditivo .....                                         | 34 |
| Equação 2 - Modelo multiplicativo .....                                  | 35 |
| Equação 3 - Filtro de Hodrick-Prescott (HP) .....                        | 35 |
| Equação 4 - Equação de erros quadráticos .....                           | 35 |
| Equação 5 - Previsão da série h passos adiante .....                     | 37 |
| Equação 6 - Relação recursiva da Equação .....                           | 37 |
| Equação 7 - Modelo de previsão Holt-Winters h passos a frente.....       | 38 |
| Equação 8 - Modelo de previsão Holt-Winters h passos a frente - Lt.....  | 39 |
| Equação 9 - Modelo de previsão Holt-Winters h passos a frente - Tt ..... | 39 |
| Equação 10 - Modelo de previsão Holt-Winters h passos a frente - St..... | 39 |

## **LISTA DE GRÁFICOS**

|                                                                                        |    |
|----------------------------------------------------------------------------------------|----|
| Gráfico 1 - Tendência - Exportação de suco de laranja - 2002 a 2019 .....              | 34 |
| Gráfico 2 - Exportação de suco de laranja - 2002 a 2019 .....                          | 45 |
| Gráfico 3 – Comparativo das médias dos modelos para as exportações do ano de 2019 .... | 59 |

## 1. INTRODUÇÃO

Considerado o maior produtor mundial de suco de laranja, o Brasil extrapola suas fronteiras e se torna destaque no comércio internacional, trazendo números impressionantes para a citricultura, um dos setores mais competitivos e de maior potencial do agronegócio. De cada cinco copos de suco de laranja consumidos no mundo, três são de sucos produzidos em território brasileiro, fazendo com que, nenhuma outra *commodity* no país tenha tamanha expressividade. O cultivo da fruta está presente em todos os estados brasileiros e o país detém, na atualidade, mais de 50% da produção mundial de suco de laranja e, exporta 98% de sua capacidade produção, onde, juntamente com o estado da Flórida, nos Estados Unidos, dominam a oferta mundial de suco de laranja, cobrindo 86% do total.

As indústrias brasileiras se aperfeiçoaram na produção e distribuição internacional do suco de laranja (NEVES et al, 2010) e com a integração das relações em escalas mundiais, em um mundo cada vez mais competitivo e globalizado, se torna fundamental para a sobrevivência das corporações a redução de custos e para tal, uma boa estratégia de dimensionamento de demanda é a obtenção da informação no tempo correto, para se tomar decisões mais assertivas e melhor planejamento de futuras ações perante o mercado mundial. Seja uma empresa prestadora de serviços, manufatureira, ou mista, uma das questões mais importantes e de maior relevância para todo o seu sistema, é o quanto a organização irá vender de seus produtos e/ou serviços. Nesse cenário, a previsão de demanda vem se tornando ponto fundamental para o desenvolvimento das organizações, pois ela têm potencial para auxiliar nas principais tomadas de decisões, tanto em nível operacional quanto estratégico, por apresentar uma visão mais clara do futuro (ARMSTRONG, 2001).

São inúmeras as aplicações de métodos de previsão (forecasting) dentro de uma empresa, portanto, se conseguirmos prever como será o comportamento futuro, podemos alterar o nosso processo agora, para estar em uma posição melhor que aquela, que por outro lado seria, quando então, o futuro chegar. A operacionalização satisfatória de estratégias de planejamento e controle da produção, em particular, está fortemente associada à existência de um sistema eficiente de forecasting (HILL, 1994; TOMPKINS et al., 1996). Os métodos previsão quantitativos são baseados em

dados históricos, sendo possível estabelecer previsões quantitativas através de análise de séries temporais (ARCHER, 1980, apud GRIPPA et al. 2005).

De acordo com Zhang (2003), a previsão de séries temporais é uma área essencial e de grande relevância, na qual a previsão de observações passadas, de uma mesma variável, são recuperadas e analisadas para desenvolver um modelo que descreve relações que não se situam claras e definidas. Grande esforço está sendo empenhado ao desenvolvimento e melhoria dos modelos de previsão de séries temporais.

O objetivo deste projeto é apresentar uma análise estatística exploratória e desenvolver a otimização do processo atual de recuperação das informações, utilizando como base os dados históricos do mensário estatístico do Porto de Santos, de janeiro de 2002 a dezembro de 2019, através do uso de séries temporais e modelos estatísticos de previsão, que são um importante instrumento no entendimento do mercado e na formulação de planos de ação e estratégias.

A intenção do trabalho é a de realizar a previsão de demanda para os próximos meses, obtendo-se a quantidade de suco necessária a ser exportada, buscando adquirir vantagem competitiva, antecipando-se ao mercado mundial e aos concorrentes, e desta forma, otimizar processos, como o planejamento da produção e rendimentos operacionais, realizando um melhor dimensionamento da quantidade de recursos, prevendo a redução de custos, melhorando a eficiência operacional, na concepção do produto, bem como a otimização do fluxo logístico rodoviário, do complexo sistema integrado de transporte, que inclui terminais portuários, caminhões tanque e navios especializados, tendo como destino o Porto de Santos, realizando as entregas de forma agendada, prevendo a redução de custos com multas e riscos com estoques elevados, mantendo somente o estoque necessário para atendimento nos silos e, o impulsionamento da força de vendas, sugerindo ao cliente os produtos necessários, estreitando-se assim a relação comercial.

## **2. OBJETIVOS**

### **2.1. Objetivo Geral**

O objetivo geral desta pesquisa é o de prever a demanda do suco de laranja para os próximos meses, através da implementação de modelos estatísticos, baseando-se em dados históricos.

### **2.2. Objetivos Específicos**

Realizar a previsão de exportação de sucos cítricos para os próximos meses, realizando uma análise estatística exploratória, por intermédio de séries temporais, viabilizando um instrumento de gestão estratégica de fundamental apoio na redução de custos de produção, melhoria da performance logística e otimização do processo atual de recuperação das informações, utilizando como base os dados históricos do mensário estatístico do Porto de Santos, que concentram as informações das exportações brasileiras de sucos cítricos.

### 3. POTENCIAL DE INOVAÇÃO

#### 3.1. Escopo

Quanto ao escopo, esta pesquisa se concentra em empresas produtoras de sucos cítricos com ênfase na previsão da exportação do produto, mais especificamente nos dados públicos, disponibilizados pelo Mensário Estatístico do Porto de Santos (PORTO DE SANTOS, 2020), da empresa Cutrale.

#### 3.2. Justificativa


Todo e qualquer segmento de negócio, seja ele prestador de serviços ou produtor de bens de consumo, do setor público ou privado, necessita de planejamento e de projeção para atendimento das necessidades de seus clientes de uma forma confiável, precisa, rápida, em qualquer localização geográfica e com os custos de operação em nível adequado de competição com seus concorrentes. Hoje a empresa possui os dados operacionais atuais, com potencial de atendimento da demanda do seu estoque físico no próprio mês, não conseguindo atuar de forma estimada para os meses futuros. A previsão da produção visa dimensionar o quanto a empresa conseguirá transformar de matéria prima em produto acabado, em determinado período de tempo, antecipando e antevendo seus problemas relacionados à sua capacidade de produção.

Foi realizado um levantamento junto à principal coleção da plataforma *ISI Web of Science*, com as palavras chave de pesquisa sendo “*forecast*” e “*orange*”, com intuito de observar interesse da comunidade acadêmica sobre os trabalhos que tratam deste tema.

Mesmo notando o crescente interesse pelo tema, o que pode ser observado pela Figura 1, especialmente a partir do ano de 2015, também se torna relevante o número total de publicações sobre previsão e o setor citrícola, levando-se em consideração os termos “*forecast*” + “*orange*”, que totalizam 209, em aproximadamente 40 anos ( 1981 a 2020 ). Sendo assim, este trabalho também se justifica pelo fato da questão da previsão da demanda no setor citrícola estar sendo pouco explorado no meio acadêmico, setor este, de grande importância para o desenvolvimento não só brasileiro, mas também mundial, produzindo 50% do suco que se consome através do globo.




**Figura 1 - Total de publicações "forecast" + "orange" desde 1981**



Realizando um refinamento da pesquisa, na plataforma ISI Web of Science, utilizando dos termos “forecast” + “orange juice”, nota-se que a disponibilidade de material sobre o tema deste projeto cai drasticamente, levando-se em consideração a quantidade, que totaliza 07 ocorrências, do período de 1994 até 2020, como demonstram, os resultados, exibidos na Figura 2.

**Figura 2 - Total de publicações "forecast" + "orange juice" desde 1994**



## **4. REVISÃO BIBLIOGRÁFICA**

### **4.1. O Porto de Santos**

Principal porto brasileiro e, o maior da América Latina, com área útil de 7,8 milhões de metros quadrados, o Porto de Santos possui 55 terminais marítimos e retro portuários, com localização em duas margens, sendo uma no município do Guarujá/SP (direita) e a outra em Santos/SP (esquerda), com um canal de navegação com profundidade de 15 metros e largura de 22 metros (seu trecho mais estreito), trata-se do maior complexo portuário da América Latina.

Com capacidade de armazenamento de aproximadamente 700 mil m<sup>3</sup> para grãos líquidos, o Porto de Santos, conta com uma extensão de cais de quase 16 quilômetros e, contempla 11 berços de atracação de uso privado, dos quais 02 são destinados para sucos cítricos, que abrange os seguintes operadores, além da Sucocítrico Cutrale: Dow Química, DP World (Embraport), Tiplan, Usiminas e Saipem e responde por aproximadamente um terço das trocas comerciais brasileiras e, é o maior exportador de suco de laranja, açúcar e café em grãos do mundo. (PORTO DE SANTOS, 2020).

### **4.2. Dados Históricos**

Os dados responsáveis pelo embasamento do presente estudo, que norteiam todo o trabalho, foram recuperados do Mensário Estatístico do Porto de Santos, desenvolvido pela GETAE, através do tópico de “Estatísticas”, da área de relações com o mercado de seu site, portanto, dados disponibilizados publicamente, em periodicidade mensal, em arquivos de formato pdf.

O arquivo pdf disponibilizado, que contém, em média, mais de 20 páginas, documentando toda a movimentação realizada no Porto de Santos (PS) naquele mês, possui vários índices para diversas formas de análise como: movimento no PS (gráfico), evolução mensal, utilização do cais, comparativos dos totais movimentados etc., e, para a elaboração deste trabalho, os arquivos no formato pdf, sendo um arquivo por mês, irão nos orientar pelos dados evidenciados no tópico: “MOVIMENTO NOS TERMINAIS DE USO PRIVATIVOS DO PORTO DE SANTOS - NO MÊS”, coluna de exportação, no porto organizado, para o operador portuário Cutrale, que contém o registro das quantidades exportadas para a linha de sucos cítricos (Quadro 1).

**Quadro 1 - Mensário Estatístico - Janeiro de 2020**

| ESPECIFICAÇÃO           |                   | EXPORTAÇÃO          |     |                          |         |           |         |
|-------------------------|-------------------|---------------------|-----|--------------------------|---------|-----------|---------|
|                         |                   | No Porto Organizado |     | Fora do Porto Organizado |         |           | TOTAL   |
|                         |                   | CUTRALE             | DOW | USIMINAS                 | TIPLAM¹ | DP WORLD² |         |
| L O N G O   C U R S O   |                   |                     |     |                          |         |           |         |
| Carga                   | Containerizada    | -                   | -   | -                        | -       | 306.028   | 306.028 |
| Geral                   | Solta             | -                   | -   | 22.360                   | -       | 50.538    | 72.898  |
|                         | Soma              | -                   | -   | 22.360                   | -       | 356.566   | 378.926 |
| Sólidos                 | Açúcar            | -                   | -   | -                        | 237.675 | -         | 237.675 |
|                         | Adubo             | -                   | -   | -                        | -       | -         | -       |
|                         | Carvão            | -                   | -   | 22.301                   | -       | -         | 22.301  |
|                         | Enxofre           | -                   | -   | -                        | -       | -         | -       |
| a                       | Farelo de Soja    | -                   | -   | -                        | 12.175  | -         | 12.175  |
|                         | Fosfato de Cálcio | -                   | -   | -                        | -       | -         | -       |
| Granel                  | Milho             | -                   | -   | -                        | 50.412  | -         | 50.412  |
|                         | Minério de Ferro  | -                   | -   | -                        | -       | -         | -       |
|                         | Soja em Grãos     | 71.365              | -   | -                        | -       | -         | 71.365  |
|                         | Outros            | -                   | -   | -                        | -       | -         | -       |
|                         | Soma              | 71.365              | -   | 22.301                   | 300.262 | -         | 393.928 |
| Líquidos<br>a<br>Granel | Ácido Fosfórico   | -                   | -   | -                        | -       | -         | -       |
|                         | Alcool            | -                   | -   | -                        | -       | -         | -       |
|                         | Amônia            | -                   | -   | -                        | -       | -         | -       |
|                         | Gasolina          | -                   | -   | -                        | -       | -         | -       |
|                         | Soda Cáustica     | -                   | -   | -                        | -       | -         | -       |
|                         | Sucos Cítricos    | 58.525              | -   | -                        | -       | -         | 58.525  |
|                         | Outros            | -                   | -   | -                        | -       | -         | -       |
|                         | Soma              | 58.525              | -   | -                        | -       | -         | 58.525  |
| TOTAL                   |                   | 129.890             | -   | 44.661                   | 300.262 | 356.566   | 831.379 |

Fonte: Adaptado do Mensário Estatístico do Porto de Santos, Janeiro de 2020.

#### 4.3. Cutrale

A Sucocítrico Cutrale Ltda., empresa brasileira fundada em 1967, reconhecida mundialmente como produtora de suco de laranja, através de décadas estabeleceu-se no ramo da citricultura, opera em dois terminais portuários no Brasil, nas cidades de Santos (SP) e Guarujá (SP), e desenvolve atividades de produção agrícola, além de atividades industriais em suas fábricas, todas no Estado de São Paulo, nas cidades de Araraquara, Colina, Conchal, Itápolis e Uchôa, onde, em período de safra, conta com a prestação de serviços de cerca de dezoito mil colaboradores (CUTRALE, 2020).

Segundo seu site (CUTRALE, 2020), quanto ao seu portfólio de produtos, encontram-se as frutas “in natura”, comercializadas internamente no mercado brasileiro e também exportadas para diversos países; o suco de laranja concentrado e congelado (FCOJ), produzido sem perda de qualidade, por meio de processo de extração e concentração, e congelado em baixas temperaturas, preservando suas


propriedades naturais, sobretudo quanto à vitamina C; suco de laranja integral (NFC), citado em seu site institucional (CUTRALE, 2020); o farelo de polpa cítrica, que é obtido através do tratamento de resíduos sólidos e os óleos essenciais, que são óleos voláteis, obtidos da casca das frutas cítricas.

Reconhecida como uma empresa líder no mercado de suco de laranja por seus clientes, sendo eles fabricantes de refrigerantes, sucos prontos e grandes redes de super e hipermercados, a empresa exporta, atualmente 98% da sua produção de suco de laranja, para mais de 90 países situados na América do Norte, Ásia e Europa (CUTRALE, 2020).

#### 4.4. Subprodutos da Laranja

No Brasil, é comum o consumo da fruta “in natura”, onde a mesma é abundante, porém, conforme CITRUSBR (2020), na grande maioria dos demais países cobertos pela exportação da laranja brasileira, a procura e o consumo é por suco de laranja, industrializado ou fresco (espremido diretamente da fruta).

Do processamento industrial de frutos cítricos para a exportação do suco, existem alguns elementos da fruta que não são utilizados, porém, aproveitados como subprodutos, como por exemplo, a polpa cítrica Peletizada, os óleos essenciais etc., como demonstrado na Figura 3 e, estes, também são exportados.



Fonte: O autor, com dados da EMBRAPA (2001).

De acordo com Neves et al (2010), no ano de 2009 foram exportadas 1.129 mil toneladas de suco de laranja concentrado (FCOJ), 939 mil toneladas de suco não concentrado (NFC) e, 786 mil toneladas de subprodutos derivados da laranja, sendo os subprodutos identificados na Tabela 1:

**Tabela 1 - Exportações dos Subprodutos Cítricos**

| Ano  | Exportações de óleo essencial de laranja |               |                 | Exportações de Dlimoneno e terpenos cítricos (elaborados a partir de laranja, lima, limão, grape & tangerina) |               |                 | Exportações de CPP (farelo de polpa cítrica) |                |                 |
|------|------------------------------------------|---------------|-----------------|---------------------------------------------------------------------------------------------------------------|---------------|-----------------|----------------------------------------------|----------------|-----------------|
|      | Volume Exportado                         | Valor FOB     | Preço FOB médio | Volume Exportado                                                                                              | Valor FOB     | Preço FOB médio | Volume Exportado                             | Valor FOB      | Preço FOB médio |
|      | Tons.                                    | US\$ total    | US\$/ton.       | tons.                                                                                                         | US\$ total    | US\$/ton.       | tons.                                        | US\$ total     | US\$/ton.       |
| 2000 | 17.564                                   | \$ 17.177.408 | \$ 978          | 38.728                                                                                                        | \$ 19.258.197 | \$ 497          | 557.703                                      | \$ 38.307.811  | \$ 69           |
| 2001 | 26.550                                   | \$ 23.325.167 | \$ 879          | 41.360                                                                                                        | \$ 21.174.548 | \$ 512          | 1.020.378                                    | \$ 61.925.217  | \$ 61           |
| 2002 | 20.342                                   | \$ 38.911.517 | \$ 1.913        | 37.927                                                                                                        | \$ 26.199.384 | \$ 691          | 852.682                                      | \$ 54.155.697  | \$ 64           |
| 2003 | 22.852                                   | \$ 63.951.368 | \$ 2.799        | 36.010                                                                                                        | \$ 33.883.928 | \$ 941          | 858.721                                      | \$ 64.974.786  | \$ 76           |
| 2004 | 27.153                                   | \$ 52.375.678 | \$ 1.929        | 39.389                                                                                                        | \$ 29.293.960 | \$ 744          | 889.375                                      | \$ 64.308.215  | \$ 72           |
| 2005 | 31.690                                   | \$ 57.521.777 | \$ 1.815        | 35.379                                                                                                        | \$ 29.250.376 | \$ 827          | 792.959                                      | \$ 59.805.413  | \$ 75           |
| 2006 | 27.845                                   | \$ 61.004.192 | \$ 2.191        | 41.670                                                                                                        | \$ 45.673.217 | \$ 1.096        | 801.732                                      | \$ 72.629.076  | \$ 91           |
| 2007 | 31.647                                   | \$ 70.585.903 | \$ 2.230        | 35.316                                                                                                        | \$ 49.731.956 | \$ 1.408        | 799.712                                      | \$ 100.033.511 | \$ 125          |
| 2008 | 30.078                                   | \$ 70.892.995 | \$ 2.357        | 36.337                                                                                                        | \$ 54.344.949 | \$ 1.496        | 515.021                                      | \$ 90.264.450  | \$ 175          |
| 2009 | 28.408                                   | \$ 55.841.684 | \$ 1.966        | 35.926                                                                                                        | \$ 48.009.626 | \$ 1.336        | 721.781                                      | \$ 86.676.237  | \$ 120          |

Fonte: Elaborado por Markestrat a partir de CACEX, Banco do Brasil e Siscomex.

#### 4.4.1. Farelo de polpa cítrica

Com a elevação do preço do milho, nos últimos anos no Brasil, os agricultores foram estimulados à busca de uma fonte alternativa de energia na alimentação animal, visando à redução de custos no campo. Por se tratar de um alimento energético, o farelo de casca cítrica, ou, farelo de polpa cítrica peletizada, apresenta-se como alternativa ao uso de fontes energéticas tradicionais, sendo obtido através do tratamento de resíduos (casca, sementes e polpas de laranjas) sólidos e líquidos oriundos da extração do suco, o produto é peletizado após passar pelo processo de industrialização, onde a polpa é triturada e seca, até chegar a 12% de umidade, sendo assim, um subproduto da indústria de suco de laranja utilizado na alimentação animal (CUTRALE, 2020). De acordo com Hutton (1987), a polpa cítrica é composta de casca (50 a 55%), polpa interna (30 a 35%) e sementes (0 a 10%), que representa cerca de 50 a 60% do peso da laranja.

Utilizado como complemento para ração animal, o farelo de polpa cítrica peletizada tem boa aceitação, principalmente na pecuária, adicionado na ração de rebanhos bovinos (CUTRALE, 2020) e, vem sendo amplamente utilizado em fazendas leiteiras do sudeste brasileiro. Conforme SCOT CONSULTORIA (2019), em 2018 foram exportadas 204,43 mil toneladas de polpa cítrica, o que representou

um faturamento de US\$91,13 milhões, sendo o maior volume destinado à União Européia, tendo como principal país consumidor a Holanda.

#### 4.4.2. Óleos essenciais

Considerada uma das maiores culturas do mundo, a laranja gera uma grande quantidade de resíduos, dentre eles o óleo essencial. (RIBEIRO, 2012). Óleos essenciais são extraídos das plantas, na grande maioria das vezes, utilizando-se a técnica de arraste a vapor, e também pela prensagem do pericarpo de frutos cítricos, que no Brasil dominam o mercado de exportação (BIZZO, 2009 ).

O processo de obtenção do óleo ocorre durante a extração do suco de laranja, onde o óleo é liberado pelo rompimento das bolsas da casca da fruta e então removido por jatos de água. Logo após, o óleo é separado por centrifugação e depois, resfriado (CUTRALE, 2020).

Durante o primeiro trimestre de 2020, o volume de exportações de óleos essenciais, segundo o Ministério do Desenvolvimento, Indústria e Comércio Exterior (2020), foram de 28.807 toneladas, em um volume financeiro de US\$ 111 milhões, tendo como o principal país consumidor, os Estados Unidos, responsável por 27% das importações de óleos essenciais, conforme evidenciado na Figura 4.

**Figura 4 - Destinos do produto ( óleos essenciais, matérias de perfume e sabor )**



Fonte: ComexVis, MDIC, 2020.

#### **4.5. Fatores Intangíveis**

Consideradas atualmente como um diferencial competitivo, as pessoas constituem ativos intangíveis de extrema importância para as organizações. Prover a administração das mesmas, se tornou um grande desafio para gestores que procuram criar satisfação, valorização, condições ideais e, um bom desempenho dos seus colaboradores, buscando estratégias realmente eficazes para a obtenção do bem estar no ambiente produtivo (OLIVEIRA et al, 2020).

As indústrias cada vez mais focadas na produção, tendem ao trabalho em turnos de 24 horas, readaptação de tempo que traz questionamentos importantes no que diz respeito à saúde do trabalhador (ANDRADE et al, 2017). De acordo com Fernandes e Ferreira (2015), alguns aspectos podem favorecer o adoecimento do colaborador, bem como os acidentes no trabalho, como é o caso da sobrecarga que, além de não tornar viável o crescimento da produtividade no contexto laboral, compromete, além da saúde do próprio colaborador, o desempenho e o cumprimento dos prazos, prejudicando o alcance das entregas.

Levando-se em consideração que os funcionários são peças-chave para as organizações, pois são eles que, por meio de suas técnicas, habilidades, trabalho e conhecimento fazem com que elas atinjam seus objetivos perante seus clientes, para o alcance da missão, metas e resultados, e também perante a sociedade (KLEIN et al, 2018), se faz necessário um planejamento adequado para a redução do absenteísmo.

#### **4.6. A Linguagem R**

Além de linguagem, o R é considerado um ambiente de desenvolvimento integrado, utilizado para a realização de cálculos estatísticos e a criação de gráficos. A linguagem é largamente empregada entre os estatísticos, mineradores de dados e profissionais que utilizam ferramentas de estatística e necessitam de análise de dados no seu dia-a-dia. A linguagem permite a realização de cálculos matemáticos simples, além de funções mais complexas, como por exemplo, simulações de redes neurais, modelagens lineares e não lineares, análises de séries temporais, testes

estatísticos, técnicas de amostragem, elaboração de gráficos, entre outras coisas. (FERREIRA, 2017).

O R está disponível como software livre sobre os termos da GNU *General Public License* ( Licença Pública de Uso ) no formato de código fonte, e roda em uma gama de plataformas UNIX e sistemas similares (incluindo FreeBSD e Linux), Windows e MAC OS (R-PROJECT, 2020).

#### **4.7. Séries Temporais**

A possibilidade de prever o futuro sempre encantou a humanidade. Antever o que irá acontecer, mesmo antes dos primeiros sinais se manifestarem, pode proporcionar maior aproveitamento dos efeitos benéficos de acontecimentos futuros ou, uma antecipada preparação para eventuais efeitos contrários. (ANTUNES; CARDOSO, 2015).

Uma série temporal, também denominada série histórica, consiste em um conjunto de informações ordenadas no tempo, sobre qualquer fenômeno aleatório, uma sequência de pontos (dados numéricos) em ordem sucessiva, que podem ser contínuas ou discretas. Quando essas observações, ou conjunto de informações, são realizadas continuamente no tempo, a mesma é dita contínua, porém, quando essas medições são tomadas em intervalos de tempo regularmente espaçados, a série é denominada discreta. (MORETTIN; TOLOI, 2004). Já a Análise de Séries Temporais (AST), segundo Slack, Chambers e Johnston (2009), trata-se de um método que realiza o mapeamento de uma variável ao longo do tempo, removendo as variações com causas identificáveis e, utilizando a extrapolação para previsão do comportamento futuro.

Segundo Morettin e Toloi (2004), uma série temporal é qualquer conjunto de observações ordenadas no tempo, compostas por quatro elementos:

- Tendência: verifica o sentido de deslocamento da série ao longo de vários anos;
- Ciclo: movimento ondulatório que ao longo de vários anos tende a ser periódico;



- Sazonalidade: movimento ondulatório de curta duração, em geral, inferior a um ano; associada, na maioria dos casos, a mudanças climáticas;
- Ruído aleatório ou erro: compreende a variabilidade intrínseca aos dados e não pode ser modelado;

Podemos identificar a aplicação de séries temporais e encontrar exemplos nas mais diversas áreas, e campos de domínio. Na medicina, por exemplo, podemos observar a utilização nas leituras de eletrocardiograma e eletroencefalograma, respectivamente; na meteorologia, registros de marés, nos registros de temperaturas diárias e no registro de precipitações mensais; na economia, analisando-se as taxas de desemprego, preços diários de ações, taxas de juro ou o produto interno bruto. (BALBINOT et al, 2017).

A aplicação de previsões concebidas a partir de análise de séries temporais é de grande importância para o planeamento económico e de negócios, planeamento de produção e otimização de processos industriais (BOX; JENKINS; REINSEL, 1994). Portanto, segundo Martin et al (2015), a realização de previsões diminuirá o grau de incerteza e irá auxiliar na tomada de decisões. Assim, contribuirá para que a empresa produza a quantidade necessária no momento certo, direcione maior acurácia na produção e se adapte as variações de mercado.

## 5. MATERIAIS E MÉTODOS

### 5.1. Fonte de dados

Por se tratar de informação sensível, estratégica, relevante e que representa vantagem competitiva, a empresa em questão não autorizou a divulgação dos dados oriundos de seus sistemas e ou quaisquer fontes de dados internas, colaborando de outras formas para que o presente trabalho fosse realizado.

Portanto, para composição do modelo, foram utilizados dados mensais de janeiro de 2002 a dezembro de 2019, dados públicos referentes à quantidade de exportação de sucos cítricos, em toneladas, para o operador portuário Cutrale, disponibilizados pelo Porto de Santos, através do seu canal mensário estatístico.

Foram baixados 216 arquivos no formato PDF, que documentam, cada um deles, através de aproximadamente 25 páginas, todo o fluxo mensal do Porto (importação e exportação), dos mais variados tipos de carga, onde, no tópico “MOVIMENTO NOS TERMINAIS DE USO PRIVATIVO DO PORTO DE SANTOS – NO MÊS”, coluna de exportações, é quantificado, através do grupo “Líquidos a Granel”, a quantidade de sucos cítricos exportados no mês, conforme o Anexo 1.

### 5.2. Seleção do pacote computacional

O pacote computacional utilizado para concepção da presente pesquisa foi o R (R-PROJECT, 2020), que possui uma ampla variedade de bibliotecas estatísticas, facilmente extensível através de funções e extensões, permitindo a análise e visualização de dados, através de gráficos estatísticos, que podem produzir imagens com qualidade para publicação, incluindo símbolos matemáticos. Este software possibilita, como por exemplo, no caso do modelo autoregressivo integrado de médias móveis, ARIMA, o ajuste automático dos parâmetros, através da função *auto.arima* e da gama de bibliotecas disponíveis (R-DOCUMENTATION, 2020).


### 5.3. Representação gráfica da série temporal

A representação gráfica dos dados ao longo do tempo é a maneira mais simples de se obter importantes padrões e comportamentos da série. Por exemplo, tendências de crescimento (ou decrescimento), padrões cíclicos, alterações estruturais ou observações atípicas (dados díspares) são, muitas vezes, facilmente identificados com a simples representação gráfica da série.

Em uma série temporal a componente tendência indica o comportamento da série em longo prazo, que poderá ser constante, crescente ou decrescente, mas não necessariamente linear. A sazonalidade é um padrão que se repete com certa periodicidade dentro de um ano. A componente ciclo é um padrão que se repete com alguma regularidade, mas sem um período fixo e dentro de um período superior a um ano.

Na abordagem usual das séries temporais há interesse em separar tendências de longo prazo e variações sazonais de fenômenos exclusivamente cíclicos, ou aleatórios. Para tal, podem ser usados modelos aditivos ou multiplicativos, sob a hipótese de dados formados, respectivamente, pela soma ou multiplicação de componentes tais como tendência, sazonalidade ou ciclo.

Quando a linha cíclica não se altera ao longo da tendência, o modelo indicado é o aditivo, caso contrário, o modelo será multiplicativo. Por exemplo, numa situação ideal para o modelo aditivo, supondo uma tendência linear (conforme o Gráfico 1), as retas traçadas pelo valor máximo e valor mínimo seriam paralelas. Se o padrão nos dados não for muito esclarecedor quanto aos modelos, testam-se os dois e escolhe-se o que apresentar os melhores resultados.



É comum incluir a componente ciclo no modelo para representar movimentos com períodos longos. Contudo, como em geral os períodos observados são pequenos quando comparados com o tamanho do ciclo, muitas vezes o que se observa ao analisar o efeito da tendência é parte do ciclo. Assim, geralmente o efeito da componente ciclo é confundido com a componente tendência (MAKRIDAKIS et al, 1998; MORETTIN; TOLOI, 2006).

Para se gerar a série temporal e a sua representação gráfica pelo software R, foi utilizado o script dado no Anexo 2. No script, o comando *ts* (time series) informa ao R que a matriz de dados possui séries temporais que se iniciam em 2002, com frequência 12, ou seja, são dados mensais. Para dados anuais ou trimestrais, utiliza o parâmetro de frequência como 1 ou 4, respectivamente.

#### 5.4. Decomposição da série temporal

Se  $Z_t$  for uma série temporal observada em períodos  $t$ , então o modelo aditivo pode ser descrito por:

$$Z_t = T_t + S_t + E_t \quad (1)$$

e, no caso de modelo multiplicativo, por:

$$Z_t = T_t \times S_t \times E_t \quad (2)$$

sendo  $T_t$  a componente ciclo-tendência,  $S_t$  a componente sazonal e  $E_t$  o erro (ou termo aleatório) que representa flutuações não determinísticas (MORETTIN; TOLOI, 2006; BARROS, 2018).

No caso da série temporal que é objeto deste estudo, supõe-se a decomposição por um modelo aditivo. Para tratar cada uma das componentes  $T$ ,  $S$  e  $E$  da série temporal utiliza-se a função *decompose* do R. A decomposição da série pode ser obtida pelo script dado pelo Anexo 3, sendo o objeto “exportacoes” a série temporal armazenada no R, e o modelo do tipo aditivo.

Outra ferramenta para decomposição de uma série temporal, é o filtro de Hodrick-Prescott (filtro HP), cuja proposta metodológica consiste em supor que em um período  $t$ , uma série temporal  $Z_t$  é composta por uma tendência  $T_t$  e um termo estacionário de flutuações cíclico-aleatórias  $Z_t - T_t$ , isto é:

$$Z_t = T_t + C_t, \quad (3)$$

sendo  $C_t$  é a componente cíclico-aleatória.

A extração da componente de tendência se dá minimizando a seguinte equação de erros quadráticos:

$$\frac{1}{\tau} \sum_{t=1}^{\tau} (Z_t - T_t)^2 + \frac{\lambda}{\tau} \sum_{t=2}^{\tau-1} [(T_{t+1} - T_t) - (T_t - T_{t-1})]^2. \quad (4)$$

O primeiro termo da Equação (4) representa os desvios quadráticos da série original em relação à componente tendência, isto é, trata-se de uma medida do grau

do ajuste. O segundo termo é a soma de quadrados da diferença entre os componentes da tendência e indica seu grau de suavidade.

O parâmetro de suavização ou penalização da incorporação das flutuações na componente tendência,  $\lambda$ , deve assumir valores positivos. Se  $\lambda = 0$ , a tendência é igual à série original e por outro lado, quanto maior for  $\lambda$ , maior é a suavização da tendência.


No R, a decomposição utilizando o filtro Hodrick-Prescott foi realizada com a função *hpfilter*, executando-se o script dado no Anexo 4.

### **5.5. Suavização exponencial simples**

Proposta no final dos anos 50, a suavização exponencial (SE) motivou alguns dos métodos de previsão mais bem sucedidos (HYNDMAN; ATHANASOPOULOS, 2018). Os modelos de suavização exponencial são largamente utilizados para se realizar a previsão de demanda, devido a sua facilidade de ajuste, simplicidade e uma boa precisão. A suavização exponencial simples (SES), também conhecida como suavização exponencial de primeira ordem, pondera as observações passadas com pesos decrescentes exponencialmente, para previsão de valores futuros, em outras palavras, quanto mais recente se tratar a observação, maior o peso associado a ela, enquanto que, para as observações mais antigas, o peso decai exponencialmente. O mais simples dos métodos de previsão, naturalmente chamado de suavização exponencial simples (SES), e trata-se de um método adequado para realizar previsões em séries temporais livres das componentes tendência e sazonalidade. (BARROS, 2018).

De acordo com Barros et al (2020), apesar de ser difícil observar séries sem as componentes de tendência e sazonalidade, é possível utilizar o método SES ao identificar e remover esses efeitos, produzindo então, séries estacionárias. Para fins de ilustração, a Figura 5 abaixo, demonstra graficamente o comportamento de uma série temporal, denominada “Série Simulada SES”, onde não há evidências de comportamento sazonal ou de tendência, atendendo aos requisitos para utilização do SES.

**Figura 5 - Série simulada de suavização exponencial simples - SES**



**Fonte: O autor (2020)**

Os comandos para criação da série simulada evidenciada na Figura 5, estão expostos sequencialmente de acordo com o Anexo 5.

Seja  $Z_t$ , uma série temporal não sazonal e sem tendência sistemática. A previsão da série em  $h$  passos adiante, pelo método da suavização exponencial, pode ser obtida pela média ponderada das observações passadas, isto é:

$$\hat{Z}_{t+h} = \bar{Z}_t = \alpha Z_t + \alpha(1 - \alpha)Z_{t-1} + \alpha(1 - \alpha)^2 Z_{t-2} + \dots \quad (5)$$

sendo  $\alpha$  o parâmetro de suavização com valores entre 0 e 1,  $\bar{Z}_0 = Z_1$  e  $t = 1, 2, \dots, n$ .

Observa-se que quanto menor for o parâmetro  $\alpha$ , as previsões serão mais estáveis e, maiores serão os pesos das observações passadas tal que, se  $\alpha$  for próximo de 1 então a previsão é próxima de  $Z_t$ . A Equação (5) pode ser transformada na seguinte relação recursiva (BARROS, 2018; MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998):

$$\hat{Z}_{t+h} = \alpha Z_t + (1 - \alpha)\hat{Z}_{t+h-1} \quad (6)$$

A Equação (6) utiliza apenas o parâmetro de suavização exponencial  $\alpha$ , a observação mais recente e a previsão feita no período anterior.

### 5.6. Suavização exponencial de Holt-Winters

O modelo de Holt-Winters (HW), ou como também é conhecido por modelo de Winters, é aplicado satisfatoriamente a séries temporais que exibem tendência e sazonalidade (WINTERS,1960; PELLEGRINI; FOLLIATO, 2001). Segundo Barros et al (2020), o modelo de suavização exponencial simples (SES) não é apropriado para séries temporais que apresentam tendência linear e, uma incorreta aplicação do modelo acarretaria subestimar ou superestimar os valores reais da série. Como, na prática, a maioria das séries apresentam a componente de sazonalidade, o modelo HW é apropriado para séries que possuem comportamento mais geral.

Existem dois métodos diferentes para se realizar a análise por Holt-Winters, diferenciando-se na forma como a sazonalidade é modelada, ou seja, a sazonalidade pode receber um tratamento aditivo (SEHWA) ou multiplicativo (SEHWM). Diferente do modelo de suavização exponencial simples, o modelo de suavização exponencial Holt-Winters captura os efeitos da tendência e da sazonalidade, suaviza não somente o nível, mas também modela a tendência da série.

Para o modelo aditivo (SEHWA), entende-se que a amplitude da variação sazonal permanece constante ao longo do tempo, e, quanto ao modelo multiplicativo (SEHWM), parte-se do pressuposto que a amplitude da variação sazonal varia ao longo do tempo (PELLEGRINI, 2000; ALLEMÃO, 2004). De acordo com Allemão (2004), as séries que possuem as características dos modelos de Holt-Winters são séries observadas frequentemente no dia a dia.

Supondo que a componente sazonal seja aditiva, então, o modelo de previsão de Holt-Winters para  $h$  passos à frente é dado por:

$$\hat{Z}_{t+h} = L_t + T_t h + S_{t+h-m} \quad (7)$$



onde:

$$L_t = \alpha(Z_t - S_{t-m}) + (1 - \alpha)L_{t-1} + T_{t-1} \quad (8)$$


$$T_t = \beta(L_t - L_{t-1}) + (1 - \beta)T_{t-1} \quad (9)$$

$$S_t = \gamma(Z_t - L_{t-1} - T_{t-1}) + (1 - \gamma)S_{t-m} \quad (10)$$

sendo que  $\alpha$ ,  $\beta$  e  $\gamma$  representam, respectivamente, os parâmetros de suavização para o nível da série, para a tendência e sazonalidade da série, com valores restritos ao intervalo 0 e 1.

Makridakis, Wheelwright e Hyndman (1998) apresentam um fluxo estratégico para a utilização dos modelos de suavização exponencial apresentada na Figura 6 e, segundo eles, essa estratégia pode ser utilizada a qualquer metodologia de previsão.

**Figura 6 - Estratégia para avaliação dos métodos de previsão**



**Fonte: Adaptado de Makridakis et al (1998)**

A seguir, são descritas as etapas identificadas na Figura 6, para a utilização dos modelos de suavização exponencial:

- a) 1ª Etapa: É realizada a divisão da série temporal de interesse em duas partes: conjunto de inicialização e, conjunto de testes. Após essa divisão realizada, prossegue-se com a avaliação do método de previsão;
- b) 2ª Etapa: É selecionado um método de previsão, dentre a lista de possíveis métodos à serem utilizados;
- c) 3ª Etapa: Utiliza-se o conjunto de dados de inicialização no método de previsão escolhido na segunda etapa;
- d) 4ª Etapa: É aplicado então, o método selecionado ao conjunto de testes, para se verificar como este irá modelar os dados não utilizados na estimação dos componentes do modelo. Após essa análise, o erro de previsão é determinado. Caso os parâmetros estimados não sejam ótimos, então serão necessárias alterações no processo de inicialização;
- e) 5ª Etapa: O método de previsão é então avaliado quanto à sua conformidade para os padrões dos dados;

## 5.7. Box-Jenkins ou modelos ARIMA

O modelo ARIMA (modelo autorregressivo integrado de médias móveis) foi apresentado em 1970, por Box e Jenkins, no livro *Time Series Analysis, Forecasting and Control*. Neste modelo, são identificados os processos subjacentes que evidenciam o mecanismo do processo gerador visando sempre à precisão quanto aos dados (BOX; JENKINS, 1994). A partir de então, o método tornou-se uma das abordagens mais populares para a previsão de valor e continua sendo utilizado atualmente para este propósito.

Essa metodologia, popularmente conhecida por Box-Jenkins e, no campo técnico como ARIMA, parte do princípio de que, cada observação da série temporal pode ser explicada por seus valores anteriores, através da utilização de uma estrutura de correlação no tempo, algo que geralmente ocorre entre as observações da série. (GUJARATI, 2000; FAVA, 2000; WERNER; RIBEIRO, 2003). Segundo

Moretin e Toloi (1987), a construção desses modelos é baseada em um ciclo iterativo, onde a opção pelo modelo é realizada com base nos próprios dados.

Em um modelo ARIMA(p,d,q) os parâmetros p, d e q são números inteiros não negativos. De acordo com Fava (2000), os modelos ARIMA são oriundos da combinação de três componentes também conhecidos como filtros, sendo eles:

- Componente Auto-Regressivo (AR): parâmetros auto-regressivos (p)
- Filtro de Integração (I): processos de diferenciação (d)
- Componente de Médias Móveis (MA): parâmetros de médias móveis (q)

O parâmetro p é o número de defasagens ou ordem do processo autorregressivo, d é o grau de diferenciação ou o número de vezes em que os dados tiveram valores anteriores subtraídos e q é a ordem do modelo de média móvel. Um processo  $X_t$  estacionário de média  $\mu$  é de médias móveis de ordem q se

$$X_t = a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q} \quad (11)$$

onde  $\mu$  e  $\theta_i, i = 1, 2, \dots, q$  são parâmetros reais e  $a_t$  é normalmente distribuído com média 0 e variância  $\sigma_a^2$ , isto é  $a_t \sim N(0, \sigma_a^2)$ .

Maddala (2003) relata que a metodologia Box-Jenkins é uma das mais utilizadas na análise de dados em séries temporais e que se tornou popular em virtude de sua generalidade; ela pode lidar com qualquer série, estacionária ou não, com ou sem elementos sazonais. Para Gujarati (2000), o destaque destes métodos de previsão está na análise probabilística das séries temporais em si mesmas, sendo assim, classificados como modelos univariados (FAVA, 2000).

A estratégia para a construção de um modelo de previsão, segundo Moretin e Toloi (2004), é baseada em um ciclo iterativo, com os seguintes estágios:

1. Identificação: identificar o modelo com base em análise de autocorrelações, autocorrelações parciais e outros critérios;
2. Estimação: fase onde os parâmetros do modelo são estimados;
3. Verificação ou Diagnóstico: análise dos resíduos para identificar se este é adequado para os fins (previsão etc);

Caso o modelo evidenciado não seja adequado, este ciclo é repetido, iniciando-se na fase de identificação e assim por diante, e caso o propósito seja a previsão, deverá se escolher o melhor modelo, por exemplo, no sentido de fornecer o menor erro quadrático médio de previsão.

### 5.7.1. Identificação

A identificação da ordem do modelo ARIMA ( $p, d, q$ ) se dá através da análise dos dados que compõe a série temporal, onde as ferramentas principais utilizadas no processo de identificação são as funções de autocorrelação (ACF) e autocorrelação parcial (PACF). Hyndman e Athanasopoulos (2018) relatam que, do mesmo modo que a correlação mede a extensão de um relacionamento linear entre duas variáveis, a autocorrelação mede o relacionamento linear entre os valores defasados (anteriores) de uma série temporal. Ou seja, é uma medida da correlação entre as observações  $Z_t$  e  $Z_{t-k}$  de uma série temporal, separadas por  $k$  unidades de tempo. Existem vários coeficientes de autocorrelação, correspondentes a cada painel no gráfico de atraso.

Existe uma grande quantidade de modelos possíveis considerados como candidatos, portanto, escolher o modelo mais apropriado para descrever uma série temporal não se torna tarefa trivial. Na prática, a identificação do melhor modelo pode ser amparada pela sequência abaixo (MAKRIDAKIS et al, 1998):

- 1) Com base no gráfico da série temporal, analisa-se seu comportamento no tempo. É necessário realizar, em certas situações, transformações nos dados (por exemplo, uma transformação logarítmica), com o objetivo de estabilizar a variância da série em estudo.
- 2) Após a variância estabilizada, caso seja necessário este procedimento, então se analisa a estacionariedade da série temporal. O procedimento de verificação se a série é estacionária ou não, é realizado em duas etapas: análise da série temporal e dos gráficos das ACF (autocorrelação) e PACF (autocorrelação parcial). Quando os dados da série são exibidos em torno de uma média constante e os gráficos das ACF e das PACF apresentam autocorrelações que tendem a zero rapidamente, obtém-se a indicação de que a série é estacionária. Caso algum destes requisitos não forem observados, a série é então, possivelmente, do tipo não estacionária.
- 3) As séries não estacionárias, devem ser estabilizadas através de do método de diferenciação. Para séries não sazonais, faz-se a diferenciação

das observações ( $z'_t = z_t - z_{t-1}$ ); para séries sazonais, faz-se a diferenciação sazonal das observações ( $z'_t = z_t - z_{t-s}$ ), que leva em consideração o intervalo sazonal  $s$ . Caso a não estacionariedade permaneça, diferenciações são aplicadas enquanto necessário. Geralmente, após no máximo duas diferenciações, a série torna-se estacionária.

- 4) Tornando-se estacionária, os valores  $D$  e  $d$  da série são conhecidos. Falta então determinar os valores dos demais componentes: normais ( $p$  e  $q$ ), e sazonais ( $P$  e  $Q$ ).

### 5.7.2. Estimativa dos parâmetros

Após o processo de identificação do modelo, seus parâmetros devem ser estimados. Segundo Morettin e Toloi (2004), serão utilizadas as estimativas preliminares encontradas na fase de identificação, como valores iniciais, porém, atualmente os programas computacionais incorporam tais valores, não se havendo então, a necessidade de estimativas preliminares. Um método bastante utilizado para a estimação dos parâmetros é o da máxima verossimilhança.

Considere um modelo  $ARIMA(p,d,q)$  e coloquemos seus  $p+q+1$  parâmetros no vetor  $\xi = (\phi, \theta, \sigma_a^2)$ , onde  $\phi = (\phi_1, \phi_2, \dots, \phi_p)$ ,  $\theta = (\theta_1, \theta_2, \dots, \theta_q)$  e  $\sigma_a^2$  é a variância residual. Quando  $d > 0$  supomos a média  $\mu = 0$ , caso contrário precisamos considerar  $\mu$  como um parâmetro e estimá-lo, então teríamos  $p+q+2$  parâmetros a serem estimados.

Dado as  $n$  observações,  $X_1, X_2, \dots, X_n$ , consideramos a função de verossimilhança  $L(\xi|X_1, X_2, \dots, X_n) = \prod_{i=1}^n f(X_i|\xi)$ , sendo  $f(X_i|\xi)$  a função densidade de probabilidade da  $i$ -ésima observação como função de  $\xi$ . Então queremos encontrar os valores de  $\xi$  que maximizam  $L$  ou  $l = \log(L)$ .

Para determinar os estimadores de máxima verossimilhança, EMV, trabalharemos com a hipótese que o processo  $a_t$  é normal, ou seja, para cada  $t$ , temos  $a_t \sim N(0, \sigma_a^2)$ . Nestas considerações os EMV serão aproximadamente estimadores de mínimos quadrados (EMQ).

Inicialmente, tomamos d diferenças na série temporal para alcançarmos a estacionariedade, ficamos com  $n = N - d$  observações denotadas por  $W_1, W_2, \dots, W_n$ , onde  $W_t = \Delta^d Z_t$  ( $\Delta Z_t = Z_t - Z_{t-1}$ ), resultando em um modelo ARMA(p,q) estacionário e invertível, então escrevemos:

$$a_t = \tilde{W} - \phi_t \tilde{W}_{t-1} - \dots - \phi_{t-p} \tilde{W}_{t-p} + \theta_1 a_{t-1} + \dots + \theta_q a_{t-q}, \quad (12)$$

sendo  $\tilde{W}_t = W_t - \mu$ .

Para calcular os  $a_t$ , é necessário obter valores iniciais para os  $\tilde{W}'s$  e os  $a's$ . Podemos resolver esta questão através de dois métodos: Condicional, que os valores iniciais desconhecidos são substituídos por valores que supomos serem razoáveis; incondicional, em que o valores iniciais são estimados utilizando um procedimento denominado "*backforecasting*".

### 5.7.3. Diagnóstico ou verificação

Uma vez obtido o modelo preliminar e, ajustados os parâmetros para a série temporal, deve-se então analisar se o modelo representa ou não, os dados, adequadamente. De acordo com Morettin e Tolo (2004), a verificação pode ser feita, analisando os resíduos, através de testes de diagnóstico do modelo ajustado a uma série e, esses testes, são baseados, em geral, nas autocorrelações estimadas dos resíduos.

#### 5.7.3.1. Teste de autocorrelação residual

É o processo de análise residual que nos permite realizar o diagnóstico do modelo. Estimados  $\phi$  e  $\theta$ , as quantidades  $\hat{a}_t$  são denominadas resíduos estimados, ou apenas resíduos. Essa análise se mostra de grande interesse para o trabalho pois possui a capacidade de rejeição do modelo, nesta etapa do desenvolvimento. Considera-se que o modelo esteja adequado caso os  $\hat{a}_t$  estiverem próximos de  $a_t$  e, portanto, deverão ser aproximadamente não-correlacionadas (MORETTIN; TOLOI, 2004).

#### 5.7.3.2. Teste de Box-Pierce e Ljung e Box

Box e Pierce (1970) sugeriram um teste para as autocorrelações dos resíduos estimados que possa identificar se os valores são muito altos, ou seja, são analisadas  $m$  autocorrelações dos resíduos e quanto menor for esse valor, melhor o

ajustamento do modelo escolhido. O teste de Ljung e Box (1978) é uma variação deste modelo, com estatística de teste definida por:

$$LB = n(n+2) \sum_{k=1}^m \left( \frac{\hat{r}_k^2}{N-k} \right) \quad (13)$$


onde  $\hat{r}_k$  são as estimativas de autocorrelação definidas por

$$\hat{r}_k = \frac{\sum_{t=k+1}^n \hat{a}_t \hat{a}_{t-k}}{\sum_{t=1}^n \hat{a}_t^2}.$$

#### 5.7.4. Análise da série

##### 5.7.4.1. Gráfico da série

Para fins de análise gráfica dos dados, a série temporal contendo o período de exportações de 2002 a 2019, está representada no Gráfico 2 abaixo:



**Fonte: O autor (2020)**

Tendo em vista que é basicamente impossível se comprovar a estacionariedade ou não através de uma análise visual do gráfico, optou-se por realizar a análise do teste da raiz unitária, para a identificação de estacionariedade

ou não, pois, de acordo com Morettin e Tolo (1979), é desejável que a série temporal seja estacionária de primeira ordem.

#### **5.7.4.2. Teste de estacionariedade**

Na estacionariedade, pressupõe-se que a média e a variância de uma série temporal se mantenham constantes durante o tempo. Em princípio, séries com sazonalidade e tendência não são séries estacionárias, porém, eventualmente podem ser e, se torna difícil uma identificação puramente visual para a identificação.

Para a previsão de demanda utilizando-se dos modelos ARIMA, é necessária a condição de estacionariedade da série temporal, que é a primeira etapa para sua construção, diagnosticando a presença ou não de raiz unitária na série ( KUMAR; JAIN, 1999; ZHANG, 2003) e, conforme Morettin e Tolo (1979), é desejável que a mesma seja estacionária de primeira ordem.

##### **5.7.4.2.1. Teste KPSS**

Denominado conforme as iniciais dos sobrenomes de seus criadores (KWIATKOWSKI et al, 1992), este teste determina a estacionariedade de uma série temporal, composto pelas hipóteses:

- $H_0$ : A série é estacionária (não possui raiz unitária)
- $H_1$ : A série não é estacionária (possui raiz unitária)

Diferentemente dos demais testes de estacionariedade presentes na literatura, como: Dickey-Fuller, Phillips Perron etc, no teste KPSS, a hipótese nula sugere a estacionariedade da série, enquanto que nos dois anteriormente citados, a hipótese alternativa sugere a estacionariedade da série temporal. Para a validação que segue, foi utilizado o comando indicado no Anexo 6, através do software R (R PROJECT, 2020). A Figura 7, valida a série original, denominada “exportações”, e identifica se a mesma é estacionária, através do teste KPSS:



**Figura 7 - Identificação da estacionariedade da série “exportações”**

```
#####
# KPSS Unit Root Test #
#####

Test is of type: mu with 4 lags.

Value of test-statistic is: 3.394


Critical value for a significance level of:
      10pct  5pct 2.5pct  1pct
critical values 0.347 0.463 0.574 0.739
```

**Fonte: O autor (2020)**

Comparado com os valores críticos de 0.347, 0.463, 0.574 e 0.739, respectivamente, verificou-se que o valor 3.394, da estatística do teste KPSS, foi muito superior aos valores apresentados, indicando que devemos rejeitar a hipótese nula (KWIATKOWSKI et al, 1992), então, a série “exportações” é uma série temporal não estacionária. Iremos então, estimar a quantidade de diferenciações necessárias para que a série se torne estacionária, utilizando o comando `ndiffs` (HYNDMAN et al, 2020), do pacote `forecast`. Conforme o comando executado no Anexo 7, o resultado foi o de que será necessária uma única diferenciação ( $d=1$ ), para que a série se torne estacionária.

Uma vez identificada a não estacionariedade e a quantidade de diferenças necessárias para que a mesma se torne estacionária, utilizamos o pacote `diff` (R PROJECT, 2020), que calcula a diferença entre as defasagens da série e realizamos a comparação entre a série temporal original (denominada “exportações”) e a série contendo a diferenciação de primeira ordem (denominada “Exportações D1”), conforme a Figura 8.

**Figura 8 - Comparação série temporal original e com diferenciação de 1a ordem**



**Fonte: O autor (2020)**

De acordo com os resultados, é notável que a série temporal original (não estacionária) se tornou estacionária submetendo-a à apenas uma diferenciação, conforme visualização da Figura 8, onde o plot denominado “Exportações D1”, que se refere à série temporal original, com a aplicação de uma diferenciação, está com seus valores médios próximos de zero (observa-se que a série passou a oscilar em torno de uma média constante). Conforme a Figura 9, o valor do teste após diferenciação foi de 0.0184, ficando abaixo do valor crítico de 0,05 (p-value) para os percentuais, aceitando-se a hipótese nula, onde se evidencia estacionariedade. Os dados de aceitação da estacionariedade foram obtidos através da nova realização do teste KPSS, com a aplicação de diferenciação de primeira ordem sobre os dados da série temporal exportações, conforme comando identificado no Anexo 8.

**Figura 9 - Identificação da estacionariedade da série “exportações” após diferenciação**

```
#####
# KPSS Unit Root Test #
#####

Test is of type: mu with 4 lags.

Value of test-statistic is: 0.0184

Critical value for a significance level of:
      10pct  5pct 2.5pct  1pct
critical values 0.347 0.463 0.574 0.739
```

Fonte: O autor (2020)

#### 5.7.4.3. Identificação do modelo ARIMA com o software R

Na fase de identificação do modelo ARIMA (p, d, q) se torna necessário a definição dos filtros p, d e q. Como identificado na Figura 23, a série temporal se tornou estacionária com apenas uma diferenciação, então, temos o valor do filtro “d” definido como 1 (d=1).

Como mencionado no item 3.7.1, segundo Morettin e Toloí (2004), a identificação do modelo ocorre com base nas autocorrelações, porém, iremos utilizar para tal detecção de identificação, uma função do pacote *forecast*, do software R, denominada *auto.arima*, que na data deste documento, encontra-se em sua versão 8.12 (HYNDMAN et al, 2020). A função *auto.arima* tem como objetivo retornar o melhor modelo ARIMA, de acordo com os menores valores de AIC ( Critério de Informação de Akaike ) ou BIC (Critério de Informação Bayesiano) definidos respectivamente por

$$AIC = -2 \ln(\hat{\sigma}_{p,q}^2) + 2(p + q + 2) \quad (14)$$

$$BIC = -2 \ln(\hat{\sigma}_{p,q}^2) + (p + q) \frac{\ln n}{n} \quad (15)$$

onde n é o número de observações e  $\hat{\sigma}_{p,q}^2$  é o estimador de máxima verossimilhança da variância do modelo ARMA(p,q).


## 6. RESULTADOS E DISCUSSÃO

O presente capítulo apresenta os resultados de ajuste e de previsão da série temporal de sucos cítricos e, no final deste, será apresentada uma discussão à respeito dos resultados obtidos, realizando as análises dos modelos utilizados e demais questões relevantes.

A série temporal utilizada para realização do presente estudo corresponde ao conjunto de observações mensais, de janeiro de 2002 a dezembro de 2019, dados referentes à exportação de sucos cítricos, medida em toneladas, realizadas através do Porto de Santos.

A figura 10 mostra a representação gráfica da série temporal das exportações de suco de laranja, período de 2002 à 2019, gerada pelo software R:

**Figura 10 - Série temporal das exportações de suco de laranja de 2002 a 2019**



**Fonte: O autor (2020)**

A figura 11 mostra a decomposição da série temporal exportações, dada na Figura 10. A primeira janela (observed), representa a série temporal. A segunda, terceira e quarta janela representam, respectivamente, as componentes de tendência (trend), sazonalidade (seasonal) e os erros (random). Nota-se que na segunda janela da Figura 11, que a série apresenta uma tendência de crescimento linear, o que corrobora que se trata de uma série temporal não estacionária e, os erros apresentam uma dispersão aleatória em torno do zero. Estas observações,

juntamente com o comportamento da componente sazonal, serão discutidas posteriormente.

Nota-se também, para esta série de dados, que a componente tendência é bastante similar aos dados observados, conforme apresentado no terceiro gráfico da Figura 11, pois esta componente apresenta padrão repetitivo.


**Figura 11 - Decomposição da série exportações, admitindo-se um modelo aditivo**



**Fonte: O autor (2020)**

A Figura 12 ilustra a decomposição da série temporal exportações utilizando o filtro HP. Na primeira janela observa-se, após a extração da componente cíclica, que a tendência apresenta um comportamento notadamente linear. A componente cíclica, da série mostrada na segunda janela gráfica da Figura 12 apresenta um comportamento semelhante ao da componente randômica da última janela (random) da Figura 11. Isto significa que a série original não sofre influência significativa da componente cíclica, o que concorda com o fato de os dados terem sido registrados em períodos curtos (meses), como comentado anteriormente.

**Figura 12 - Decomposição da série temporal exportações utilizando filtro HP**



**Fonte: O autor (2020)**

### 6.1. Resultados do ajustamento dos modelos e previsão da série temporal

Nesta seção é apresentado o ajustamento dos modelos da série temporal de sucos cítricos, evidenciando o modelo que apresentou a melhor performance e ajuste na comparação entre os modelos selecionados. Como base de dados para o ajuste, os dados de exportação do período de 2002 a 2019, recuperados através do Mensário Estatístico do Porto de Santos, foram subdivididos em dois grupos:

1. **Dados de treino:** correspondentes ao período de janeiro de 2002 à dezembro de 2017, compreendendo 192 meses;
2. **Dados de validação:** compreendendo o período de janeiro de 2018 à dezembro de 2019, cobrindo os demais 24 meses restantes.

A Tabela 2 abaixo identifica a separação dos dados de treino e validação, além de apresentar a quantidade de meses cobertos em cada agrupamento de dados:

**Tabela 2 - Subdivisão dos dados da série temporal para aplicação dos modelos****Exportação de Sucos Cítricos - 2002 a 2019**


| Período Inicial | Período Final | Qtd. Meses | Observação                                 |
|-----------------|---------------|------------|--------------------------------------------|
| 01/01/2002      | 31/12/2017    | 192        | Período utilizado como treino do modelo    |
| 01/01/2018      | 31/12/2019    | 24         | Período utilizado como validação do modelo |

**Fonte: O autor (2020)**

De acordo com Raschka (2015), a divisão da amostra em questão (dados de exportação de sucos cítricos), em dados de treinamento e dados de validação, é utilizada para verificar se determinado modelo apresenta um bom ajuste, não apenas em dados utilizados para seu ajuste (dados de treinamento), mas também pela capacidade de generalização para novas observações (validação).

As divisões mais utilizadas são 60:40, 70:30 ou 80:20, de acordo com o tamanho do conjunto de observações. Em geral, quanto maior o número de observações, maior será a proporção do conjunto inicial utilizada para o treinamento. No presente estudo, conforme evidenciado na Tabela 2, aproximadamente 89% dos dados foram utilizados para treinamento dos modelos aplicados e, 11% foram utilizados para validação, o que significa que, todos os modelos aqui citados, foram executados sob os dados de treino (2002 a 2017), e, seus resultados de previsão obtidos, comparados com os dados de validação (2018 a 2019).

A Figura 13 exhibe graficamente a separação do conjunto total dos dados, que compreende o período de janeiro de 2002 à dezembro de 2019, onde o primeiro conjunto, em azul, referentes ao período de 2002 à 2017 são utilizados para se treinar o modelo estatístico e, o segundo conjunto, em verde, são utilizados para realizar a validação do modelo utilizado:

**Figura 13 - Exportações - Dados de treino (2002 a 2017) e validação (2018 a 2019)****Fonte: O autor (2020)**

A validação comum consistiu em separar uma parte da base de dados para treinamento, ou seja, foi realizada a aplicação dos 20 modelos de previsão exibidos na Tabela 3, sobre os dados que compreendem os anos de 2002 a 2017 (dados de treino) e, com os dados de previsão gerados por esses modelos, foi realizada a comparação e verificação da acurácia com os dados de validação, que são os dados de 2018 a 2019, evidenciando-se assim um melhor ou pior ajuste de cada modelo proposto.

A Figura 14 representa graficamente o fluxo dos dados com a aplicação dos modelos estatísticos para previsão e, identifica que o melhor modelo estatístico é aquele que se ajusta melhor aos dados de validação.

**Figura 14 – Validação comum: fluxo de dados de treinamento, validação e previsão****Fonte: O autor (2020)**



## 6.2. Critérios para avaliação de desempenho dos modelos

Foram aplicados diversos modelos para a realização das previsões, como descritos na Tabela 3, e, recuperadas as informações de precisão e exatidão dos dados, ou seja, a proximidade do resultado experimental com o seu valor real, no caso, os dados de validação.

A escolha do modelo mais apropriada é realizada através da somatória dos erros entre a previsão ajustada ao longo da série e seu valor real e, como os erros apresentados podem apresentar valores negativos ou positivos e, existe a possibilidade dos mesmos se anularem, zerando a somatória, diferentes maneiras de cálculo da somatória foram desenvolvidas, podendo ser utilizadas para a comparação de modelos distintos, sendo elas:

- ME: Erro Médio
- RMSE: Raiz do Erro Quadrático Médio
- MAE: Erro Absoluto Médio
- MPE: Erro Percentual Médio
- MAPE: Erro Percentual Médio Absoluto

No presente estudo, nos baseamos na medida de acurácia que realiza a média percentual absoluta do erro, na avaliação da precisão da previsão, no caso o MAPE, pela sua facilidade de interpretação, devido ao fato de ser expresso em percentual.

**Tabela 3 - Medidas de acurácia para a previsão de demanda dos modelos**


| SEQ. # | MÉTODO         | ME         | RMSE        | MAE        | MPE        | MAPE      |
|--------|----------------|------------|-------------|------------|------------|-----------|
| 1      | hwa2           | 2.089792   | 12047.26    | 8998.969   | -2.474669  | 12.85337  |
| 2      | hwm2           | 56.81657   | 16818.48    | 13267.86   | -6.170681  | 20.43643  |
| 3      | taylor2        | -0.5997972 | 17026.8     | 13277.9    | -6.353614  | 20.44085  |
| 4      | holt1          | -434.3433  | 17376.73    | 13271.05   | -7.027191  | 20.45868  |
| 5      | exp2           | -0.0488385 | 16818.24    | 13279.38   | -6.250221  | 20.46966  |
| 6      | hwd2           | -13.22324  | 17003.96    | 13320.91   | -6.363302  | 20.51581  |
| 7      | sbest2         | -724.6115  | 17361.02    | 13294.89   | -7.513011  | 20.68847  |
| 8      | sma1\$forecast | -2934.144  | 17304.41    | 13370.42   | -10.36805  | 21.01635  |
| 9      | gardner1       | -2302.111  | 17887.13    | 13445.74   | -9.717849  | 21.08716  |
| 10     | gardner2       | -1301.525  | 17514.77    | 13423.85   | -8.406512  | 21.19568  |
| 11     | taylor1        | -2786.159  | 17827.31    | 13575.61   | -10.38272  | 21.38018  |
| 12     | holt2          | -4.338965  | 17540.06    | 13880.91   | -6.528088  | 21.4511   |
| 13     | brown2         | -1188.09   | 17726.48    | 13754.4    | -8.299881  | 21.53566  |
| 14     | hwa1           | 3055.429   | 17282.7     | 14591.99   | -1.799936  | 21.87288  |
| 15     | exp1           | -3302.755  | 17875.85    | 13824.44   | -11.18363  | 21.94455  |
| 16     | sma2           | -2342.776  | 17941.71    | 13996.28   | -9.971971  | 22.22972  |
| 17     | hwd1           | 6004.703   | 18243.71    | 15833.99   | 2.512731   | 22.90981  |
| 18     | hwm1           | 4027.309   | 17961.17    | 15497.93   | -0.4148305 | 23.14273  |
| 19     | arw2           | 455.476832 | 28132.15136 | 23624.8935 | -7.607384  | 34.837367 |

Fonte: O autor (2020)

A Figura 15 representa graficamente, dos vários modelos utilizados, os dois modelos com melhor ajuste, denominados, respectivamente “hwa2” (Holt-Winters Aditivo) , “hwm2” (Holt-Winters Multiplicativo) . Também é representado na figura, por questões de comparação de métodos, um modelo Arima, denominado “arw2”, porém, pela sua medida de acurácia, o mesmo não constitui um modelo de ajuste satisfatório para a previsão.

O modelo “hwm2”, na comparação dos dados gerados, de treinamento (linha verde) e com os dados de validação (linha tracejada preta), obteve um ajuste não satisfatório, com erro percentual médio absoluto (MAPE), de 20,44%, o que também está evidenciado nas medidas de acurácia da Tabela 3.


**Figura 15 - Modelo de previsão HWM2 - Validação x Previsão**  
**Modelo hwm2: Exportações Previsão 2018 - 2019 - Holt-Winters Multiplicativo ETS(A,A,M)**



**Fonte: O autor (2020)**

Porém, de acordo com a Figura 17, dentre os modelos apresentados, o modelo “hwa2”, foi o que obteve o melhor desempenho e ajuste, com erro percentual médio absoluto (MAPE), de 12,85%, ocupando assim a primeira posição da Tabela 3.


**Figura 16 - Modelo de previsão ARW2 - Validação x Previsão**  
**Modelo arw2: Exportações Previsão 2018 - 2019 - Random Walk ARIMA(0,1,0) Sem Constante Modelo 2**



**Fonte: O autor (2021)**

**Figura 17 - Modelo de previsão HWA2 - Validação x Previsão**

Modelo hwa2: Exportações Previsão 2018 - 2019 - Holt-Winters Aditivo ETS(A,A,A)

**Fonte: O autor (2021)**

O Gráfico 3, abaixo, exibe a média de exportações do ano de 2019, baseando-se nas informações do Quadro 2, considerando os dados do Mensário Estatístico do Porto de Santos, que foi de 68.154 toneladas neste período. Com base neste valor, foram evidenciadas também as médias dos três modelos de previsão aplicados:

- “hwa2” : Holt-Winters aditivo
- “hwm2”: Holt-Winters multiplicativo
- “arw2”: Arima

**Quadro 2 – Valores de exportações mensais do ano de 2019 – por método**

| EXPORTAÇÕES - MENSÁRIO ESTATÍSTICO PORTO DE SANTOS                          |        |        |        |        |        |        |        |        |        |        |        |        |
|-----------------------------------------------------------------------------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|
| 2019 - Sucos Cítricos - Operador Portuário Cutrale - Resultados por Métodos |        |        |        |        |        |        |        |        |        |        |        |        |
| 2019                                                                        | mês    |        |        |        |        |        |        |        |        |        |        |        |
|                                                                             | jan    | fev    | mar    | abr    | mai    | jun    | jul    | ago    | set    | out    | nov    | dez    |
| Dados do Mensário Estatístico                                               | 39,405 | 75,499 | 80,753 | 43,729 | 77,284 | 60,610 | 75,398 | 77,832 | 64,290 | 70,154 | 94,569 | 58,328 |
| Método hwa2                                                                 | 35,110 | 80,966 | 64,048 | 69,934 | 67,352 | 61,397 | 68,069 | 79,922 | 66,153 | 76,904 | 70,291 | 69,972 |
| Método hwm2                                                                 | 73,583 | 73,181 | 72,779 | 72,377 | 71,974 | 71,572 | 71,170 | 70,768 | 70,366 | 69,964 | 69,562 | 69,160 |
| Método arw2                                                                 | 90,613 | 39,405 | 75,499 | 80,753 | 43,729 | 77,284 | 60,610 | 75,398 | 77,832 | 64,290 | 70,154 | 94,569 |
| Total no Mês                                                                | 39,405 | 75,499 | 80,753 | 43,729 | 77,284 | 60,610 | 75,398 | 77,832 | 64,290 | 70,154 | 94,569 | 58,328 |


**Fonte: O autor (2021)**

### 6.3. Comparação entre os métodos

Para concepção da previsão, foram utilizados três métodos distintos neste estudo, sendo eles: Holt-Winters Aditivo (hwa2), Holt-Winters Multiplicativo (hwm2) e ARIMA (arw2) e, conforme evidenciado no Gráfico 3, o modelo “hwa2”, com média

de 67.510 toneladas para ano de 2019, foi considerado o de melhor ajuste, em comparação com todos os modelos apresentados na Tabela 3, baseando-se nos dados de 2019 do Mensário Estatístico do Porto de Santos, por se posicionar numericamente mais próximo dos dados obtidos no ano, que é de 68.154 toneladas, fato que é explicado também pelo seu MAPE e, pelo percentual de proximidade do Quadro 3.

**Gráfico 3 – Comparativo das médias dos modelos para as exportações do ano de 2019**



Fonte: O autor (2021)

As diferenças em toneladas, na comparação dos métodos com os dados de 2019, estão também estão dispostas no Quadro 3. Em percentual, o método evidenciado aqui como de melhor ajuste, hwa2, obteve uma proximidade de 99,05% com os dados exportados em 2019, o que enfatiza a assertividade do método de previsão Holt-Winters aditivo.

**Quadro 3 – Acurácia dos modelos em Toneladas**

|                               | Média por Método | Proximidade (%) | MAPE  | Dif. Ton. |
|-------------------------------|------------------|-----------------|-------|-----------|
| Dados do Mensário Estatístico | 68,154           |                 |       |           |
| Método hwa2                   | 67,510           | 99.05           | 12.85 | 644.42    |
| Método hwm2                   | 71,371           | 105             | 20.44 | 3,217.08  |
| Método arw2                   | 70,845           | 103.95          | 34.84 | 2,690.42  |

Fonte: O autor (2021)

### 6.3.1. Método Holt-Winters x ARIMA

Através da análise do Quadro 4, abaixo, com base nas estimativas do MAPE e o seu respectivo percentual de proximidade com os dados reais do ano de 2019, adquiridos do Mensário Estatístico do Porto de Santos, observou-se que o modelo mais adequado ao ajuste da série temporal foi o Holt-Winters Aditivo (“hwa2”), em relação ao modelo ARIMA.

**Quadro 4 – Comparação Holt-Winters x ARIMA**

|                                    | Média por Método | Proximidade (%) | MAPE  |
|------------------------------------|------------------|-----------------|-------|
| Dados do Mensário Estatístico      | 68,154           |                 |       |
| Método Holt-Winters Aditivo (hwa2) | 67,510           | 99.05           | 12.85 |
| Método ARIMA (arw2)                | 70,845           | 103.95          | 34.84 |


Fonte: O autor (2021)

Quanto ao método ARIMA (auto regressivo, integrado e de médias móveis), e, de acordo com a Figura 18, responsável pela análise dos resíduos do modelo ARIMA, os mesmos encontram-se distribuídos em torno do valor 70000 (*residuals*), e suas autocorrelações (*ACF*) encontram-se distribuídas em torno do zero, ou seja, existe o indicativo que, por este modelo, os resíduos são independentes ao longo das observações. Além disso, no histograma, observa-se que a distribuição de frequências dos resíduos tem um aspecto aproximadamente parecido com uma distribuição normal.

Em termos de acurácia, o modelo ARIMA proposto obteve um percentual (MAPE) de 34,84%, sendo bem superior aos valores do modelo Holt-Winters, não sendo então considerado o mais apropriado para a realização da previsão.

Portanto, as exportações não estão auto correlacionadas ao longo do tempo, ou seja, a variável exportações não é afetada significativamente pelos seus valores defasados.


**Figura 18 – Resíduos do modelo ARIMA (arw2)**



**Fonte: O autor (2021)**

Considerando que a série temporal utilizada neste estudo possui características de tendência e uma possível sazonalidade, conforme a Figura 19, foi utilizado o modelo de suavização exponencial de Holt-Winters Aditivo (“hwa2”), envolvendo os parâmetros de suavização a cada componente da série: nível, tendência e sazonalidade.

**Figura 19 – Exportações 2002 a 2019 - Tendência**



**Fonte: O autor (2021)**

De acordo com as características citadas da série temporal e a identificação com as características do modelo de Holt-Winters Aditivo, e levando em consideração o seu ajuste de performance, bem como a evidência de um percentual

de acurácia de 12,85% (de acordo com o Quadro 4), este modelo foi considerado o modelo de melhor ajuste e performance, com um percentual de 99,05% de proximidade com os dados reais de exportação do ano de 2019.

#### 6.4. Comparação com a literatura

Foram realizadas pesquisas na literatura, para fins de comparação e questões de validação da eficácia dos métodos apresentados neste estudo, porém, especificamente sobre “Previsão de exportação de suco de laranja”, onde não foram encontrados resultados específicos para o tema.

Entretanto, Tan et al (2020), realizou um trabalho sobre “Aceitação sensorial e perspectiva de produção de refresco de laranja em pó”, onde, no estudo, é realizada a utilização do método de decomposição e suavização exponencial, juntamente com software estatístico NNQ-Statistica, para obtenção de previsão de demanda para os próximos 12 meses, visando auxiliar a cadeia de suprimentos da corporação.

A Tabela 4 abaixo, identifica o poder de acurácia dos modelos apresentados no trabalho sobre a exportação do suco em pó, onde o autor cita o melhor método como sendo o MNM (tratamento de erros de forma multiplicativa, sem tendência e sazonalidade multiplicativa), com MAPE de 27,11%:

**Tabela 4 - Comparação dos valores de erros e coeficientes calculados para todos os modelos de suavização exponencial possíveis de serem aplicados aos dados**

| Método | DM     | MAE   | RMES  | MAPE   | r <sup>1</sup> | U de Theil | AIC     |
|--------|--------|-------|-------|--------|----------------|------------|---------|
| ANA    | -0,018 | 2,488 | 3,344 | 29,37% | 0,025          | 0,677      | 426,023 |
| MNA    | 0,026  | 2,660 | 3,638 | 29,32% | 0,245          | 0,613      | 444,638 |
| AAA    | -0,094 | 2,506 | 3,358 | 29,63% | 0,025          | 0,678      | 430,562 |
| MAA    | 0,151  | 3,424 | 4,332 | 45,99% | 0,448          | 0,877      | 484,887 |
| AAdA   | -0,214 | 2,482 | 3,312 | 29,75% | 0,023          | 0,673      | 430,872 |
| MAdA   | -0,249 | 2,921 | 4,129 | 35,55% | 0,379          | 0,753      | 446,978 |
| MNM    | -0,287 | 2,518 | 3,618 | 27,11% | -0,027         | 0,499      | 384,935 |
| MAM    | -0,440 | 2,478 | 3,639 | 26,25% | 0,060          | 0,480      | 386,041 |
| MAdM   | -0,300 | 2,449 | 3,603 | 25,71% | 0,085          | 0,479      | 387,718 |
| MMM    | -0,671 | 2,592 | 3,929 | 27,33% | 0,155          | 0,484      | 387,096 |
| MMdM   | -0,572 | 2,549 | 3,815 | 26,99% | 0,137          | 0,481      | 388,702 |

Fonte: Tan et al (2020)



Foram evidenciadas, através do Quadro 4, abaixo, as diferenças da acurácia (medida dos erros), entre o presente trabalho (MAPE de 12,85%) e a pesquisa na literatura (MAPE de 27,11%), observando-se neste estudo uma medida de erros inferior, gerando uma diferença entre os valores de 14,26%, mantendo suas quantidades mais próximas dos valores previstos.

**Quadro 5 – Diferença da acurácia entre o presente estudo e a literatura**

|                                                         | MAPE  |
|---------------------------------------------------------|-------|
| Método Holt-Winters Aditivo (hwa2)                      | 12.85 |
| Método Suavização Exponencial Tripla ( Tan et al 2020 ) | 27.11 |

**Fonte: O autor (2021)**

Com os dados do Quadro 4, estabelece-se a comparação do presente trabalho com as evidências da literatura e, conclui-se que diante dos resultados dos cálculos apresentados, chegou-se à conclusão de que o Modelo Holt-Winters Multiplicativo (“hwa2”) é o mais indicado para realização das previsões utilizando-se como base os dados do Mensário Estatístico do Porto de Santos, onde a performance de ajustamento está com melhor acurácia e percentual de acerto no método estatístico utilizado neste trabalho, em comparação com a literatura (Tan et al, 2015).

## 7. CONCLUSÃO

O aumento no consumo do suco brasileiro, bem como o aumento da produção e da capacidade competitiva, sempre estiveram relacionados aos avanços científicos e à disponibilização de novas tecnologias ao setor agrícola. A participação brasileira no mercado internacional de sucos cítricos cresce significativamente a cada ano, aumentando cada vez mais as perspectivas das exportações, que se baseiam em vantagens competitivas e diminuição do custo de produção.

Com mercados mais exigentes e a concorrência internacional mais acirrada se faz necessário o aumento da qualidade dos produtos e para que o país se mantenha em posição favorável no comércio mundial de suco de laranja, são necessários investimentos em novas tecnologias e processos que visam aumentar a produtividade e agregar maior valor ao seu produto, se posicionando a frente de seus concorrentes.

As séries temporais ajustadas por modelos estatísticos para a previsão de demanda, mostraram-se eficientes em acompanhar os dados de previsão obtidos pelo Mensário Estatístico do Porto de Santos, dados estes que, foram imprescindíveis para a concepção do trabalho, posto que nenhuma empresa do segmento, por tamanha expressão e por questões de concorrência e sigilo, nos forneceria dados diretamente recuperados de sistemas internos ou oriundos deles, se tornando uma solução de contorno completamente viável para concepção da série temporal, baseando-se em dados reais da exportação brasileira de suco cítrico, de domínio público.

A aceitabilidade do modelo, sua capacidade preditiva, foi evidenciada pelo método Holt-Winters aditivo (hwa2), proposto neste trabalho, que obteve o menor percentual de erro estatístico para o ano de 2019, com valor de MAPE da ordem de 12,85% e, valor de proximidade dos dados de 99,05%, na comparação dos dados e, tão importante quando apresentar o modelo foi cumprir, por meio de técnicas estatísticas, as adequações à série temporal analisada.

O trabalho apresentou uma alternativa consistente, através da aplicação de modelos estatísticos, para utilização da previsão de demanda na exportação de sucos cítricos, onde foi evidenciado que o ajuste acompanhou de forma satisfatória a série temporal e o mesmo poderá auxiliar os tomadores de decisão, conhecendo

valores futuros e otimizando todo o processo de produção e entrega do produto, reafirmando contratos de parceria e estreitando o relacionamento com seus clientes.

Espera-se que os resultados aqui disponibilizados possam amparar futuras decisões estratégicas da agroindústria, uma vez que a laranja é um cultivo de alto impacto no mercado brasileiro, sendo de grande representatividade no cenário das exportações.

Para futuros trabalhos, recomenda-se a continuidade da aplicação das técnicas estatísticas de previsão de demanda aqui apresentadas, para outros itens produzidos na indústria, como os subprodutos resultantes do processo da extração do suco, e até mesmo de outros itens que são disponibilizados pelo Mensário Estatístico do Porto de Santos, além de sucos cítricos, tais como: farelo de soja, açúcar, milho, soja em grãos, minério de ferro etc, visando a adequação dos modelos aqui apresentados.

Por fim, sugere-se também a utilização de outras técnicas computacionais disponíveis atualmente para a concepção da previsão de demanda, como a utilização de redes neurais, inteligência artificial e aprendizado de máquina (*machine learning*).

## REFERÊNCIAS

ALLEMÃO, M. A. F. **Redes Neurais Aplicadas à Previsão de Demanda de Numerário em Agências Bancárias**. Dissertação (Mestrado em Ciência da Computação) - Programa de Pós Graduação em Ciência da Computação, Universidade Federal do Rio de Janeiro, 2004. 247 p.

ANDRADE, R. et al. Absenteísmo na Indústria está Associado com o Trabalho em Turnos e com Problemas no Sono. **Revista Ciencia & Trabajo**. Ano 19, n. 58, 2017, p. 31-45. Acesso em: 31 de dez. 2020. Disponível em: <<https://scielo.conicyt.cl/pdf/cyt/v19n58/0718-2449-cyt-19-58-00035.pdf>>.

ANTUNES, J. L. F.; CARDOSO, M. R. A. Uso da análise de séries temporais em estudos epidemiológicos. **Epidemiol. Serv. Saúde**, Brasília, v. 24, n. 3, p. 565-576, jul-set 2015. Disponível em: <<https://repositorio.ufu.br/bitstream/123456789/26459/1/AnaliseSeriesTemporais.pdf>>. Acesso em: 02 de jun. 2020.

ARCHER, B. Forecasting Demand: Quantitative and Intuitive Techniques. **International Journal of Tourism Management**. v.1, n.1, p. 5-12, 1980.

ARMSTRONG, J. S. **Principles of Forecasting: A handbook for Researchers and Practitioners**. Boston: Kluwer Academic Publishers, 2001.

BALBINOT, E. et al. Modelos de séries temporais aplicados a previsão de radiação solar. **Perspectiva**, Erechim, v. 41, n. 155, p. 63-71, 2017. Disponível em: <[http://www.uricer.edu.br/site/pdfs/perspectiva/155\\_636.pdf](http://www.uricer.edu.br/site/pdfs/perspectiva/155_636.pdf)>. Acesso em: 01 de jun. 2020.

BARROS, A. C. et al. **Análise de séries temporais em R: curso introdutório**. 6. ed. São Paulo: Editora Atlas, 2020. 264 p.

BIZZO, H; REZENDE, A. Óleos essenciais no Brasil: aspectos gerais, desenvolvimento e perspectivas, **Quim. Nova**. v. 32, p. 588-594, 2009.

BOX, G. E. P., PIERCE, D. A. Distribution of residual autocorrelations in autoregressive-integrated moving average time series models. **Journal of the American Statistical Association**. v. 65, n. 332, p. 1509-1526, 1970.

BOX, G. P; JENKINS, G. M.; REINSEL, G. C. **Time Series Analysis: Forecasting and Control**. 5th. ed. New Jersey: Prentice Hall, 2015.

CITRUSBR. **Laranja e Suco**. Disponível em: <<http://www.citrusbr.com/laranjaesuco/?ins=19/>> Acesso em: 11 de mai. de 2020.

CLARIVATIVE ANALYTICS, ISI Web of Science, **Relatório de citações – total de publicações**. Disponível em: <http://apps-webofknowledge.ez87.periodicos.capes.gov.br/CitationReport.do?product=WOS&se>

[arch\\_mode=CitationReport&SID=6BIY7hm4pidX9Gjh4Ld&page=1&cr\\_pqid=1&viewType=summary&colName=WOS](http://arch_mode=CitationReport&SID=6BIY7hm4pidX9Gjh4Ld&page=1&cr_pqid=1&viewType=summary&colName=WOS). Acesso em: 03 jul. 2020.

CUTRALE. **Institucional**. Disponível em: < <https://www.cutrale.com.br/institucional.xhtml/>> Acesso em: 23 de mar. de 2020.

CUTRALE. **Produtos**. Disponível em: < <https://www.cutrale.com.br/produtos.xhtml/>> Acesso em: 15 de mai. de 2020.

EMBRAPA. **Circular Técnica 23**. A laranja e seus subprodutos na alimentação animal, p. 10, 2001. Disponível em: <<https://ainfo.cnptia.embrapa.br/digital/bitstream/item/91662/1/CPATC-CIR.-TEC.-23-01.pdf>> Acesso em: 31 de mai. de 2020.

FERREIRA, P. C. *et al.* **Análise de Séries Temporais em R: Um curso introdutório**. Rio de Janeiro: Elsevier: FGV-IBRE, 2017. p. 12.

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

GONZALEZ, R. et al. Gestão do conhecimento: tipologia a partir dos fatores contextuais da organização. **Transinformação**, Campinas, v. 30, n. 2, p. 249-266, 2018. Disponível em: < [https://www.scielo.br/scielo.php?script=sci\\_arttext&pid=S0103-37862018000200249&lng=pt&tlng=pt](https://www.scielo.br/scielo.php?script=sci_arttext&pid=S0103-37862018000200249&lng=pt&tlng=pt) >. Acesso em: 21 de dez. de 2020.

HILL, T. **Manufacturing strategy: text and cases**. 2th. ed. Boston, MA: Business One Irwin, 1994.

HYNDMAN, R.J.; ATHANASOPOULOS, G. **Forecasting: principles and practice**. 2th. ed. Melbourne, Austrália: OTexts, 2018. Disponível em: < <https://otexts.com/fpp2/> > Acesso em: 29 de jun. 2020 .

HYNDMAN, R. J. et al. **Package forecast. Forecasting Functions for Time Series and Linear Models**. Software, R package version 8.12, 2020. Disponível em < <https://www.rdocumentation.org/packages/forecast/versions/8.12/topics/auto.arima> >. Acesso em: 12 de jul. 2020.

HYNDMAN, R. J.; RAZBASH, S.; O'HARA-WILD, M. **Package ndiffs**. R Documentation. Software Forecast v8.12. Disponível em: <<https://www.rdocumentation.org/packages/forecast/versions/8.12/topics/ndiffs>>. Acesso em: 12 de jul. 2020.

HODRICK, R.; PRESCOTT, E. Postwar business cycles: An Empirical Investigation. **Journal of Money, Credit and Banking**, v. 29, n. 1, p. 1-16, 1997.

HUTTON, K. Citrus pulp in formulated diets. In: FARRELL, D. (editor). **Recent advances in animal nutrition in Australia**, Armidale, NSW: University of

New England, 1987. p. 297-316.

KLEIN, L. *et al.* Qualidade de vida no trabalho: Parâmetros e avaliação no serviço público. **Revista de Administração Mackenzie**, v. 20, n. 3, eRAMG190134, 2018. Acesso em: 31 de dez. 2020. Disponível em: <  
[https://www.scielo.br/pdf/ram/v20n3/pt\\_1678-6971-ram-20-03-eRAMG190134.pdf](https://www.scielo.br/pdf/ram/v20n3/pt_1678-6971-ram-20-03-eRAMG190134.pdf)>.

KWIATKOWSKI, D.; PHILLIPS, P. C.B.; SCHMIDT, P.; SHIN, Y. Testing the null hypothesis of stationarity against the alternative of a unit root. **Journal of Econometrics**, v. 54, p.159-178. 1992.

LJUNG, G. M.; BOX, G. E. P. On a measure of lack of fit in time series models. **Biometrika**, v. 64, p. 297-303, 1978.

MADDALA, G. S. **Introdução à Econometria**. 3 ed. Rio de Janeiro: Ed. LTC – Livros Técnicos e Científicos, 2017. 245 p.

MAKRIDAKIS, S.; WHEELWRIGHT, S. C; HYNDMAN, R. J. **Forecasting: Methods and Applications**. 3<sup>rd</sup>. ed. New York: John Wiley & Sons, 1998.

MARTIN, A. C. *et al.* Análise de séries temporais para previsão da evolução do número de automóveis no Município de Joinville. **Revista Espacios**, v. 37, n. 6, e-16370629, 2016. Disponível em <<https://qualimetria.ufsc.br/files/2016/05/Revista-ESPACIOS--Vol.pdf>> Acesso em: 02 de jun. 2020.

MINISTÉRIO DO DESENVOLVIMENTO, INDÚSTRIA E COMÉRCIO EXTERIOR. **ComexVis**. Visualizações de Comércio Exterior. Disponível em: <  
<http://comexstat.mdic.gov.br/pt/comex-vis/>> Acesso em: 28 mai. 2020.

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

NEVES, M. F. *et al.* **O retrato da citricultura brasileira**. São Paulo: Editora CitrusBR, 2010. p. 8.

NEVES, M. F. *et al.* **A laranja do campo ao copo**, Envase, distribuição e consumo de bebidas no mundo. São Paulo: Atlas, 2010. p. 44.

OLIVEIRA, A. *et al.* Antecedentes de bem-estar no trabalho: Confiança e Políticas de Gestão de Pessoas. **RAM. Revista de Administração Mackenzie**, v. 21, n. 1, São Paulo, 2020. Disponível em: <  
[https://www.scielo.br/scielo.php?script=sci\\_arttext&pid=S1678-69712020000100602&tlng=pt](https://www.scielo.br/scielo.php?script=sci_arttext&pid=S1678-69712020000100602&tlng=pt)>. Acesso em: 29 dez. 2020.

PELLEGRINI, F.R.; FOLIATTO, F.S. Passos para Implantação de Sistemas de Previsão de Demanda Técnicas e Estudo de Caso. **Revista Produção**, v. 11, n. 1, p. 43-64, 2001.

PLAFF, B; STIGLER, M; ZIVOT, E. Package 'urca'. 2016. Disponível em: <  
<https://cran.r-project.org/web/packages/urca/urca.pdf> > Acesso em: 11 de jul. 2020.

PORTO DE SANTOS. Institucional. **Estatísticas**. Disponível em: <  
<https://www.portodesantos.com.br/relacoes-com-o-mercado/estatisticas/>> Acesso  
 em: 07 abr. 2020.

PORTO DE SANTOS. **Mensário Estatístico do Porto de Santos de Janeiro de 2020**. Santos, SP: Porto de Santos, 2020. 32 f., p. 22. Disponível em: <  
[http://intranet.portodesantos.com.br/docs\\_codesp/doc\\_codesp\\_pdf\\_site.asp?id=128572/](http://intranet.portodesantos.com.br/docs_codesp/doc_codesp_pdf_site.asp?id=128572/)> Acesso em: 22 de mar. de 2020.

PORTO DE SANTOS. **Relações com o Mercado - Estatísticas**. Informações operacionais. Santos, SP: Porto de Santos. Disponível em: <  
<https://www.portodesantos.com.br/relacoes-com-o-mercado/estatisticas/>> Acesso  
 em: 22 mar. 2020.

R CORE TEAM. 2019. **R: A language and environment for statistical computing**. R Foundation for Statistical Computing, Vienna, Austria. Disponível em <  
<https://www.R-project.org/> > Acesso em: 20 de jul. de 2020.

R-DOCUMENTATION. **Packages. Forecast**. Disponível em: <  
<https://www.rdocumentation.org/packages/forecast/versions/8.12/topics/auto.arima>>.  
 Acesso em: 06 de jul. de 2020.

R-PROJECT. **About R**. Disponível em: <<https://www.r-project.org/about.html>>  
 Acesso em: 04 de abr. de 2020.

RASCHKA, S. **Python machine learning**. Second Edition. Birmingham: Packt Publishing, 2017.

RIBEIRO, J; LIMA, M. Allelopathic effects of orange (*Citrus sinensis* L.) peel essential oil. **Acta Botânica Brasílica**, v. 26, n. 1, p. 256-259, 2012. Disponível em: <  
<http://dx.doi.org/10.1590/S0102-33062012000100025/> > Acesso em: 27 mai. 2020.

SCOT CONSULTORIA. **Carta Insumos**. Disponível em: <  
<https://www.scotconsultoria.com.br/noticias/cartas/50825/carta-insumos---o-mercado-de-polpa-citrica-em-2019.htm> >. Acesso em: 04 de abr. de 2020.

TAN, J. *et al.* Aceitação sensorial e perspectiva de produção de refresco de laranja em pó. **Revista Brasileira de Tecnologia Agroindustrial**, v. 14, n. 1, p. 3139-3160. Paraná, 2020. Disponível em: < <https://periodicos.utfpr.edu.br/rbta/article/view/8116> >. Acesso em: 12 jan. 2021.

TOMPKINS, J. A., et al. **Facilities planning**. 2<sup>nd</sup>. ed. New York: John Wiley, 1996.

WERNER, L. RIBEIRO, J. L. D. Previsão de demanda: uma aplicação dos modelos Box-Jenkins na área de assistência técnica de computadores pessoais. **Revista Gestão & Produção**. v. 10, p. 47-63, 2003.

WINTERS, P. R. Forecasting Sales by Exponentially Weighted Moving Averages. **Management Sci.**, v. 6, p. 324-342, 1960.



## ANEXOS

### Anexo 1 - Série histórica de dados de Exportações - Jan/2002 a Dez/2019

# Exportação de Sucos Citricos: 2002 a 2019

|      | Jan   | Feb   | Mar   | Apr    | May   | Jun   | Jul   | Aug   | Sep   | Oct    | Nov   | Dec    |
|------|-------|-------|-------|--------|-------|-------|-------|-------|-------|--------|-------|--------|
| 2002 | 26068 | 24393 | 11080 | 24475  | 24297 | 26105 | 23163 | 36476 | 13364 | 34401  | 36972 | 48308  |
| 2003 | 26054 | 46060 | 19080 | 46555  | 45040 | 23156 | 40967 | 25853 | 45699 | 24346  | 48398 | 23377  |
| 2004 | 36070 | 24178 | 34705 | 25858  | 43582 | 13176 | 43832 | 23570 | 52285 | 44827  | 26389 | 43497  |
| 2005 | 10958 | 56965 | 36976 | 44022  | 44022 | 12449 | 45484 | 23360 | 44277 | 23314  | 45431 | 43283  |
| 2006 | 43135 | 55994 | 24801 | 36461  | 44308 | 34111 | 24819 | 45480 | 43833 | 43542  | 56105 | 34997  |
| 2007 | 43980 | 32311 | 23078 | 76114  | 10702 | 63009 | 61797 | 44917 | 35419 | 62368  | 73779 | 54934  |
| 2008 | 52903 | 72667 | 32327 | 84643  | 21870 | 71877 | 60384 | 52730 | 43740 | 61536  | 40934 | 82782  |
| 2009 | 74195 | 60926 | 34678 | 53441  | 53816 | 53730 | 43208 | 57449 | 54051 | 42899  | 84541 | 64462  |
| 2010 | 34014 | 56581 | 61360 | 70500  | 19528 | 76101 | 12036 | 71402 | 55588 | 53552  | 51252 | 43513  |
| 2011 | 74940 | 21946 | 74786 | 42749  | 45944 | 50469 | 61749 | 61429 | 46779 | 61438  | 62726 | 55563  |
| 2012 | 50335 | 55719 | 67225 | 53934  | 14514 | 34640 | 45384 | 75692 | 56597 | 84110  | 30491 | 106471 |
| 2013 | 58807 | 61801 | 46298 | 96574  | 88835 | 96298 | 55034 | 61972 | 64565 | 77038  | 75220 | 65952  |
| 2014 | 74515 | 68887 | 31360 | 67642  | 87025 | 58265 | 33115 | 94768 | 70702 | 67264  | 99706 | 68758  |
| 2015 | 74211 | 48732 | 67662 | 72092  | 59243 | 62449 | 34261 | 70812 | 33035 | 104731 | 64275 | 52849  |
| 2016 | 62679 | 68841 | 51093 | 54937  | 75024 | 33637 | 59979 | 83647 | 60351 | 83479  | 61693 | 69273  |
| 2017 | 54958 | 34064 | 60037 | 54049  | 62056 | 44590 | 55618 | 88992 | 93093 | 77151  | 80236 | 115274 |
| 2018 | 47444 | 97694 | 67277 | 108704 | 66882 | 74055 | 73688 | 95263 | 76208 | 94094  | 62411 | 90613  |
| 2019 | 39405 | 75499 | 80753 | 43729  | 77284 | 60610 | 75398 | 77832 | 64290 | 70154  | 94569 | 58328  |

Fonte: O autor, baseado em dados do Mensário Estatístico do Porto de Santos (2020)

### Anexo 2 - Criação da série temporal – Exportações de suco de laranja de 2002 a 2019

```
# Cria fonte de dados [2002 a 2019]
dados <- read.table("02 - dados_exportacoes_geral_2002_a_2020.txt",header=FALSE,sep="\t",dec=".")
ano_2020 <- c(-217:-220)
dados<-dados[ano_2020,]
exportacoes <- ts(dados[,2],start=2002,frequency=12)
options(scipen=10000)
plot(exportacoes,xaxt="n",xlab="Ano",ylab="Exportações", bty='l', col='blue')
axis(side=1,at=2002+1*(0:18))
grid(col='darkgrey',lwd=2)
```

Fonte: O autor (2020)

### Anexo 3 - Comandos de decomposição da série

```
# Decomposição da série exportacoes - modelo aditivo
decomp <- decompose(exportacoes,type='additive')
plot(decomp, col="blue")
```

Fonte: O autor (2020)

#### Anexo 4 - Comandos de decomposição da série com o Filtro HP

```
# Decomposição da série exportacoes - filtro HP ( Hodrick-Prescott )
library(mFilter)
filtro_hp <- hpfilter(exportacoes,type="lambda")
par(mfrow=c(2,1))
plot(exportacoes,xaxt="n",xlab="Ano",ylab="Exportações",col="blue")
axis(side=1,at=2002+1*(0:18))
abline(h=seq(0,115000,50000),v=seq(2000,2019,1),lty=2,col="darkgray")
lines(filtro_hp$trend,col="red",lwd=2)
legend(2001,115000,c("Série original", "Tendência-Filtro HP"),col=c("blue","red"),lwd=c(1,2),bty="n")
#Componente Cíclica
plot(filtro_hp$cycle,ylab="Componente Cíclica",xlab="Ano",xaxt="n",col="blue")
axis(side=1,at=2002+1*(0:18))
abline(h=seq(0,115000,50000),v=seq(2000,2019,1),lty=2,col="darkgray")
```

Fonte: O autor (2020)

#### Anexo 5 - Comandos para criação da série simulada SES

```
# Série SES simulada
set.seed(4321)
series simulada <- ts( runif(100,10,15), start=c(1905,1), frequency = 1)
plot(series simulada, main="Série Simulada SES")
```

Fonte: O autor (2020)

#### Anexo 6 - Comandos para validação da estacionariedade da série - Teste KPSS

```
# Identificação da Estacionariedade da Série - Teste KPSS
library(urca)
summary(ur.kpss(exportacoes))
```

Fonte: O autor (2020)

#### Anexo 7 - Comandos para validação da quantidade de diferenciações necessárias

```
#Teste da quantidade de diferenciações necessárias
ndiffs(exportacoes
      ,alpha = 0.05
      ,test = c("kpss","adf","pp"))
```

Fonte: O autor (2020)

#### Anexo 8 - Comando para diferenciação de primeira ordem da série temporal

```
# Diferenciação de 1a ordem
exportacoes_d1 <- diff(exportacoes)
summary(exportacoes_d1)
```

Fonte: O autor (2020)