



UNIVERSIDADE FEDERAL DE ALAGOAS – UFAL
CAMPUS SERTÃO
ENGENHARIA DE PRODUÇÃO

Lucas Gabriel de Souza Silva

**AVALIAÇÃO DE TÉCNICAS DE PREVISÃO DE DEMANDA PARA ESTIMAR
PRODUÇÃO DE ÁGUA DE COCO: O CASO DE UMA AGROINDÚSTRIA
PERNAMBUCANA.**

Delmiro Gouveia/AL
2021



LUCAS GABRIEL DE SOUZA SILVA

**AVALIAÇÃO DE TÉCNICAS DE PREVISÃO DE DEMANDA PARA ESTIMAR
PRODUÇÃO DE ÁGUA DE COCO: O CASO DE UMA AGROINDÚSTRIA
PERNAMBUCANA.**

Trabalho de Conclusão de Curso apresentado ao
Curso de Engenharia de Produção da Universidade
Federal de Alagoas – Campus Sertão, para obtenção
do título de Bacharel em Engenharia de Produção.

Orientador: Prof. Dr. Jonhatan Magno Norte da Silva

**Catálogo na fonte
Universidade Federal de Alagoas
Biblioteca do Campus Sertão
Sede Delmiro Gouveia**

Bibliotecária responsável: Sâmela Rouse de Brito Silva CRB-4/22063

S586a Silva, Lucas Gabriel de Souza

Avaliação de técnicas de previsão de demanda para estimar produção de água de coco: o caso de uma agroindústria pernambucana / Lucas Gabriel de Souza Silva. – 2021.

84 f. : il.

Orientação: Jonhatan Magno Norte da Silva.

Monografia (Engenharia de Produção) – Universidade Federal de Alagoas. Curso de Engenharia de Produção. Delmiro Gouveia, 2021.

1. Autorregressão neural. 2. Modelos de previsão de demanda.
3. Planejamento e controle. I. Título.

CDU: 658.5

Folha de Aprovação

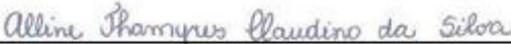
LUCAS GABRIEL DE SOUZA SILVA

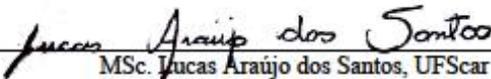
**AValiação de Técnicas de Previsão de Demanda para Estimar
Produção de Água de Coco: O Caso de uma Agroindústria
Pernambucana**

Trabalho de Conclusão de Curso submetido ao corpo docente do Curso de Engenharia de Produção da Universidade Federal de Alagoas – Campus Sertão e aprovado em de maio de 2021.


Prof. Dr. Jonhatan Magno Norte da Silva, UFAL – Campus do Sertão

Banca Examinadora:


Prof. MSc. Alline Thamyres Claudino da Silva, UFAL – Campus do Sertão


MSc. Lucas Araújo dos Santos, UFScar


Prof. Dr. Jonhatan Magno Norte da Silva, UFAL – Campus do Sertão

Dedico este trabalho a todos que ajudaram direta ou indiretamente, em especial a André Barbosa, diretor da empresa e facilitador do estudo de caso, ao meu orientador, Jonhatan Magno, família e amigos.

AGRADECIMENTOS

Primeiramente à Deus que sempre esteve comigo e em momento algum me abandonou nessa trajetória.

Aos meu pais, Sonha e Ronaldo. Expressar com palavras os sentimentos que tenho por ambos é praticamente impossível. Tudo o que eu sou, tudo o que almejo ser, todo meu amor, todo do meu carinho, dedico à vocês.

À toda minha família, minha irmã Letícia, meus primos Jheniffer e Jefferson, meu tio José Adilson, que sempre estiveram comigo nesta trajetória. Meus avós, tios e primos que me apoiaram, agradeço à Deus por ter me colocado nessa família. Em especial ao meu tio, Jairo Camilo, que todos esses anos me acolheu, ajudou e se fez presente na jornada. Infelizmente não pôde ver o sonho se realizar, mas sei que estás no céu, feliz e orgulhoso por essa conquista.

Ao meu orientador, Prof. Msc. Jonhatan Magno, que confiou no meu trabalho e aceitou este desafio. Um exemplo de profissional, dedicado e integro. Que todo aluno pudesse ter a oportunidade de ter um professor que exerce a função com tanto empenho e amor.

Aos grandes amigos que fiz na graduação, compartilhando momentos memoráveis. Yogo Jessé, Arão Henrique, Danilo Novais, Leticia Xavier, Myllena Barros, Isabelle Araújo e muitos outros que fizeram parte desta caminhada.

À minha namorada, Laelya Laranjeira, que sempre esteve ao meu lado, incentivando, apoiando e focando nesta vitória comigo. O seu exemplo de determinação e companheirismo me fez uma pessoa melhor.

À UFAL-Campus Sertão, professores e servidores que proporcionaram um ensino de excelência.

Finalizo agradecendo à todos que passaram por minha vida neste período de graduação.

RESUMO

Com a necessidade de melhorar seu desempenho e continuar competitivas no mercado, empresas buscam ferramentas para dar apoio a tomada de decisão no âmbito estratégico. Assim, a previsão de demanda se tornou uma grande aliada e vem sendo muito utilizada por quem entende a importância de conviver e estar preparado para as oscilações das necessidades de demanda da empresa ao longo do tempo. Este trabalho trouxe uma abordagem de previsões de demanda quantitativas e computacionais com o intuito de analisar qual melhor método se adequa a realidade de uma empresa de envase de água de coco, localizada em Petrolina, região do Vale do São Francisco pernambucano. Os dados utilizados foram sobre a quantidade de frutos, coco verde, comprada e que é afetada pela sazonalidade. Foram selecionados quatro modelos com base nos parâmetros de erros: Média Absoluta de Erro (MAE), Média Absoluta Percentual de Erro (MAPE), Quadrático Médio da Raiz (RMSE) e Escalar Médio Absoluto (MASE). Dentre os modelos de previsão utilizados, cinco tiveram melhor desempenho com base nos parâmetros de erros. Os modelos selecionados foram: Short-Term Load Forecasting (STLF) (MAPE=39,44034; MAE=100677,00; RMSE=124480,40; MASE=0,4908916); Autorregressão Neural (MAPE=32,91682; MAE=106726,00; RMSE=130103,90; MASE=0,5203861); Holt-Winters Multiplicativo (MAPE=41,90111; MAE=101470,20 ,RMSE=134650,50; MASE=0,4947594); Holt-Winters Aditivo (MAPE=44,7642 ,MAE=107720,00; RMSE=136886,30; MASE=0,5252326); Arima de Box & Jenkins (MAPE=38,91704; MAE=108053,50; RMSE=142522,40; MASE=0,5268587). Vale ressaltar que a produção foi afetada em 2020 pela pandemia do COVID-19. Ainda assim, o estudo conseguiu um bom resultado e o modelo de previsão que teve melhor desempenho foi o de Autorregressão Neural com um erro de 11,86% no acumulado dos 5 meses analisados, o que representa uma diferença de 202604 unidades de coco entre o modelo previsto e os dados reais. Com isso, a empresa em questão terá mais assertividade na tomada de decisão em relação a sua produção, o que resultará num melhor desempenho financeiro.

Palavras-chave: Planejamento e controle, Modelos de previsão de demanda, Autorregressão Neural.

ABSTRACT

With the need to improve their performance and remain competitive in the market, companies are looking for tools to support their decision-making in the strategic sphere. Thus, the demand forecast has become a great ally and has been very useful for those who understand the importance of living together and being prepared for the fluctuations in the company's demand needs over time. This work brought a quantitative and computational supply & demand approach in order to analyze which method is best suited to the reality of a coconut water bottling company, located in Petrolina, in the São Francisco Valley region of Pernambuco. The data used were on the amount of fruit (green coconut) purchased and which is affected by seasonality. Four models were selected based on error parameters: Mean Absolute Error (MAE), Mean Absolute Percentage Error (MAPE), Root Mean Square (RMSE) and Scalar Mean Absolute (MASE). Among the forecast models used, five performed better based on the error parameters. The selected models were: Short-Term Load Forecasting (STLF) (MAPE = 39,44034; MAE = 100677.00; RMSE = 124480.40; MASE = 0.4908916); Neural autoregression (MAPE = 32.91682; MAE = 106726.00; RMSE = 130103.90; MASE = 0.5203861); Multiplicative Holt-Winters (MAPE = 41.90111; MAE = 101470.20, RMSE = 134650.50; MASE = 0.4947594); Holt-Winters Additive (MAPE = 44,7642, MAE = 107720.00; RMSE = 136886.30; MASE = 0.5252326); Arima by Box & Jenkins (MAPE = 38.91704; MAE = 108053.50; RMSE = 142522.40; MASE = 0.5268587). It is worth nothing that production was affected in 2020 by the COVID-19 pandemic. Nevertheless, the study showed a good result and the prediction model that had the best performance for the Neural Autoregression with an error of 11.86% within over 5 months accumulated of calculation, which represents a difference of 202,604 coconut units between the predicted model and the actual data. Summary, the company in question will have more assertiveness in decision making in relation to its production, which will result in a better financial performance.

Keywords: Planning and Control, Demand Forecast Models, Neural Autoregression.

LISTA DE FIGURAS

Figura 1 – Série temporal histórica da quantidade de coco comprada	48
Figura 2 – Representação gráfica do método STLF	51
Figura 3 – Pressupostos dos erros do método STLF	51
Figura 4 – Representação gráfica do método auto regressão neural	53
Figura 5 – Pressupostos dos erros do método auto regressão neural.....	53
Figura 6 – Representação gráfica do método Holt-Winters multiplicativo.....	55
Figura 7 – Pressupostos dos erros do método Holt-Winters multiplicativo.....	55
Figura 8 – Representação gráfica do método Holt-Winters aditivo	57
Figura 9 – Pressupostos dos erros do método Holt-Winters aditivo	57
Figura 10 – Representação gráfica do método Box & Jekins.....	59
Figura 11 – Pressupostos dos erros do método Box & Jekins.....	59

LISTA DE QUADROS

Quadro 1 – Introdução do coqueiro no Brasil.	20
Quadro 2 – Desenvolvimento do coqueiro híbrido.	21

LISTA DE TABELAS

Tabela 1 – Principais características das variedades de coqueiro.	22
Tabela 2 – Área colhida, produção e rendimento de coco-da-baía por região, e estados.....	25
Tabela 3 – Dados históricos da quantidade de coco.....	Erro! Indicador não definido.
Tabela 4 – Resumo dos resultados dos erros médios dos modelos	49
Tabela 5 – Resultado do método STLF	50
Tabela 6 – Resultado do método auto regressão neural	52
Tabela 7 – Resultado do método Holt-Winters multiplicativo.....	54
Tabela 8 – Resultado do método Holt-Winters aditivo	56
Tabela 9 – Resultado do método Box & Jekins	58
Tabela 10 – Comparação entre os erros dos métodos e demanda real	Erro! Indicador não definido.

LISTA DE ABREVIATURAS E SIGLAS

Ceagesp – Companhia de Entrepostos e Armazéns Gerais de São Paulo

Ceplac – Comissão Executiva do Plano da Lavoura Cacaueira

CHESF – Companhia Hidrelétrica do São Francisco

EMPARN – Empresa de Pesquisa Agropecuária do Rio Grande do Norte

FAOSTAT – Food and Agriculture Organization of the United Nations

IRHO – Institute de Recherches Pour Les Huiles et Oleagineux

MAE – Média Absoluta de Erro

MAPE – Média Absoluta Percentual de Erro

MASE – Média Escalar Médio Absoluto

RMSE – Média Quadrático Médio da Raiz

STLF – Short-Term Load Forecasting

SUMÁRIO

1. INTRODUÇÃO	14
1.1 JUSTIFICATIVA	15
1.2 PROBLEMA DE PESQUISA	17
1.3 OBJETIVOS DA PESQUISA	17
1.3.1 Objetivo Geral	17
1.3.2 Objetivos Específicos	17
1.4 ESTRUTURA DO TRABALHO	17
2. REFERENCIAL TEÓRICO	19
2.1 COQUEIRO E SUA PRODUÇÃO	19
2.1.1 Características das variedades e mercado	21
2.1.2 Produção: mundial e nacional	25
2.2 ADMINISTRAÇÃO DA PRODUÇÃO	27
2.2.1 Planejamento e controle	28
2.2.2 Previsão de demanda	29
2.3 TÉCNICAS DE PREVISÃO DE DEMANDA	31
2.3.1 Abordagem qualitativa	31
2.3.1.1 Predição	31
2.3.1.2 Opiniões/júri de executivos e abordagem de painel	32
2.3.1.3 Método Delphi	32
2.3.1.4 Estimativas/opinião da força de vendas	33
2.3.1.5 Pesquisa de mercado	33
2.3.1.6 Pesquisa de clientes	34
2.3.1.7 Planejamento de cenários	34
2.3.1.8 Analogia com produtos similares	34
2.3.2 Abordagem quantitativa	34
2.3.2.1 Média móvel simples	35
2.3.2.2 Média móvel ponderada	35
2.3.2.3 Suavização exponencial	36
2.3.2.4 Mínimos quadrados ou regressão linear	36
2.3.2.5 Ajustamento sazonal	36
2.3.2.6 Modelo de Winter	37
2.3.2.7 Modelos casuais	37
2.4 TÉCNICAS DE PREVISÃO DE DEMANDA COMPUTACIONAIS	318
2.4.1 Método de Holt mais Damp	318

2.4.2 Método de Holt-Winters	319
2.4.2.1 Método de Holt-Winters Aditivo.....	39
2.4.2.2 Método de Holt-Winters Multiplicativo	39
2.4.3 Método ARIMA	310
2.4.4 Método de Naive	310
2.4.5 Método de S Naive	41
2.4.6 Método STLF mais ETS (ANN)	31
2.4.7 Método de Splinesf	41
2.4.8 Método de Thetaf	42
2.4.9 Método ETS mais ANN (ou Forecast no software R)	312
2.4.10 Método de Rede Neural Auto Regressivo	42
3. METODOLOGIA	44
3.1 CLASSIFICAÇÃO DA PESQUISA	44
3.2 APRESENTAÇÃO DA EMPRESA	44
3.3 ETAPAS DA PESQUISA	45
3.3.1 Coleta de dados	45
3.3.2 Análise e tratamento dos dados	45
4. RESULTADOS E DISCUSSÃO	47
4.1 DESCRIÇÃO DOS DADOS.....	47
4.2 ANÁLISE E COMPARAÇÃO DA APLICAÇÃO DOS MODELOS DE PREVISÃO DE DEMANDA	48
4.2.1 STLF – short-term load forecasting	51
4.2.2 Modelo Auto Regressão Neural	52
4.2.3 Modelo Holt-Winters multiplicativo	55
4.2.4 Modelo Holt-Winters aditivo	56
4.2.5 Modelo Arima Auto Regressivo de Box & Jekins	58
4.3 DEFINIÇÃO DO MODELO MAIS ADEQUADO	61
5. CONSIDERAÇÕES FINAIS	65
6. REFERÊNCIAS	67
ANEXO A - Modelo de Holt com “Damp”	72
ANEXO B - Modelo de Holt	74
ANEXO C - Modelo de suavização exponencial	76
ANEXO D - Modelo de Forecast	78
ANEXO E - Modelo de Thetaf	80
ANEXO F - Modelo de Naive	82

1. INTRODUÇÃO

A globalização e o conseqüente aumento da competitividade no mercado levou as empresas a se aperfeiçoar e aplicar melhorias em seus processos para enfrentar os desafios e conseguir sobrevivência e lucratividade, principalmente pelas mudanças econômicas que vem ocorrendo nos últimos anos.

Nesse sentido, o planejamento se torna essencial para as organizações, sendo uma atividade comum e inerente para qualquer empresa, independente do ramo de atuação. É nesse processo que ocorre as projeções dos caminhos das ações no futuro com base na necessidade de recursos (SOUZA *et al.*, 2011), para assim alcançar seus objetivos e metas de forma organizada, seja para curtos ou longos prazos. No desenvolvimento do planejamento, é preciso considerar que a capacidade de mensurar e prever mudanças do mercado são essenciais para a tomada de decisão, sendo um ponto crítico (REIS *et al.*, 2015).

No contexto de sistemas produtivos, a previsão acerca de quanto será a demanda dos clientes no futuro possibilita a utilização da capacidade de produção de uma cadeia com efetividade, tendo recursos necessários na quantidade, momento e qualidade adequada. Essa premissa é válida seja para recursos existentes, recursos de aquisição e estoques, e a finalidade esperada é a minimização de custos e investimentos (MANCUZO, 2003; QUEIROZ; CAVALHEIROS, 2003; RITZMAN; KRAJEWSKI, 2004; REIS *et al.*, 2015).

Slack, Chambers e Johnston (2009) argumentam que, devido à grande competitividade e a economia mais globalizada do mercado, não basta saber se a demanda dos produtos ou serviços está em crescimento ou declínio. Por isso, as previsões e a tomada da decisão não devem ser baseadas apenas no conhecimento e/ou insights dos gestores, como geralmente ocorrem e estão ligadas aos efeitos do feedback, e sim devem usar técnicas de previsão (GEOMELOS; XIDEAS, 2014).

Com isso, conhecer o comportamento da demanda e todos seus fatores envolvidos é crucial para organização, pois auxilia na compreensão dos consumidores e do comportamento do mercado. Desse modo, no desenvolvimento das previsões de demanda, é necessário ter e entender muitas informações que envolvam as vendas, sazonalidade, tendências, variações, entre outros fatores, e de praticamente todos os setores da empresa, para melhores resultados da previsão (ROSETTO *et al.*, 2011).

Como pode ser utilizado em todo tipo de organização, a aplicação das técnicas de previsão de demanda tem sido amplamente incorporada nas empresas como diferencial estratégico e estudada em diversos segmentos de mercado: indústria eletrônica (SOUZA *et al.*, 2011), varejo (REIS *et al.*, 2015), indústria alimentícia (ROSSETO *et al.*, 2011; ARAUJO *et al.*, 2018), serviços financeiros (SOUZA; RODRIGUES; PACHECO, 2015), aeroportuária (CONDÉ, 2010), serviços militares (CARVALHO, 2018). Oliveira, Dourado e Mello (2017) aplicaram alguns modelos em uma fábrica de embalagens plásticas, verificando que o método Box-Jenkins possuiu o melhor resultado e se mostrou mais adequado as características, tendências e sazonalidades dessa empresa de acordo com a demanda de seu produto.

Os métodos também são utilizados para outras previsões, como no estudo de Geomelos e Xideas (2014) que utilizaram modelos multivariados e univariados, em um estudo econométrico, para prever preços locais no transporte a granel em mercados petroleiros e graneleiros em um nível desagregado, em que concluíram que os preços estavam estacionários e fatores implicavam no consumo, como a sazonalidade.

Não há o modelo de previsão de demanda ideal para todos, mas a utilização dessa ferramenta de forma adequada auxilia na tomada de decisão em atender as demandas reais dos clientes. Aliado a isso, a particularidade de cada produto e sua relação no mercado explica a dificuldade em ajustar um modelo de previsão de demanda (CASULA, 2012).

Independente do modelo adotado, uma previsão de demanda assertiva é capaz de trazer muitos benefícios para ajudar a empresa no mercado competitivo, muito por conta de tratar e trabalhar de forma qualitativa e/ou quantitativa, ou ainda na combinação das duas. Por isso, é importante haver estudos e aplicação dessa ferramenta nas mais diversas áreas e segmentos de mercado e pelas empresas.

1.1 Justificativa

Atualmente, o Brasil ocupa a quinta posição da produção mundial de coco, sendo assim um dos maiores produtores mundiais e também em área cultivada, mas sendo o que possui maior produtividade. Esses resultados se deu por conta da crescente demanda por água de coco, onde houve a expansão do coqueiro para outras regiões, e nas últimas décadas o aumento na produtividade e produção desse e de outros derivados (BRAINER, 2018).

Brainer (2018) explica que o aumento da produção brasileira foi devido ao aumento da produtividade, mas não acompanhada pela área de cultivo, tendo como fatores: utilização

intensiva de insumos, de tecnologia, implantação de grandes projetos em perímetros irrigados e utilização das variedades de coqueiro, além de novos plantios. Esses processos são explicitados pela reestruturação produtiva do setor que trouxe modernização e novas formas de produção de coco advindos dos incentivos de capital e da pesquisa, resultando na ampliação da quantidade produzida (CAVALCANTE, 2017).

Esses acontecimentos levaram a ampliação das desigualdades entre produtores de coco, pois nem todos possuem acesso e capital para acompanhar as inovações e tecnologias. Com isso, esses produtores menos favorecidos ficam dependentes de insumos da indústria, acarretando na territorialização do capital e risco de alguns não conseguirem permanecer no mercado (CAVALCANTE, 2017).

Mesmo sendo a região de maior produção no Brasil, o Nordeste vem perdendo parte de seus consumidores e tendo baixo desempenho. Além disso, é caracterizada por produtores em comunidades litorâneas e produção de pequenas quantidades sem a utilização de quaisquer insumos. Por isso, vem passando por ajustes, como renovação de coqueirais, utilizando mais variedades, conquistando novos mercados, para não obter mais resultados ruins (CAVALCANTE, 2017; BRAINER, 2018).

Nesse sentido, o planejamento é essencial para que os *stakeholders* desse setor possam desenvolver e manter estratégias para reduzir custos, melhorias nos processos produtivos e de negócios e em tomada de decisões. Tendo assim a possibilidade de determinar quanto, quando e como produzir, em que reflete a demanda futura e pode ser ponto chave para alcançar bons resultados.

Conseguindo estruturar o dimensionamento da quantidade de produtos que precisa produzir e, conseqüentemente, os recursos necessários, será possível atender as demandas futuras com qualidade, no tempo certo, com redução de custos e riscos, maior controle de estoque e colocar a empresa em patamar de se adaptar as situações que podem ocorrer.

Assim, a previsão de demanda é ponto inicial para desenvolver diversos planos, como os de capacidade, financeiros, estoques e produção, venda, além de recursos como de mão-de-obra e compras (TUBINO, 2009).

Desta forma, o estudo se justifica ao passo que será aplicado o método de previsão de demanda em uma empresa de um setor que passa por desafios no mercado e vem se desenvolvendo. Assim, a obtenção assertiva de uma previsão poderá auxiliar no planejamento e no desempenho da empresa e na produção de coco.

1.2 Problema de pesquisa

Verificando a atual conjuntura da produção de coco e seu mercado aliado aos benefícios da aplicação de técnicas e estratégicas das áreas da Engenharia de Produção aos processos, como no caso da previsão de demanda no planejamento das organizações, se mostra interessante realizar um estudo unindo essas partes.

A empresa do estudo de caso se encontra no interior de Pernambuco e adquire o fruto “coco” (matéria-prima para produção) de pequenos produtores na região. Sendo um local com oportunidades para melhorias e desenvolvimento de estudos em que traga contribuições acadêmicas e práticas.

Diante do exposto, surge o problema de pesquisa que pretendesse investigar: **qual método de previsão de demanda melhor se adequa em uma indústria de produção de derivado de coco?**

1.3 Objetivos da pesquisa

1.3.1 Objetivo Geral

O objetivo geral deste trabalho é aplicar a previsão de demanda na produção do derivado de coco (água de coco) em uma agroindústria, apresentando o método que melhor se adequa ao estudo de caso.

1.3.2 Objetivos Específicos

- Coletar e analisar os dados históricos da produção de água de coco da agroindústria;
- Identificar fatores que afetam a demanda da produção de coco na agroindústria;
- Aplicar métodos de previsão de demanda;
- Realizar uma avaliação comparativa entre os métodos;
- Definir o mais adequado;
- Demonstrar a previsão e o impacto para produção de coco (fruto).

1.4 Estrutura do trabalho

A estrutura do trabalho está dividida em 5 capítulos, em que serão explanados adiante:

- Capítulo 1: apresenta a definição do estudo e sua contextualização, assim como os objetivos e as informações da estruturação em capítulos do trabalho;

- Capítulo 2: trata do referencial teórico, em que aborda os conceitos e informações de assuntos em volta do tema, tais como: o coqueiro e sua produção, a administração da produção e as técnicas de previsão de demanda;

- Capítulo 3: aborda a metodologia, com a caracterização do estudo e as etapas da pesquisa;

- Capítulo 4: mostrará os resultados obtidos, constatando o alcance dos objetivos e a contribuição da pesquisa, apresentando o método e a discussão acerca da previsão da demanda;

- Capítulo 5: traz as considerações finais sobre o objetivo proposto, ainda as limitações e sugestão de trabalhos futuros.

2. REFERENCIAL TEÓRICO

2.1 Coqueiro e sua produção

O coqueiro (*Cocos nucifera* Linnaeus) é uma monocotiledônea (*Monocotyledoneae*) pertencente à família *Palmae* e subfamília *Cocoideae*, sendo uma das palmeiras tropicais mais difundidas mundialmente, encontrada em todos os continentes, originada no Sudoeste Asiático (SOUZA, 2006; SILVA, 2014).

Segundo Andrade *et al.* (2004), a origem do coqueiro ocorreu nas ilhas entre os oceanos Índico e Pacífico, onde, provavelmente, o fruto foi levado para a Índia e depois para África, seguindo para as Américas e demais continentes.

O fruto do coqueiro é o “coco”, que é uma drupa, possuindo uma estrutura no interior oca, que contém a água (albúmen líquido), e progressivamente transforma-se em albúmen sólido, envolvido pela parte mais dura (endocarpo), a casca (mesocarpo) – a maior parte do fruto e um fino exocarpo de cor verde, amarelo ou marrom, respectivamente (ARAGÃO, 2002 *apud* SILVA, 2014). A palmeira possui um sistema radicular fasciculado, não possuindo assim uma raiz principal, característica das monocotiledôneas, com as raízes primárias mais grossas – responsáveis pela sustentação (SOUZA, 2006).

No Brasil, a espécie possui duas principais variedades: *Typica* (coqueiro gigante) e *Nana* (coqueiro anão). Ainda, há os híbridos intervarietal que são resultados dos cruzamentos dessas variedades. (ARAGÃO; RAMOS; ALVES, 2016; BRAINER, 2018).

Devido as suas múltiplas funcionalidades em gama de produtos e o aproveitamento de suas partes, é um recurso vital para humanidade, tendo reconhecimento mundial e, em muitos países, conhecido como “árvore da vida” (MARTINS; JESUS JUNIOR, 2014; SILVA, 2014; MARTINS *et al.*, 2016).

A chegada do coqueiro no Brasil ainda é um conhecimento incerto, mas a principal hipótese é que tenha vindo pela África, em meados dos anos 1950, por Cabo Verde até o estado da Bahia, tendo assim denominado como coco-da-baía (SILVA, 2014; BRAINER, 2018). Inicialmente, se expandiu pelo litoral nordestino devido a ser típica de clima tropical, tendo encontrado condições climáticas ideais para cultivo e, posteriormente, se disseminou por quase todos os estados (BRAINER, 2018).

Siqueira, Aragão e Tupinambá (2002) abordam a introdução do coqueiro no Brasil de acordo com a sua variedade, tendo ocorrido diversas introduções historicamente. O Quadro 1,

apresenta o resumo da introdução dos coqueiros gigante e anão. O Quadro 2, o desenvolvimento do híbrido.

Quadro 1 – Introdução do coqueiro no Brasil.

Variedade	Origem/ano	Detalhes
Gigante	Índia ou Sri Lanka (meados de 1553)	Importada das Ilhas de Cabo Verde, sendo está hipótese ser devido a semelhança entre o coqueiro do oeste da África e o coqueiro Gigante de Moçambique. O local de plantio foi na Bahia.
	Kuala Lumpur (1939)	A variedade foi importada por Paulo Burle e Carlos Browne da Malásia e plantadas em Cabo Verde-RJ.
	Sudoeste Asiático (1978)	Foi realizada pela Ceplac em convênio com o IRHO (<i>Institute de Recherches Pour Les Huiles et Oleagineux</i>), sendo importada da Costa do Marfim e plantada em Uma-BA.
	Sudoeste Asiático (1981)	A Sococo importou o coco gigante da Costa do Marfim para montar campo de produção de híbridos no Pará.
	Malásia, Taiti, Salomão, Fiji, Tonga, Vanuatu (1983)	A Embrapa importou diversas populações do coco gigante (Malásia, Polinésia, Rennel, Rotuma, Tonga e anuatu) da Costa do Marfim para constituir o Banco Ativo de Germoplasma, em Neópolis-SE.
Anão	Índia (1925)	A introdução é atribuída ao Dr. Arthur Neiva (pesquisador da Fundação Osvaldo Cruz) e Miguel Calmon (Ministro da Agricultura). Após viagem de Neiva ao Oriente e para estudo do coqueiro, Calmon apoiou a importação de várias mudas do anão verde, que foram distribuídas pelos estados do Norte, na Bahia e no Rio de Janeiro.
	Malásia (1938 e 1939)	Paulo Burle e Carlos M. Browne introduziram no estado do Rio de Janeiro várias populações, sendo a primeira de cor amarela, e posteriormente vermelha, verde e uma variedade gigante (chamada de caboclo).
	Malásia e Camarões (1978)	A Ceplac em convenio com o extinto IRHO (França) importou sementes de anão amarelo da Malásia e vermelho de Camarões para Ilhéus-BA.
	Malásia (1981)	A Sococo importou o anão amarelo da Costa do Marfim, visando implantar uma produção de híbridos em Moju-PA.

	Malásia e Camarões (1982)	A Embrapa trouxe para sua coleção em Sergipe o anão amarelo e vermelho da Malásia e anão vermelho de Camarões, através da Costa do Marfim.
--	---------------------------	--

Fonte: Martins (adaptado de WEINBERG e GOULD, 2001, p. 382) (2005).

Quadro 2 – Desenvolvimento do coqueiro híbrido.

Ano	Detalhes
1938 a 1951	José Pereira de Miranda Júnior desenvolveu o 1º programa de melhoramento com coqueiro no Brasil, onde realizou prospecções, autopolinizações, cruzamentos e estudos da biologia floral e caracterização de frutos. Mas seus trabalhos foram de pequena escala e não tiveram continuidade.
1963	A Sudene, com a criação do Campo de Jiquí-RN, utilizou-se da plantaçãõ adulta e substituiu uma linha de gigantes por duas linhas de anão verdes, procurando congrega as qualidades das duas variedades.
1982	A Sococo estabeleceu um campo de produção de semente a partir do cruzamento do anão amarelo da Malásia com o gigante do Oeste Africano.
1983	A Empresa Pernambucana de Pesquisa Agropecuária instalou sementes híbridas de coqueiros anão amarelo e anão vermelho (progenitores femininos) e gigante do Brasil (genitor masculino). Devido à escassez de recursos, os trabalhos não tiveram continuidade.
1990	A Embrapa Tabuleiro Costeiros e a Embrapa firmaram convênio para recuperação do campo de produção de sementes híbridas de Jiquí-RN. Desde 1995 a Embrapa segue a frente da coordenação e firmou acordo com a Empresa Metro do Ceará para a produção de híbridos, que fornece sementes para todo Brasil. Além disso, há estudos realizados pelo pesquisador Wilson Menezes Aragão (Embrapa Tabuleiros Costeiros) através de uma rede nacional de avaliação de cultivares de coqueiro nos estados do Pará (Sococo), Pernambuco (Embrapa Semi-árido e Petrolina), Alagoas (Maragogi), Bahia (CEPLAC em Una), Minas Gerais (Uberaba), São Paulo (Bebedouro) e no Paraná (Paranavaí).

Fonte: Martins (adaptado de WEINBERG e GOULD, 2001, p. 382) (2005).

2.1.1 Características das variedades e mercado

Os cultivadores de coqueiro, na maioria dos países, destinam-se a produção de frutos, explorando comercialmente a polpa seca (copra) na produção de óleo e coco desidratado. Em relação ao Brasil, os cultivos de coqueiro destinam-se à agroindústria para produção de coco ralado e leite de coco, além da água de coco (MARTINS; JESUS JUNIOR, 2014).

A destinação da variedade cultivada na produção depende de alguns fatores, como as de seu conjunto de características (MARTINS; JESUS JUNIOR, 2014; BRAINER, 2018), pois envolve a área de plantio, características estruturais e físicas do coqueiro, entre outros. A Tabela

1 apresenta as principais características agrônômicas das variedades mais utilizadas no Brasil (gigante, anão e híbrido).

Tabela 1 – Principais características das variedades de coqueiro.

Características	Variedades		
	Anão	Gigante	Híbrido
Início da floração (ano)	2 a 3	5 a 7	3 a 4
Vida útil (ano)	30 a 40	60 a 80	50 a 60
Tamanho do fruto	Pequeno	Grande	Intermediário
Crescimento	Lento	Rápido	Intermediário
Porte (m)	8 a 10	35	20
Produção de frutos (frutos/planta/ano)	150 a 200	60 a 80	130 a 150
Peso do fruto (g)	900	1400	1200
Peso da noz (g)	550	800	700
Peso médio albúmen sólido (g)	250	350	400
Produtividade copra (kg)	3 a 4 mil	2 a 2,5 mil	4 a 5 mil
Teor médio de óleo (%)	25,41	650 a 900	1300 a 1700
Teor médio de ácido láurico (%)	50,16	52,04	50,65
Produtividade de ácido láurico (Kg/há)	380 a 510	650 a 900	1300 a 1700
Produção de água (ml)	200 s 300	500 ou mais	400 a t500
Destino produção	<i>In natura</i>	<i>In natura</i>	<i>In natura</i>
	Agroindústria	Agroindústria	Agroindústria

Fonte: Adaptado de Martins e Jesus Júnior (2014) e fontes(2002).

A produção está embasada nos segmentos de coco seco e coco verde, sendo todas as partes do fruto do coqueiro possui aproveitamento e, assim, comercializadas em grande gama de produtos, tanto na forma *in natura* quando industrial (MARTINS; JESUS JUNIOR, 2014; BRAINER, 2018). A colheita ocorre em todos os meses no ano, não havendo uma estação climática definida, que ocorre em dois períodos de maturação, de acordo com a destinação no mercado (BRAINER, 2018).

As exigências climáticas do coqueiro estão relacionadas em ser uma planta tropical, tendo condições favoráveis em latitudes 20° N e 20° S, possuindo algumas peculiaridades:

requer climas quentes e úmidos, sem grandes variações de temperatura (em média 27°C); regime pluviométrico ideal com precipitação anual de 1500mm; insolação de 2000 horas anuais (mínimo de 120 horas por mês); ventos fracos e moderados favorecem o desenvolvimento; melhor adaptação a solos leves e bem drenados, mas permitindo suprimento de água nas plantas, e solos arenosos (PASSOS, 2016).

Resumidamente, o coco verde possui destinação ao mercado de água de coco (obtido na variedade anão) e o coco seco na produção de coco ralado (proveniente da variedade Gigante), como também leite de coco e vários outros derivados, já o híbrido destina-se as duas produções pelos dois segmentos (MARTINS; JESUS JUNIOR, 2014; BRAINER, 2018). Na produção de coco verde, o fruto é colhido ainda imaturo, entre 6 a 7 meses de idade, onde o albúmen sólido inicia a formação, possuindo maior rendimento de água e sabor mais agradável ao consumidor. Quando destinado ao mercado de coco seco, os frutos devem ser colhidos entre 11 e 12 meses (fase de maturação), quando assim o albúmen sólido está totalmente formado (MARTINS; JESUS JUNIOR, 2014).

Há utilização das partes do coco seco em diversas aplicações, desde a casca até o albúmen sólido. Cuenca (2016) aborda algumas dessas aplicações no Brasil:

- Albúmen sólido ou polpa (parte branca): consumo *in natura*; pela indústria na produção de coco ralado, leite de coco, fabricação de bebidas, margarinas, ração animal, álcool graxo, glicerina; dentre outros;
- Mesocarpo (fibras da casca): produção de fibras marrons longas e curtas; como matéria-prima na agricultura, fabricação de colchoes, bancos de veículos, cordas, entre outros, devido a elasticidade, durabilidade e resistência a tração e umidade;
- Óleo de coco: principal fonte de ácido láurico para indústria de detergentes e sabões, devido a ser biodegradável e características espumante, bactericida e geminizada; ainda pode ser aplicado na indústria de cosméticos e alimentos.

O coco verde é comercializado pelo seu fruto inteiro, ainda verde, tendo seu maior mercado a água de coco, sendo predominantemente comercializada *in natura* ou envasada (CUENCA, 2016). Há também aplicação do pó da casca de coco verde como substrato agrícola, na confecção de vasos e placas utilizadas em jardins (FONTENELE, 2005 *apud* BRAINER, 2018).

A produção de coco está localizada a maior parte na região Nordeste e é caracterizada por pequenos e médios produtores, e nas demais regiões, geralmente, por grandes e médios produtores, grandes empresas e indústrias agrícolas. O coqueiro possui a peculiaridade de ser cultivado em sistemas *agrosilvipastoris* (seu cultivo permite convívio com outras culturas e criação de animais), sendo benefício para outras fontes de rendas em pequenos produtores (MARTINS *et al.*, 2016; BRAINER, 2018).

Os principais fatores que influenciam no custo final e na qualidade dos produtos, tanto em relação ao seco quanto ao verde, são o transporte e o acondicionamento da carga, devido as grandes distâncias percorridas via terrestres entre os principais produtores, região Nordeste, e consumidores, regiões Sudeste e Sul. Assim, o valor final do produto se torna mais caro e ainda as perdas ocorridas no trajeto e deformações e manchas no fruto (CUENCA, 2016; BRAINER, 2018).

Outro aspecto fundamental é a sazonalidade dos preços do coco, seja seco ou verde, pois seu conhecimento leva a entender as forças de mercado (oferta e demanda). Em relação ao coco seco, no Nordeste, em tempos chuvosos tende a oferta ser menor que a demanda, aumentando o valor do preço, e meses mais secos a oferta e demanda aumentam, sendo a oferta superior, influencia a baixar o preço. Ao mercado de coco verde, o que influencia é o consumo *in natura*: de outubro a março, a oferta e demanda são maiores devido as férias escolares e influência do turismo no litoral; no período de abril a setembro, acontece o inverso, por causa das chuvas e tendo oferta menor, o produto sofre uma queda de preço (CUENCA, 2016).

Cuenca (2016) também apresenta esse ponto na região sudeste, através do contexto na Companhia de Entrepostos e Armazéns Gerais de São Paulo (CEAGESP): de junho a outubro, tem-se os melhores preços para coco seco por causa do período de chuvas retrai no mercado do Nordeste; já o coco verde, tende a crescer a partir de novembro, com seu máximo em março.

Além disso, a importação de produtos, como coco seco ralado desidratado, afeta diretamente os preços dos frutos, até mesmo o verde. E com a expiração das medidas de salvaguardas (criada em 2002) em 2012, é uma potencial ameaça. Esse fator afeta de forma negativa na oferta e demanda do mercado nacional, acarretando a diminuição do preço no mercado (CUENCA, 2016).

2.1.2 Produção: mundial e nacional

A produção mundial de coco, atualmente, gira em torno de 61,1 milhões de toneladas, com 12 milhões de hectares de área colhida. Sendo os principais produtores a Indonésia, Filipinas, Índia, Sri Lanka e Brasil, respectivamente. Os três primeiros países correspondem a 72,6% da área e 72,8% da produção mundial, e o Brasil tendo a sexta maior área e quinta maior produção. Esses dados nacionais refletem decréscimo de 21,6% na área e 17,6% na produção, por conta de adversidade climáticas que provocaram a morte de coqueirais na região Nordeste (BRAINER, 2018).

De acordo com dados da *Food and Agriculture Organization of the United Nations* (FAOSTAT) houve aumento da produção mundial em 1,2% entre 2010 e 2017, mas decréscimos nos rendimentos devido a problemas climáticos, como o tufão em 2014 nas Filipinas (MARTINS; JESUS JUNIOR, 2014; BRAINER, 2018). Ainda, o Brasil possui maior produtividade (10.863 kg/ha), tendo tendência contrária aos rendimentos mundiais (média de 4.952 kg/ha). Isso pode ser explicado pela tecnologia instalada na cultura, sistemas intensivos de cultivo e a melhoria nas variedades de anão e híbrido (BRAINER, 2018).

Atualmente, o Brasil possui 198,7 mil hectares de área, com produção de 1.564 toneladas de frutos e rendimento de 7.873 (frutos/ha). Mesmo havendo queda na área (-5,1%), a produção e o rendimento aumentaram em 6,1% e 11,8, respectivamente. A região Nordeste possui a maior área colhida (81,3% do total) e maior produção (71,2 do total%), mas com um dos menores rendimentos. Em caso contrário, as regiões Sul e Centro-Oeste possuem os maiores rendimentos de 15.381 frutos/ha e 12.144 frutos/ha, respectivamente, mesmo com menores áreas (Tabela 2).

Tabela 2 – Área colhida, produção e rendimento de coco-da-baía por região, e estados..

País, Regiões e Estados	Área colhida (ha)		Quantidade produzida (toneladas)				Rendimento (frutos/ha)			
	2017	2018	18-19		18-19		18-19		18-19 (%)	
			19	(%)	2017	2018	19	2017		2018
Brasil	209.406	198.715	-5,1		1.473.426	1.564.500	6,1	7.036	7.873	11,8
Nordeste	172.547	161.627	-6,3		1.067.193	1.114.359	4,4	6.185	6.895	11,4
Norte	20.569	20.857	1,4		186.528	206.954	10,9	9.068	9.923	9,4
Sudeste	14.625	14.573	-0,3		200.684	224.153	11,7	13.722	15.381	12
Centro-Oeste	1.430	1.414	-0,1		17.528	17.172	-2	12.257	12.144	-0,9

Sul	235	244	3,8	1.493	1.862	24,7	6.353	7.631	20,1
Bahia	47.638	44.287	-7	350.868	344.782	-1,7	7.365	7.785	5,7
Ceará	38.965	38.328	-1,6	186.732	254.161	36,1	4.792	6.631	38,3
Sergipe	32.194	25.328	-21,3	201.759	174.364	-13,5	6.267	6.884	9,8
Alagoas	22.888	21.343	-6,7	89.686	77.448	-13,6	3.918	3.629	7,3
Pará	18.595	18.511	-0,4	173.788	191.825	10,3	9.346	10.363	10,8
Rio Grande do Norte	15.140	16.030	5,8	69.076	70.347	1,8	4.562	4.388	-0,3
Espirito Santo	9.346	9.655	3,3	118.476	150.089	26,6	12.677	15.545	22,6
Pernambuco	6.435	7.398	14,9	115.129	139.516	21,1	17.891	18.859	5,4
Paraíba	6.415	6,041	-5,8	36.751	34.594	-5,8	5.729	5.727	-0,03
Rio de Janeiro	2.808	2.360	-16	45.797	38.594	-15,7	16.309	16.290	-0,1

Fonte: IBGE (2018).

O baixo desempenho no Nordeste é devido as restrições hídricas tanto para produção, como também a predominância de sistema de cultivo semiextrativista, com baixa fertilidade e sem implementação de práticas de manejo cultural, e ainda a variedade de coco explorada – em sua maioria o coqueiro gigante com baixos preços e pouca remuneração ao produtor – e pouca tecnologia empregada (MARTINS; JESUS JUNIOR, 2014; BRAINER, 2018). Já nas regiões Sudeste e Centro-Oeste a predominância é de coqueiro anão para produção de água de coco, tendo assim maiores remunerações, e Norte com variedades híbrida e gigante (BRAINER, 2018).

Em relação aos estados, os maiores produtores são Bahia, Ceará e Pará, conforme Tabela 2, com 22%, 16,2% e 12,2% do total. A Bahia ainda possui maior área colhida (44287 ha) e com melhora de 5,7% de seu rendimento em relação a 2017, mas ainda possuindo baixo rendimento se comparado com outros estados. O Ceará cresceu em 36,1% sua produção, ultrapassando Sergipe para ser segunda maior produtora, e 38,1% seu rendimento – mesmo assim possui baixo rendimento. Já o Pará produziu 191,8 milhões, tendo melhora de 10,3%, e sendo a quinta maior área (18.511ha), é ainda a maior área contínua cultivo de coco do mundo (BRAINER, 2018).

Destaque para Pernambuco, que possui o maior rendimento entre os estados (18.859 frutos/ha de toneladas) e é o sexto maior produtor nacional, Rio de Janeiro com 16.309 frutos/ha toneladas, sendo o nono maior produtor, e o Espirito Santo com 15.545 frutos/ha toneladas de rendimento e sendo quinto maior produtor. (Tabela 2). Martins e Jesus Júnior (2014), explicam que esses dois últimos estados têm esse resultado devido à variedade de coco verde, o sistema

de produção adotado e a aplicabilidade na indústria. Já Pernambuco é por causa da alta produtividade na região irrigada do Vale do São Francisco.

Com ênfase em municípios, os maiores produtores seguem os mesmos de 2017 e 2018, e possuem características para explicação: Moju-PA, se encontra a maior área de cultivo contínuo de coqueiros híbridos; Conde-Ba é o segundo maior produtor com 20% da produção do estado; Petrolina-PE e Juazeiro-BA, possuem alto rendimento pelo cultivo serem irrigados (proveniente do perímetro Irrigado Nilo Coelho) e produção do coqueiro anão; e Rodelas-BA, visto que sua produção é proveniente do perímetro irrigado instalado pela CHESF e plantada o coqueiro anão (BRAINER, 2018; IBGE, 2019).

2.2 Administração da produção

A administração da produção é a atividade responsável pelo gerenciamento dos recursos do processo de transformação para desenvolver e entregar produtos e serviços com a exigência definida pelo mercado (KRAJEWSKI; RITSMAN; MALHOTRA, 2009; SLACK; JONES; JOHNSTON, 2018). Dentro desta atividade, há a função de produção – podendo ter nomes variados, a depender da empresa, responsável por gerenciar. E por todas as organizações produzirem algum produto, seja serviços ou bens, todas possuem a função de produção (SLACK; JONES; JOHNSTON, 2018).

Além dessa função, Slack, Jones e Johnston (2018) abordam que há mais duas centrais (marketing e desenvolvimento de produto/serviço), de qualquer organização, e outras consideradas de apoio. Levando para prática, essas funções não possuem fronteiras bem definidas, sendo assim fundamental que as fronteiras não afetem negativamente a eficiência dos processos, e sim tenham cooperação para garantir o desempenho organizacional (SLACK; JONES; JOHNSTON, 2018).

Enquanto as funções centrais atuam sobre o contexto atual da produção e como juntar para necessidades do negócio; as de apoio se relacionam em entender as necessidades da produção e ajudar a satisfazer (SLACK; JONES; JOHNSTON, 2018). Todas essas relações refletem como a administração de produção afeta na estratégia e objetivos da organização e é um conjunto de decisões (aspecto inerente das atividades) (KRAJEWSKI; RITSMAN; MALHOTRA, 2009).

De acordo com Krajewski, Ritsman e Malhotra (2009), para uma administração efetiva é essencial uma coordenação interfuncional, ou seja, que tenha abrangência das várias áreas

funcionais. Isso é devido a existir relação forte entre as áreas, como marketing, financeiro, recursos humanos, com as operações, que precisam se interagir para ocorrer a produção dos produtos e serviços. Como no caso da previsão de demanda do marketing, que norteia o planejamento do ritmo e da capacidade de produção (KRAJEWSKI; RITSMAN; MALHOTRA, 2009).

Fatores relacionados a demanda veem impactando as atividades da administração da produção nos últimos anos, levando a encararem novos desafios, como aumento de concorrência, expectativas dos clientes por qualidade e variedade, novas tecnologias, entre outros. Isso é resultante da globalização e pressões por causa dos custos, e resulta em mudanças nas operações e no mercado (SLACK; JONES; JOHNSTON, 2018).

A maneira de encarar esses desafios é transformá-los em oportunidades que possibilitem melhorar processos, agregação de valor e/ou criar novos produtos/processos/serviços inovadores, para maximizar sua competitividade no mercado (KRAJEWSKI; RITSMAN; MALHOTRA, 2009).

A importância da administração da produção se dá pelo fato de todos os setores – funções centrais e de apoio – envolverem processos e conjuntos de recursos, que é essencial seu gerenciamento para obter eficiência e eficácia no desempenho da organização e, conseqüentemente, entregar os produtos ao consumidor e mercado.

No geral, a administração da produção constitui-se de quatro atividades: direcionar as operações e processos; no projeto, configurar processos, produtos e serviços; planejar e controlar, no desenvolvimento, as operações no seu caminho; e entregar, tendo a melhoria da capacidade da operação (SLACK; JONES; JOHNSTON, 2018).

2.2.1 Planejamento e controle

Quando há as demandas advindas do mercado e consumidores/clientes, é necessário que a organização obtenha os sistemas, procedimentos e decisões para operacionalizar seus recursos e realizar as entrega. As atividades que compreendem esses pontos consistem em planejamento e controle (SLACK; JONES; JOHNSTON, 2018).

O planejamento está relacionado a formalizar o que deve acontecer em tal futuro, em certo período de tempo, com tais expectativas; já o controle, lida no processo após a implementação em mudanças e/ou modificações que ocorram e possíveis intervenções (SLACK; JONES; JOHNSTON, 2018).

É essencial haver nos planos o equilíbrio entre a demanda e os suprimentos, que repercutem a previsão da demanda e os recursos necessários para satisfazer a demanda estabelecida, respectivamente. Para isso, é feito o planejamento de vendas e operações, que pode ter outras denominações, dependendo do setor (KRAJEWSKI; RITSMAN; MALHOTRA, 2009).

Na construção dos planos são usadas as previsões de demanda, seja em prazos longo, médio ou curto (SLACK; JONES; JOHNSTON, 2018):

- Longo prazo: usa previsões de demanda agregadas, com metas financeiras e de volume, que envolve o que pretende fazer, quais recursos utilizar e objetivos a atingir com ênfase mais no planejamento;
- Médio prazo: previsões de demanda parcialmente desagregadas com planejamento e controle mais detalhados, avaliando a demanda global que a produção deve atender, parcialmente;
- Curto prazo: previsões totalmente desagregadas ou demanda real, os recursos já bem definidos e com difícil mudanças a serem feitas, mas com possíveis intervenções, tendo que avaliar a demanda de forma desagregada.

Assim, a previsão de demanda é um dos trabalhos iniciais para o planejamento, pois a partir dessas previsões serão feitas tomadas de decisões sobre a visão do futuro da organização. Sendo considerada uma principal fonte de informações para a atividade de planejamento e controle da produção (FERNANDES; GODINHO FILHO, 2010).

2.2.2 Previsão de demanda

Para determinar os recursos da produção, as empresas não esperam obter os pedidos de recebimentos, normalmente, pois os clientes têm a expectativa da entrega em certo período de tempo (que não é preciso). Por isso, que a organização precisa antecipar a demanda de seus produtos e, assim, garantir a capacidade de produção (MANCUZO, 2003). Esse processo é conceituado como previsão de demanda.

A previsão de demanda são modelos de estimativas para visão do mercado, buscando entender seu comportamento, ou seja, são estimativas do potencial de compra e venda do mercado (CORRÊA; CORRÊA, 2009). Assim, a previsão fornece informações e dados que permitem os responsáveis pelo planejamento tomar decisões sobre o fato, antes que ele aconteça.

A previsão de demanda, normalmente, advém do *marketing*, mas é um processo interfuncional, pois todos os setores necessitam de previsões, que são informações críticas para planos de negócios: o financeiro, utiliza para projetar orçamentos e fluxos de caixa; os recursos humanos, antecipar a contratação e treinamento; no marketing, é fundamental para previsões de vendas; a operação, para planejar níveis de produção, aquisição dos recursos, estoque e cronograma (KRAJEWSKI; RITSMAN; MALHOTRA, 2009). Sendo assim, um pilar no planejamento estratégico da organização na produção, vendas e finanças (TUBINO, 2009; FERNANDES; GODINHO FILHO, 2010).

No geral, as previsões auxiliam na organização dos recursos para o processo de transformação, a programação de recursos já existentes e para aquisição de novos recursos, possibilitando na programação a utilização da capacidade de forma eficiente, redução do tempo de reação dos clientes e diminuição de estoque (RITZMAN; KRAJEWSKI, 2004).

Realizar previsões no ambiente de negócios é passível de erros diante a complexidade da ação, porém são necessárias para auxiliar os gerentes de produção na tomada de decisões sobre aquisição e organização dos recursos para o futuro. Por isso, não é só suficiente saber o aumento ou diminuição da demanda, e sim essencial conhecer a taxa de mudança (SLACK; JONES; JOHNSTON, 2018).

Para tomada de decisão no processo de gestão no planejamento, são necessários dados quantitativos sobre a capacidade de produção e da demanda (SLACK; JONES; JOHNSTON, 2018). Então, precisa ser possível realizar a estimativa de demanda e assim ocorrer a produção de forma eficiente e eficaz., tendo relação entre a capacidade e a demanda, pois a organização tem que ser capaz de atender a demanda.

Para a escolha da abordagem e técnica de previsão, é necessário que a organização tome três decisões: o que deve ser previsto, que tipo de técnica usar e que tipo de software (KRAJEWSKI; RITSMAN; MALHOTRA, 2009). Tubino (2009), classifica as previsões em dois tipos: longo prazo, utilizadas em aspectos estratégicos; e médio curto prazos em aspectos táticos e operacionais.

Nahmias (1993 *apud* MANCUZO, 2003), elenca que as principais características da previsão de demanda são, em geral erradas, tendo que ter assim capacidade de antecipar erros de previsão; uma boa previsão tem que ter além de dados quantitativos; previsões agregadas são mais precisas; quanto mais longo for o horizonte da previsão, menos exata ela será; e ela não deve ser usada para excluir informações já conhecidas.

2.3 Técnicas de previsão de demanda

Para desenvolver a previsão de demanda é preciso que a organização tenha base de dados históricos, além de outros fatores, na tomada de decisões. Nisso, a previsão possui, como principais, as abordagens qualitativas e quantitativas, tendo um conjunto de técnicas específicas de serem exploradas (PEINADO; GRAEML, 2004; KRAJEWSKI; RITSMAN; MALHOTRA, 2009; CORRÊA; CORRÊA, 2009; SLACK; JONES; JOHNSTON, 2018).

Mesmo assim, muitas organizações não conhecem ou tem problemas na implementação desse processo estratégico, como as pequenas e médias empresas que, segundo Tubino (2009), não possuem uma especialização nessas atividades.

2.3.1 Abordagem qualitativa

No geral, a abordagem qualitativa está baseada em opiniões, pessoais ou do conjunto de pessoas, na experiência vivida e em suposições (as melhores possíveis), seja dos clientes internos ou externos, podendo envolver a coleta e crítica de julgamentos, opções, avaliação de clientes e experiência de mercado, ou seja, aspectos subjetivos (PEINADO; GRAEML, 2004; KRAJEWSKI; RITSMAN; MALHOTRA, 2009; CORRÊA; CORRÊA, 2009; SLACK; JONES; JOHNSTON, 2018).

As técnicas são adequadas quando não há dados históricos adequados ou não úteis e em previsões de produtos novos (PEINADO; GRAEML, 2004; KRAJEWSKI; RITSMAN; MALHOTRA, 2009). Podem ainda ser utilizados para modificar ou ajustar a previsão de métodos quantitativos, dando maior certeza as previsões (KRAJEWSKI; RITSMAN; MALHOTRA, 2009).

2.3.1.1 Predição

Interpretada muitas vezes como visão ou *feeling*, a predição não é um método científico e sim um processo para determinar acontecimento futuro com base na subjetividade, sendo duvidosa e de grande risco, sujeita a sorte (PEINADO; GRAEML, 2004).

Peinado e Graeml (2004), afirmam que os empreendedores visionários dominam essa técnica, pois enxergam demandas incapazes de outros métodos tradicionais perceberem.

2.3.1.2 Opiniões/júri de executivos e abordagem de painel

Se caracteriza pela visão sobre o futuro um grupo de pessoas focadas e especialistas/administradores no tema, possibilitando que todas falem e especulem com suas opiniões, experiências e conhecimentos técnicos até chegarem no consenso ou na decisão da melhor solução na reunião por painel (KRAJEWSKI; RITSMAN; MALHOTRA, 2009; SLACK; JONES; JOHNSTON, 2018). Esses executivos de alto nível estão geralmente ligados a áreas comercial, financeira e de produção, tendo cuidado para não se confundir com metas de vendas ou faturamento (PEINADO; GRAEML, 2004).

Por isso, possui a vantagem de várias visões juntas pensando e dando maior confiabilidade, mas desvantagens por dificultar chegar do denominador comum, o efeito adesão (quem tem maior cargo, ter maior predominância) e os especialistas estarem errados (PEINADO; GRAEML, 2004; MOREIRA, 2008; FERNANDES; GODINHO FILHO, 2010; SLACK; JONES; JOHNSTON, 2018).

Pode ser empregado quando tiver novo produto ou serviço, pois a força de vendas não é capaz de estimar demandas precisas e previsões tecnológicas (KRAJEWSKI; RITSMAN; MALHOTRA, 2009). Talvez seja o método mais utilizado pelas pequenas e médias empresas, pois se baseiam na média móvel de vendas, mas utilizada com menor formalidade e ajustada pela opinião dos envolvidos (PEINADO; GRAEML, 2004).

2.3.1.3 Método *Delphi*

O método *Delphi* é o mais conhecido na abordagem qualitativa, onde consiste na construção de um questionário que é enviado a especialistas, anonimamente. Após analisadas as respostas, essas são resumidas e retornam de maneira anônima aos especialistas para que possam reavaliar suas respostas com base nos argumentos, e assim é repetida várias vezes até chegar a um consenso ou faixa de decisão estreita (PEINADO; GRAEML, 2004; SLACK; JONES; JOHNSTON, 2018).

Esse método tenta reduzir as influências de contato pessoal nas decisões, sendo mais formal, mas os problemas estão em elaborar um questionário “ótimo”, selecionar especialistas adequados, as opiniões pessoais sopresai e tempo de espera (MOREIRA, 2008; SLACK; JONES; JOHNSTON, 2018). Pode ser utilizado em previsões de longo alcance de demanda de produto, vendas de novos produtos e tecnológicas (KRAJEWSKI; RITSMAN; MALHOTRA, 2009).

2.3.1.4 Estimativas/opinião da força de vendas

As previsões advindas de estimativas, colhidas periodicamente, do setor responsável pelas vendas da empresa, são as informações para estipular a demanda futura deste método em cada área de atuação (PEINADO; GRAEML, 2004; KRAJEWSKI; RITSMAN; MALHOTRA, 2009).

Por estarem mais próximos dos clientes externos, muitas vezes tem as melhores informações, tendo como vantagens a força de vendas saber quais produtos e quantidades os clientes comprarão, informações decompostas pelo setor de vendas ter subdivisões e as previsões pessoais dos membros podem ser combinadas para vendas regionais ou nacionais (MOREIRA, 2008; KRAJEWSKI; RITSMAN; MALHOTRA, 2009). Assim, pode ser indicado ao setor de varejo, por lidarei diretamente com os clientes (FERNANDES, GODINHO FILHO, 2010).

As desvantagens estão ligadas a equipe de venda não conseguir diferenciar o que o cliente quer do que precisa, a utilização de vendas individuais como medida de desempenho e contaminação das previsões pelas visões individuais (KRAJEWSKI; RITSMAN; MALHOTRA, 2009). Esses aspectos podem levar os funcionários a subestimar as previsões para se proteger de possíveis metas audaciosas e subestimar as vendas para garantir o abastecimento de produtos (PEINADO; GRAEML, 2004).

2.3.1.5 Pesquisa de mercado

Essa técnica consiste na coleta de dados por meio de pesquisa com questionários em uma amostra específica de consumidores externos, criando e testando hipóteses sobre interesse de um serviço ou produto, para após analisar as informações usando ferramentas estatísticas e avaliação qualitativa das respostas (KRAJEWSKI; RITSMAN; MALHOTRA, 2009).

Peinaldo e Graeml (2004) afirmam que a pesquisa de mercado é um estudo sistemático que deve seguir regras estatísticas e é indispensável quando pretende-se colocar um novo produto no mercado, isso porque suas informações são capazes de nortear as decisões, envolvendo estudos descritivos, explanatórios, formativos ou preditivos.

Os principais cuidados a se tomar é que essa pesquisa se trata de intenções de compras que pode nem se concretizar, a interferência de promoções e o ciclo de vida do produto (PEINADO; GRAEML, 2004; CORRÊA; CORRÊA, 2009).

2.3.1.6 Pesquisa de clientes

Similar a pesquisa de mercado, o que diferencia é que o foco são os clientes da organização. Por isso, é um método mais viável quando há número reduzido de clientes, conseguindo uma pesquisa com todos (FERNANDES; GODINHO FILHO, 2010). Quando a empresa dispõe de alta quantidade de clientes, pode-se utilizar o mesmo método da pesquisa de mercado, mas calculando uma amostra de clientes para aplicação (MOREIRA, 2008).

2.3.1.7 Planejamento de cenários

Aplicado, geralmente, em previsões para longo prazo e usando o painel, mas os participantes são levados a imaginar diversos cenários futuros e, assim, discutidos e identificados os riscos inerentes para cada (SLACK; JONES; JOHNSTON, 2018). Os autores ainda trazem, que não precisa chegar no consenso e sim verificar as possíveis variedades e tentar evitar os cenários menos desejados, e com ações para os mais desejados.

2.3.1.8 Analogia com produtos similares

Nesta técnica, é baseado em dados históricos de vendas de produtos similares e visto como foi seu comportamento, para lançamento de um novo produto, tendo que considerar o grau de similaridade entre os produtos (PEINADO; GRAEML, 2004; FERNANDES; GODINHO FILHO, 2010).

2.3.2 Abordagem quantitativa

As técnicas quantitativas se baseiam em modelos matemáticos que utilizam os dados históricos disponíveis e adequados, conseguindo assim identificar os comportamentos ocorridos e projetar para o futuro, sendo assim mais úteis em produtos existentes com mais tempo no mercado (KRAJEWSKI; RITSMAN; MALHOTRA, 2009; CORRÊA; CORRÊA, 2011; SLACK; JONES; JOHNSTON, 2018).

Dentro dessa abordagem, há dois modelos: análise de séries temporais, técnicas que utilizam dados passados de variável independente a ser prevista na análise estatística; e casuais, que incluem técnicas com base na análise estatística da variável alvo a ser prevista, reconhecendo tendências e padrões sazonais, ou seja, variáveis que afetam a previsão (KRAJEWSKI; RITSMAN; MALHOTRA, 2009).

A seguir serão detalhadas as principais técnicas dos modelos de séries temporais (média móvel simples, média móvel ponderada, suavização exponencial, mínimos quadrados ou regressão linear, ajustamento sazonal) e casuais (regressão linear).

2.3.2.1 Média móvel simples

Esse método envolve calcular a demanda média para os períodos de tempo n mais recentes, usando-as como previsão para próximo período. Assim, a previsão da demanda será igual a média calculada no fim dos períodos incluídos, sendo assim a média se move de período a período. E é útil quando a demanda não apresenta tendências ou influências sazonais (KRAJEWSKI; RITSMAN; MALHOTRA, 2009).

Pode utilizar os tantos de período da demanda anterior quanto os envolvidos desejarem, mas é indicado que em valores grandes de n deve ser utilizado para demandas estáveis e valores menores para as suscetíveis a mudanças nas médias (KRAJEWSKI; RITSMAN; MALHOTRA, 2009). Isso é devido a quanto maior valor de n maior será sua influência das demandas antigas sobre a previsão, e na prática é utilizado apenas os 3 últimos períodos (PEINADO; GRAEML, 2004).

Normalmente quando se utiliza esse método, há erros, desvios, variâncias e amplitude, sendo também calculados para analisar todo o contexto da previsão.

2.3.2.2 Média móvel ponderada

Esta técnica se diferencia de a média móvel simples devido a cada demanda não possuir o mesmo peso de significância, ou seja, cada demanda histórica tem seu próprio peso, devendo a somas dos pesos ser igual a 1. Assim, calcula-se multiplicando o peso atribuído ao respectivo valor da demanda e somando-se os produtos (KRAJEWSKI; RITSMAN; MALHOTRA, 2009). Esse dá maior eficácia em relação à média móvel simples (MOREIRA, 2008).

Assim, pode-se enfatizar cada demanda recente sobre a previsão futura, podendo até lidar com efeitos sazonais colocando pesos maiores (KRAJEWSKI; RITSMAN; MALHOTRA, 2009). Tem em comum de a técnica anterior usar n valores anteriores da demanda e demandas que não apresentem tendência e sazonalidade (PEINADO; GRAEML, 2004).

2.3.2.3 Suavização exponencial

Esse método é uma variação da média móvel ponderada, sendo utilizado quando não há tendência e nem sazonalidade nas demandas, mas o peso que se adota é um que eleva exponencialmente quanto mais recentes são os períodos (PEINADO; GRAEML, 2004). É necessário a previsão do último período, a demanda para esse período e um parâmetro suavizador (KRAJEWSKI; RITSMAN; MALHOTRA, 2009).

Para isso, utiliza um valor de suavização - parâmetro, a constante α , que varia entre 0 e 1, onde quanto maior o valor da constante menor será a influência na demanda real do último período na previsão (PEINADO; GRAEML, 2004). No cálculo, a taxa multiplica a demanda média dos últimos períodos. Uma taxa exponencial $(1 - \alpha)$ é usada para multiplicar os últimos meses, elevando sucessivamente a cada n período utilizado. Após, é somando os produtos e como resultado a previsão de demanda.

Segundo Krajewski, Ritsman e Malhotra (2009), maiores valores de α têm resultados com previsões mais responsivas a alterações na média básica e menores valores lidam de forma uniforme com a demanda anterior e previsões mais estáveis. E afirmam que vários valores de suavizador são testados e o que gera melhores previsões é escolhido.

2.3.2.4 Mínimos quadrados ou regressão linear

Utiliza da teoria dos mínimos quadrados, conseguindo promover uma regressão linear que definirá uma equação da reta que melhor representará o comportamento dos valores da demanda passada. Esta reta é a que minimiza o somatório das distâncias entre cada valor de demanda já ocorrida e a própria reta (PEINADO; GRAEML, 2004). A regressão no foco temporal a variável X é o tempo e o Y a demanda.

Assim, essa técnica já considera as demandas que apresentam tendências, mas não sazonalidade, como exemplos produtos com tendências crescente e decrescente que é, respectivamente, crescimento e declínio (PEINADO; GRAEML, 2004).

2.3.2.5 Ajustamento sazonal

No ajustamento sazonal é considerado as séries temporais de demandas com nível, tendência e sazonalidade, como produtos que são influenciados por épocas do ano, como sorvetes no verão, material escolar no início e meio do ano letivo, ovos de chocolate na páscoa (PEINADO; GRAEML, 2004).

No cálculo, é utilizado a equação da reta (regressão linear) multiplicado pelo fator de sazonalidade, sendo que na equação leva em consideração o nível e a tendência. Assim, obtém a demanda sem as mudanças da sazonalidade (demanda dessazonalizada) na equação e após multiplica pelo fator de sazonalidade, que é encontrado pelo quociente percentual entre a demanda real ocorrida e a demanda dessazonalizada. Caso haja mais de um ciclo sazonal, o fator será a média dos valores do período de sazonalidade (PEINADO; GRAEML, 2004).

2.3.2.6 Modelo de Winter

Os índices de níveis, tendência e sazonalidade quando assumidos como constantes são utilizadas as técnicas apresentadas anteriormente, mas na prática nem sempre isso acontece, tendo que assim aplicar suavização em todos esses índices. Um dos modelos que se destaca é o de Winter, pois possui larga aplicação em organizações com produtos onde a demanda tem variabilidade nos três índices (PEINADO; GRAEML, 2004).

O desenvolvimento do cálculo se baseia no modelo de regressão linear após o ajustamento sazonal, onde é aplicado para cada índice os fatores de suavização exponencial α , β e γ no nível, tendência e sazonalidade, respectivamente (PEINADO; GRAEML, 2004).

2.3.2.7 Modelos casuais

Os modelos casuais fornecem técnicas de previsão mais sofisticadas e são indicadas para prever pontos de inflexão na demanda e previsões de longo prazo, pois são usados dados históricos fazendo a relação, em termos matemáticos, entre os fatores definidos a serem previstos e outros fatores (externos ou internos), que podem ser identificados, para entender o impacto de cada variável exerce sobre a outra (KRAJEWSKI; RITSMAN; MALHOTRA, 2009; SLACK; JONES; JOHNSTON, 2018).

A regressão linear é expressa por uma equação linear, onde há uma variável dependente relacionado a uma ou mais variáveis independentes, sendo a dependente a que se pretende prever e as independentes as que impactam seu comportamento (KRAJEWSKI; RITSMAN; MALHOTRA, 2009).

No modelo de regressão linear simples, a tentativa é prever o melhor resultado entre duas variáveis, onde a variável dependente está em função de apenas uma independente, sendo uma linha reta (KRAJEWSKI; RITSMAN; MALHOTRA, 2009; SLACK; JONES;

JOHNSTON, 2018). Este modelo é o mais utilizado pelas organizações (FERNANDES; GODINHO FILHO, 2010; MOREIRA, 2008).

Quando há diversos fatores que afetem a variável dependente, ou seja, quando a demanda possui mais de uma variável independente impactando, o modelo a ser utilizado é o de regressão múltipla (KRAJEWSKI; RITSMAN; MALHOTRA, 2009). Assim, assume-se que a variável dependente pode ser influenciada por mais de um fator.

2.4 Técnicas de previsão de demanda computacionais

O objetivo desse tópico não é se aprofundar nos preceitos matemáticos que governam os métodos de previsão computacionais. Também vale destacar que todos os demais métodos clássicos podem ser facilmente implementados computacionalmente. Porém, os métodos aqui apresentados são de uma robustez numérica grande o suficiente ou que demanda um número muito elevado de interações que demandam de um auxílio computacional.

É importante salientar que os métodos computacionais tem, em sua maioria, natureza híbrida e, por isso, podem apresentar um poder de predição superior aos métodos clássicos. Contudo, por demandarem um determinado grau de domínio de programação, tais métodos têm sido pouco utilizados fora da esfera acadêmica, algo que tenderá a mudar com o avanço da indústria 4.0.

2.4.1 Método de Holt mais Damp

Holt, em 1957, desenvolveu um modelo estendendo a suavização exponencial simples, permitindo a previsão de dados com uma tendência. Assim, tem-se a suavização exponencial dupla, pois há agora duas constantes. Esse método conhecido como Holt, é composto por três equações: uma de previsão; outra de suavização para o nível; e de suavização para a tendência (HYNDMAN; ATHANASOPOULOS, 2018; COSTA 2019).

O modelo de Holt com “Damp” pressupõe que o crescimento não é linear ao longo do tempo, tendo assim uma tendência amortecida. Gardner e McKenzie introduziram esse parâmetro que “amortece” a tendência em algum momento no futuro, em 1985. Assim, o parâmetro é introduzido nas três equações, variando entre 0 e 1. Caso o parâmetro for igual a 1, o crescimento será linear (HYNDMAN; ATHANASOPOULOS, 2018).

2.4.2 Método de Holt-Winters

O método desenvolvido por Holt e Winters é uma extensão do método de Holt para quando há sazonalidade nos dados, pois o método anterior não apresenta bom comportamento para esta situação. O método é uma suavização exponencial tripla devido ser composto por três equações de suavização (nível, tendência e componente sazonal) e a equação de previsão (HYNDMAN; ATHANASOPOULOS, 2018; COSTA 2019). Existem duas variações para este método: aditivo e multiplicativo.

2.4.2.1 Método de Holt-Winters Aditivo

O método aditivo é utilizado quando as variáveis sazonais são independentes na série, ou seja, são constantes (HYNDMAN; ATHANASOPOULOS, 2018; COSTA 2019). O componente sazonal é expresso em termos absolutos na escala da série analisada, e a série é ajustada sazonalmente na equação de nível subtraindo o componente sazonal; ainda, e cada ano o componente sazonal é somado a zero (HYNDMAN; ATHANASOPOULOS, 2018).

É necessário definir os valores iniciais para o nível, o declive e os índices de sazonalidade para iniciar o método aditivo (COSTA 2019). Sobre as equações, a equação de tendência continua igual ao do método Holt. Já a de nível, sazonal e previsão contém pequenas mudança, com o componente de sazonalidade realizando operações de soma e subtração (HYNDMAN; ATHANASOPOULOS, 2018).

2.4.2.2 Método de Holt-Winters Multiplicativo

O método aditivo é utilizado quando as variáveis sazonais se alteram de forma proporcional na série. O componente sazonal é expresso em termos de porcentagem e a série é ajustada sazonalmente pela divisão pelo componente sazonal dentro de cada ano (HYNDMAN; ATHANASOPOULOS, 2018).

Para se iniciar o método multiplicativo também é necessário definir os valores iniciais: nível, declive e os índices de sazonalidade. Para a escolha ótimo das constantes de suavizações são utilizados métodos numéricos de otimização afim de minimizarem o erro quadrático médio das previsões (COSTA, 2019). Os valores iniciais são encontrados: no nível, a partir da média da primeira estação da sazonalidade; na tendência, usando duas estações completas da sazonalidade; e do componente sazonal, é ao menos uma estação completa de dados em sazonais períodos (LIMA et al., 2015).

2.4.3 Método ARIMA

Os modelos do método *Autoregressive Integrated Moving Average* ou Auto-regressivos Integrados de Médias Móveis (ARIMA) são uma abordagem de previsão linear para séries temporais estacionários (PANIGRAHI; BEHERA, 2017), desenvolvidos por Box e Jenkins e sendo um dos métodos mais utilizados para previsão de séries temporais (DANTAS; OLIVEIRA, 2015). Por isso, é basicamente uma combinação entre os modelos de auto regressão (AR) e médias móveis (MA).

Resumidamente, os modelos consistem na combinação de três partes de natureza matemática, que detectam o estado de correlação ou auto correlação entre os valores da série temporal: a parte auto regressivo (AR), onde a variável estudada é regressada pelos valores anteriores; o filtro integração (I), que indica a substituição dos valores dos dados pela diferença entre seus valores e os valores anteriores (podendo ocorrer mais de uma vez); e a parte médias móveis (MA), indica o erro de regressão que é uma combinação linear dos termos de erro. Assim, baseado no comportamento é realizada as previsões futuras (RODRIGUES et al., 2008; MAIA, 2019).

A construção do modelo é composta por três etapas: (I) identificação, quando a série temporal já é estacionária (caso não seja, são realizadas diferenciações até se tornar estacionária), os parâmetros p (ordem do modelo auto regressivo) e q (grau de diferenciação) são identificados por meio da análise de correlação; (II) estimação, os parâmetros do modelo são estimados usando procedimentos de otimização não linear; (III) verificação ou previsão dos dados, ocorre a análise dos resíduos para confirmar o modelo mais adequado utilizando alguns testes, e após selecionado os valores futuros são previstos (PANIGRAHI; BEHERA, 2017).

2.4.4 Método de Naive

O método de Naive é conhecido como método de previsão “ingênuo” por conta da sua tradução para o português. Também é conhecido o método do caminho aleatório devido ser descrito por um *random walk* (BAZIEWICZ, 2019; RODRIGUES, 2018).

Resumidamente, o método considera que a previsão do próximo período é igual a demanda do último período (BAZIEWICZ, 2019), ou seja, a previsão futura repetirá o passado. Assim, o valor se baseia num ponto de referência, e os valores futuros vai ter o mesmo valor

(RODRIGUES, 2018). Segundo Baziewicz (2019), devido a sua simplicidade é mais utilizado para como *benchmark* para comparação com outros métodos, ou seja, como referência de comparação.

2.4.5 Método de S Naive

O método de S Naive vem de *Seasonal Naive*, conhecido também pelo método do caminho aleatório com sazonalidade. Sendo um dos métodos simples mais utilizados para dados com sazonalidade. É bastante similar ao método anterior, ocorrendo da mesma forma onde os valores futuros são iguais ao do valor passado. Porém, o que diferencia é que o valor passado é considerado o último valor para a mesma época do valor futuro, ou seja, caso uma sazonalidade de 12 meses a previsão dos meses de janeiro são o valor do último janeiro observado. E, assim, ocorre sucessivamente (RODRIGUES, 2018).

2.4.6 Método STLF mais ETS (ANN)

O método STLF mais ETS (ANN) busca a estimação das previsões via decomposição sazonal e de tendência utilizando o método de Loess, que é um método não paramétrico de regressão local, muito útil para retirar da análise de previsão os *outliers* ou dados discrepantes. A sigla STL vem do inglês *Seasonal Decomposition of Time Series by Loess*.

Desse modo, valores identificados fora dos limites dos intervalos de confiança da série temporal são suavizados. Esse método se limita a fazer um conjunto de regressões com poucos dados e estimar pesos para observações próximas aumentando o poder de previsão (MAIA,2019). Por outro lado, o STLF mais ETS (ANN) é híbrido por fazer uso ainda da suavização exponencial linear e não linear do espaço de estado de inovação (sigla inglês *ETS* de Error, Trend e Seasonality) com o modelo de redes neurais artificiais (sigla inglês *ANN* de *Artificial Neural Network*).

A combinação de ETS com ANN tem a vantagem de utilizar a detecção de padrões (forte ponto positivo da ANN) com a possibilidade de tratar dados não lineares tão bem quanto os dados lineares, ou seja, o ETS trata padrões não lineares (se houver) e o ANN trata os padrões lineares, corrigindo e aumentando o poder de previsão da ANN sozinha. (PANIGRAHI; BEHERA,2017).

2.4.7 Método de Splinef

O método de Splinef é uma previsão de Spline (método de extrapolação de tendência linear) de suavização cúbica. Este método é equivalente a um método ARIMA (0,2,2), mas com um espaço de parâmetro restrito. Sendo que, o espaço restrito tem efeito mínimo no desempenho da previsão. Possui vantagem sobre o ARIMA completo ao fornecer uma tendência histórica suave e uma função de previsão linear (HYNDMAN et al., 2005).

2.4.8 Método de Thetaf

Método para previsão do modelo Theta, desenvolvido por Assimakopoulos e Nikolopoulos em 2000. É equivalente ao método de suavização exponencial que tem suavização de tendência fixa, onde o modelo sempre usa metade da tendência. A série temporal é testada quanto à sazonalidade, e para isso utiliza o descrito A&N. Sendo confirmada como série sazonal, ela é justada sazonalmente usando decomposição multiplicativa clássica antes de aplicar o método Teta. Assim, as previsões resultantes são ressazonalizadas (HYNDMAN; BILLAH, 2003).

2.4.9 Método ETS mais ANN (ou *Forecast* no software R)

É um método de previsão semelhante ao método Método STLF mais ETS (ANN), contudo a previsão ocorre sem a suavização dos *outliers*, que é natural na presença de método de Loess utilizado pelo Método STLF mais ETS (ANN). A vantagem é o ganho de precisão da previsão em séries com muitos pontos discrepantes. Também é um método híbrido, e utilizado como padrão na função *Forecast* no software R.

2.4.10 Método de Rede Neural Auto Regressivo

Faz uso da arquitetura da rede neural artificial para previsão. Os valores da série temporal são inseridos numa rede neural de forma defasada de forma semelhante ao modelo de autorregressão e, por isso, recebe o nome de autorregressiva. Desse modo, o número de camadas ocultas e o número de nós da rede neural são estimados de forma a obter a melhor previsão (HYNDMAN; ATHANASOPOULOS, 2018).

No t3pico sobre m3todo STLF mais ETS (ANN) j3 foi apresentada que as redes neurais s3o utilizadas para detec33o de padr3es de s3ries temporais e que, por isso, tem um poder de predic33o muito acurado. Para uma melhor compreens3o das rela33es em redes neurais artificiais recomenda-se a leitura dos trabalhos de Fernandes et al. (1995), Battagello et al. (2004) e Mano e Anteneodo (2009).

3. METODOLOGIA

3.1 Classificação da pesquisa

A pesquisa pode ser classificada de diversas formas, sendo as mais clássicas divididas em quatro abordagens: quanto a sua natureza, ao problema, aos objetivos e os procedimentos técnicos (MORESI, 2003). Assim, essa pesquisa se classifica:

- Quanto a sua natureza, é uma pesquisa científica aplicada devido ter aplicação prática com finalidade às soluções de problemas específicos em uma agroindústria (MORESI, 2003; ZANELLA, 2011);
- Em relação aos objetivos, pode ser considerada exploratória por ampliar o conhecimento a respeito da realidade atual da produção de coco da indústria, fazendo análises e aplicando técnicas (ZANELLA, 2011);
- Como objetivo estudar o caso específico de uma indústria de derivados de coco, tendo assim que se aprofundar na realidade desta empresa, é um estudo de caso de acordo com o procedimento técnico (MORESI, 2003; ZANELLA, 2011);
- Devido ao problema, a abordagem é quali-quantitativa por conta de haver interpretações de fenômenos de forma subjetiva sem utilização de técnicas quantitativas, como também o emprego de métodos estatísticos para relacionar variáveis (MORESI, 2003; ZANELLA, 2011).

3.2 Apresentação da empresa

A agroindústria do estudo de caso fica localizada na região do Vale do São Francisco no estado de Pernambuco, possuindo 6 anos de atuação no mercado da produção de frutas, com instalações para processamento e envase de água de coco.

Sobre seu processo produtivo, as linhas de produção são totalmente automatizadas com capacidade de processamento de 5000 litros por hora de água de coco. Ainda na indústria os frutos são selecionados seguindo critérios padronizados e passam por processos que garantem sua conservação até o processamento do produto final.

A empresa não tem nenhum estudo de previsão de demanda para apoio à tomada de decisão.

3.3 Etapas da pesquisa

O trabalho foi dividido em três etapas principais: coleta de dados, aplicação nos métodos de previsão da demanda, e análise de dados. Na primeira, foi levantado o conjunto de dados necessários para ser possível a aplicação do método de previsão de demanda. Essa aplicação, foi realizada na segunda etapa, em que consistiu em analisar e tratar esses dados ajustando a encontrar um modelo de previsão.

3.3.1 Coleta de dados

Para coleta de dados, foram extraídos os dados históricos da produção mensal de água de coco da agroindústria, verificando as demandas do fruto coco e seu processamento até o produto final.

O período para análise foi entre 01/2016 até 10/2020. Essas informações foram repassadas pela empresa, garantindo que há consistência reais dos dados da produção de acordo com o mecanismo utilizado para acompanhamento dessas informações, que alimenta diretamente e de forma automática os dados de volume de água, a medida que é extraída do fruto.

3.3.2 Análise e tratamento dos dados

Os dados foram compilados em uma planilha no *Microsoft Office Excel*, sendo organizados e analisados. Para o tratamento dos dados, análises e testes estatísticos, foi utilizado o ambiente e linguagem em “R” (R Core Team, 2018).

Foram realizados diferentes testes estatísticos, tendo a totalidade de 14 métodos de previsão de demanda: Suavização exponencial, Média móvel, Holt, Holt mais Damp, Holt-Winters aditivo, Holt-Winters multiplicativo, Arima, Naive, SNaive, STLF mais ETS(ANN), Splinesf, Thetaf, ETS mais ANN (Forecast no software R), Rede Neural Autoregressivo,

A partir do resultado dos modelos, foi possível fazer a comparação dos resultados com intuito de selecionar os métodos mais adequados para o estudo de caso com base nos cálculos dos erros Média Absoluta de Erro (MAE), Média Absoluta Percentual de Erro (MAPE), Quadrático Médio da Raiz (RMSE) e Escalar Médio Absoluto (MASE). E, além disso, buscou-se verificar a previsão desses modelos com dados dos últimos meses (novembro e dezembro de 2020; e janeiro e fevereiro de 2021) de demandas reais da empresa. Com isso, conseguiu-se

definir qual modelo mais adequado para implementação com base nos erros e na comparação com dados reais já obtidos.

A posteriori, os dados previstos pelos cinco melhores modelos foram comparados com os dados reais dos meses de novembro de 2020 a abril de 2021 (cinco meses). O erro percentual mês a mês e o erro acumulado dos cinco meses foram os parâmetros analisados para determinar o melhor modelo de previsão.

A comparação entre os valores preditos e os reais também foi feita pelo teste t, garantido e precedido pelo teste de normalidade dos dados de Shapiro Wilk, Kolmogorov-Smirnov e Lilliefors, com nível de significância de 0,05. A lógica adotada nos testes de normalidade são:

- H_0 : $p\text{-value} \geq 0,05 \rightarrow$ Os valores seguem distribuição normal
- H_a : $p\text{-value} < 0,05 \rightarrow$ Os valores não seguem distribuição normal

Para o teste t adotou-se as seguintes hipóteses:

- H_0 : $p\text{-value} \geq 0,05 \rightarrow$ Os valores comparados são iguais
- H_a : $p\text{-value} < 0,05 \rightarrow$ Os valores comparados não são iguais

4. RESULTADOS E DISCUSSÃO

4.1 Descrição dos dados

Para aplicação dos modelos de previsão de demanda no estudo de caso, foram coletados os dados da quantidade do fruto coco utilizados na produção durante o período entre 2016 (janeiro) a 2018 (outubro), que é a matéria-prima na fabricação dos diversos produtos. As demandas analisadas são mostradas na Tabela 3.

Tabela 3 – Dados históricos da quantidade de coco

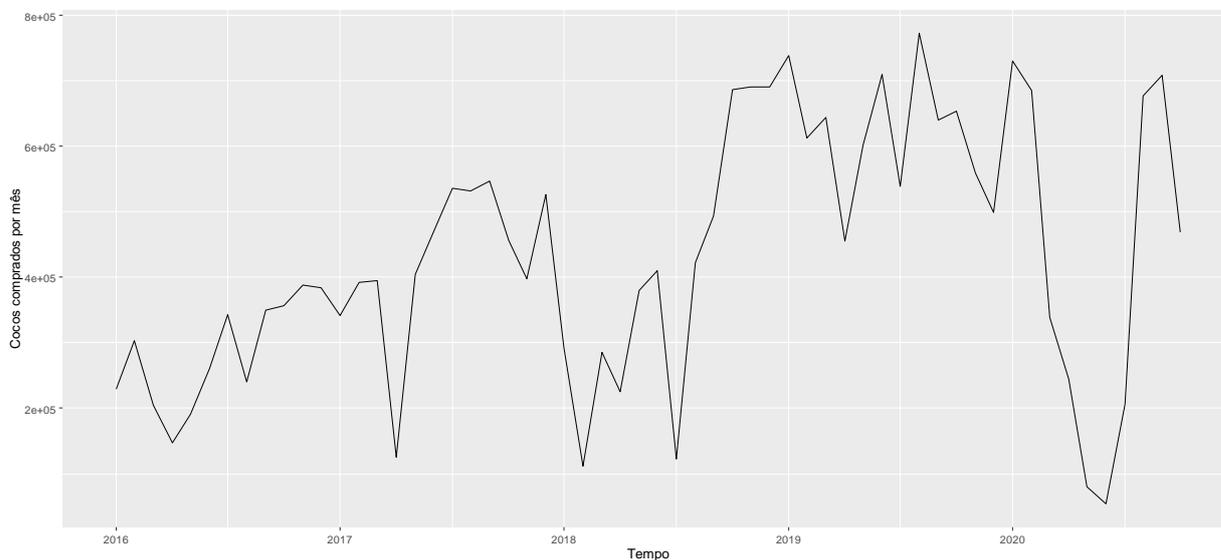
Ano	Mês	Quantidade de fruto(un)	Ano	Mês	Quantidade de fruto(un)	
2016	Janeiro	229.600	2018	Junho	410.000	
	Fevereiro	303.300		Julho	123.000	
	Março	205.300		Agosto	422.000	
	Abril	147.700		Setembro	493.000	
	Maio	191.500		Outubro	686.305	
	Junho	260.600		Novembro	690.776	
	2017	Janeiro	341.850	2019	Dezembro	690.417
		Fevereiro	392.200		Janeiro	739.340
		Março	395.600		Fevereiro	612.500
		Abril	125.500		Março	644.805
		Maio	404.750		Abril	455.200
		Junho	468.900		Maio	601.400
2018		Janeiro	293.000	2020	Junho	709.316
		Fevereiro	112.000		Julho	538.500
		Março	285.500		Agosto	772.439
		Abril	225.000		Setembro	639.578
		Maio	380.000		Outubro	653.865
					Novembro	558.931
			Dezembro	498.615		
			Janeiro	730.950		
			Fevereiro	684.767		
			Março	339.000		
			Abril	244.285		
			Maio	80.697		
		Junho	54.526			
		Julho	206.274			
		Agosto	677.122			
		Setembro	708.529			
		Outubro	469.049			

Fonte: Autoria própria (2021)

A maior demanda ocorreu no ano de 2019 com total de 7.424.489 de cocos comprados para a produção. Na Figura 1, é apresentada a série temporal histórica da quantidade de coco comprada para produção. Em 2020, o impacto da pandemia pode explicar uma menor

quantidade adquirida entre abril e julho, porém se analisarmos os meses que a antecederam, a produção continua se comportando com uma curva crescente.

Figura 1 – Série temporal histórica da quantidade de coco comprada



Fonte: O Autor (2021)

4.2 Análise e comparação da aplicação dos modelos de previsão de demanda

Os resultados da previsão foram analisados e comparados, com o intuito de selecionar o modelo de previsão mais adequada para o produto do estudo de caso da empresa.

As previsões ocorreram a partir do mês de novembro de 2020 até outubro de 2022. Foi possível obter demanda prevista, os limites inferior e superior, gráficos com o comportamento da previsão e os pressupostos dos erros. Posteriormente, os pressupostos dos erros foram calculados para encontrar os erros médios. Estes foram indicadores de acuracidade dos modelos utilizados, sendo considerados melhores os que apresentaram menor erro. A Tabela 4 traz o resumo dos erros médios calculados ordenados pelos os melhores resultados (combinação dos menores erros).

Tabela 4 – Resumo dos resultados dos erros médios dos modelos

Modelo de previsão de demanda	Erros médios			
	MAPE	MAE	RMSE	MASE
STLF	39,44034	100677,00	124480,40	0,4908916
AUTORREGRESSÃO NEURAL	32,91682	106726,00	130103,90	0,5203861
HOLT MULTIPLICATIVO	41,90111	101470,20	134650,50	0,4947594
HOLT ADITIVO	44,7642	107720,00	136886,30	0,5252326
ARIMA DE BOX & JEKINS	38,91704	108053,50	142522,40	0,5268587
HOLT DAMP	41,11874	114109,00	149298,40	0,5563848
HOLT	42,14464	114162,30	149748,40	0,5566446
SUAVIZAÇÃO EXPONENCIAL	41,05803	115702,80	149451,10	0,564156
FORECAST	41,05555	115700,70	149451,10	0,5641459
THETAF	41,05803	115702,80	149451,10	0,564156
NAIVE	39,47011	115863,50	152537,40	0,5649396
SPLINEF	48,58269	155977,80	204527,00	0,7605331
MEDIA MOVEL	67,16517	162242,20	192412,60	0,791078
S NAIVE	87,7742	205090,10	252785,20	1,000000

Fonte: O Autor (2021).

Através das análises da comparação da combinação dos erros, é possível verificar que os modelos baseados em redes neurais STLF e AUTORREGRESSÃO NEURAL obtiveram os menores erros, e assim resultados mais significativos. Os modelos HOLT MULTI, HOLT ADITIVO e ARIMA AUTO. de BOX & JEKINS também demonstraram bons resultados.

Com base nesses cinco modelos com melhores resultados, as previsões foram analisadas buscando verificar seu comportamento e os aspectos de seus erros. Também foi comparado os resultados da previsão entre os meses de novembro de 2020 a fevereiro de 2021 com os dados reais obtidos nesse período. Nas seguintes seções serão apresentadas as previsões com melhores resultados.

As demais previsões calculadas estão demonstradas nos Anexos. Os resultados desses métodos foram menos satisfatórios tanto devido aos erros quanto os resíduos dos erros não apresentarem distribuição normal, correlação ao longo do tempo e/ou menor variação durante o período analisado.

4.2.1 STLF – *short-term load forecasting*

A previsão para o método STLF+ETS (A, N, N) é apresentada na Tabela 5 e na Figura 2. O modelo de previsão de curto prazo baseada em rede neural obteve a previsão se repetindo entre os meses para os anos de 2021 e 2022. Porém, observa-se comportamento similar a demanda dos anos anteriores, tendo aumentado as demandas mensais. Assim, os resultados da previsão demonstraram-se satisfatórios, mesmo havendo os mesmos valores da previsão entre os anos devido a previsão do modelo ser de curto prazo.

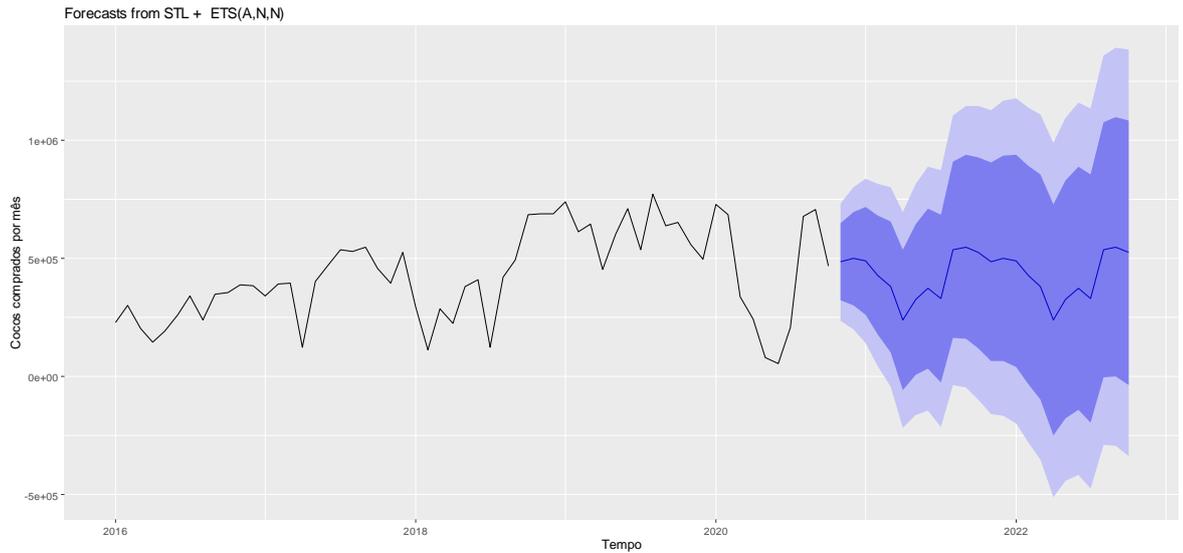
Os gráficos dos pressupostos dos erros são demonstrados a seguir. Os resultados confirmam o bom resultado dos erros devido a variável constante durante o tempo analisado. O correlograma (Figura 3) indicou que não existe correlação entre os tempos, pois estão dentro dos limites (linhas azuis), tendo assim a independência dos resíduos dos erros. O histograma (Figura 3) demonstra que os resíduos estão bem próximos a uma distribuição normal.

Tabela 5 – Resultado do método STLF

Ano	Mês	Previsão	Limite Inf (80%)	Limite Sup (80%)	Limite Inf (90%)	Limite Sup (90%)
2020	Novembro	485657,60	323305,79	648009,40	237361,94	733953,20
	Dezembro	500556,10	303278,19	697833,90	198845,59	802266,50
	Janeiro	489772,30	262882,46	716662,20	142774,22	836770,40
	Fevereiro	430054,70	176994,55	683114,90	43032,57	817076,90
	Março	379701,40	102934,51	656468,30	-43577,04	802979,80
	Abril	240226,70	-58370,64	538824,00	-216438,52	696891,90
2021	Maio	327285,10	8348,08	646222,10	-160486,98	815057,20
	Junho	372764,40	34709,31	710819,60	-144246,27	889775,20
	Julho	330855,00	-25293,45	687003,50	-213827,06	875537,10
	Agosto	536515,50	163149,48	909881,50	-34498,54	1107529,50
	Setembro	549451,50	159627,70	939275,40	-46732,58	1145635,70
	Outubro	524489,30	118874,84	930103,70	-95844,48	1144823,10
	Novembro	485657,60	64844,63	906470,50	-157920,29	1129235,40
	Dezembro	500556,10	65074,72	936037,40	-165455,17	1166567,30
	Janeiro	489772,30	40100,84	939443,80	-197940,86	1177485,50
	Fevereiro	430054,70	-33372,59	893482,10	-278696,20	1138805,70
	Março	379701,40	-97085,07	856487,90	-349480,59	1108883,40
	Abril	240226,70	-249554,69	730008,10	-508829,29	989282,70
2022	Maio	327285,10	-175155,20	829725,40	-441131,03	1095701,20
	Junho	372764,40	-142023,57	887552,50	-414535,89	1160064,80
	Julho	330855,00	-195991,42	857701,40	-474887,07	1136597,10
	Agosto	536515,50	-2119,46	1075150,40	-287255,58	1360286,60
	Setembro	549451,50	-719,39	1099622,50	-291962,30	1390865,40
	Outubro	524489,30	-36980,67	1085959,30	-334204,91	1383183,50

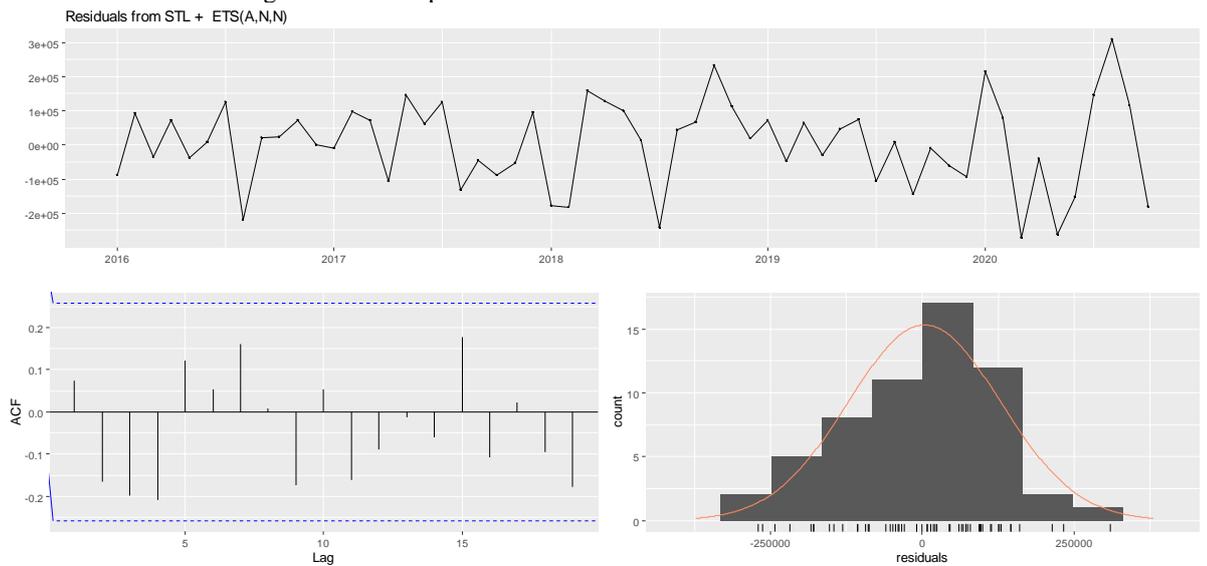
Fonte: O Autor (2021).

Figura 2 – Representação gráfica do método STLF



Fonte: O Autor (2021)

Figura 3 – Pressupostos dos erros do método STLF



Fonte: O Autor (2021)

4.2.2 Modelo Auto Regressão Neural

Os resultados do método Auto regressão neural são apresentados na Tabela 6 e na Figura 4. Mesmo os erros médios calculados tendo sido considerados bons indicadores, a previsão de demanda se mostrou insatisfatória devido ao comportamento decrescente das quantidades. Assim, o desempenho da aplicação do método não pôde ser considerado confiável.

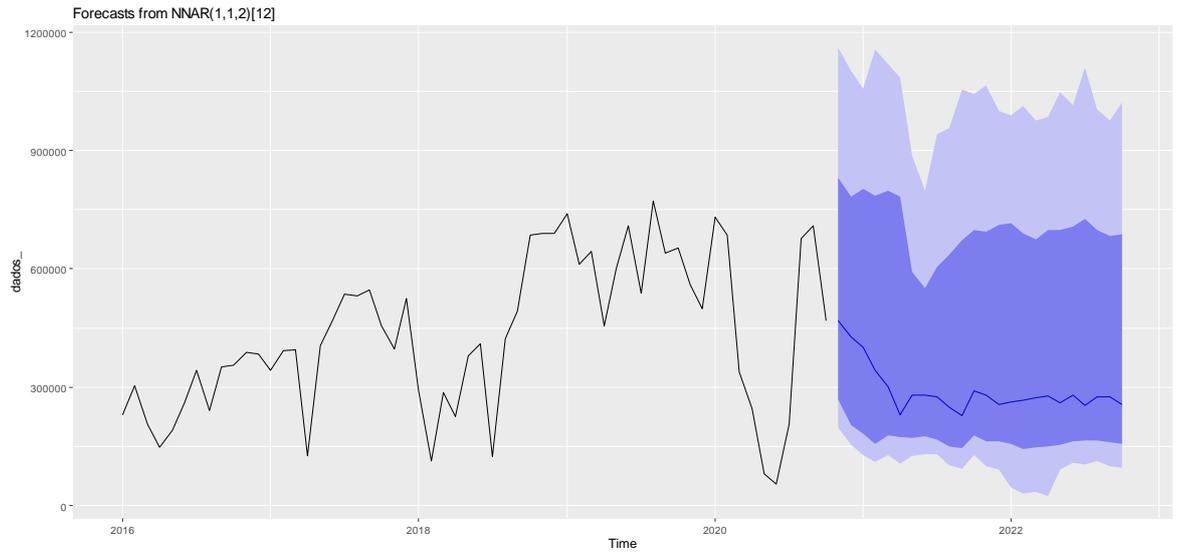
Os resultados dos pressupostos dos erros (Figura 5) demonstram uma menor variável dos erros durante o tempo, tendo não verificado para o ano de 2016. O correlograma indicou que não existe correlação entre os tempos, e assim a independência dos resíduos dos erros (Figura 5). Já no histograma os resíduos não apresentam uma distribuição normal (Figura 5). Esses resultados corroboram para considerar que este método não é confiável para o estudo de caso.

Tabela 6 – Resultado do método auto regressão neural

Ano	Mês	Previsão
2020	Novembro	468649,70
	Dezembro	427358,90
	Janeiro	401997,10
	Fevereiro	343456,90
	Março	302519,10
	Abril	230031,20
2021	Maio	280587,80
	Junho	280094,80
	Julho	274767,80
	Agosto	249883,10
	Setembro	226779,90
	Outubro	290399,50
	Novembro	280839,00
	Dezembro	255514,90
	Janeiro	262666,70
	Fevereiro	266135,80
	Março	272690,20
	Abril	276649,80
2022	Maio	259618,30
	Junho	280321,20
	Julho	254097,30
	Agosto	275176,00
	Setembro	275905,40
	Outubro	256807,60

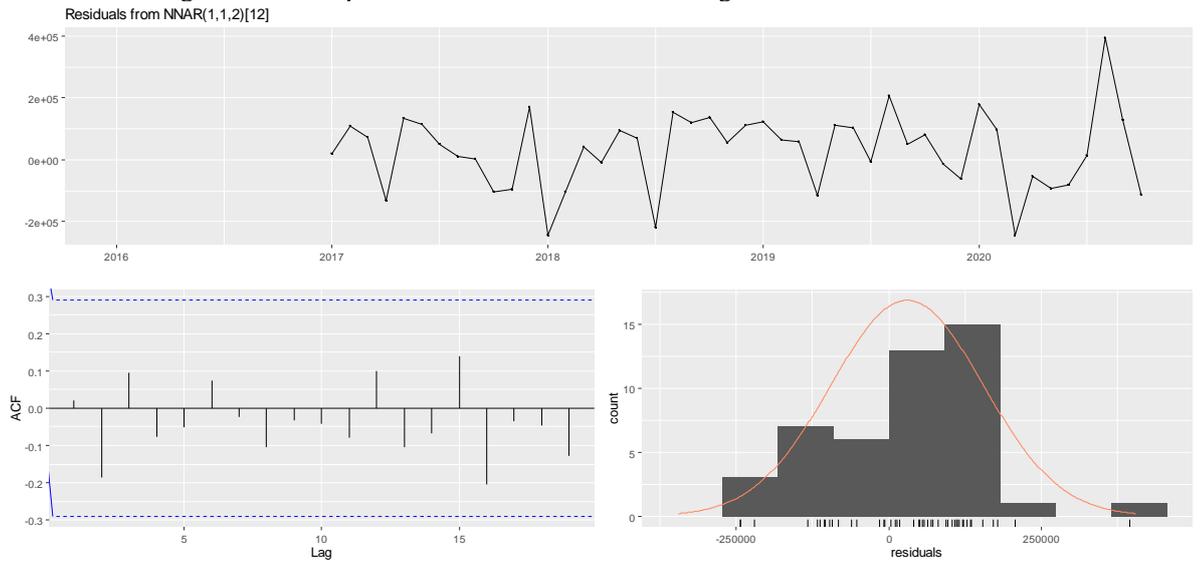
Fonte: O Autor (2021).

Figura 4 – Representação gráfica do método auto regressão neural



Fonte: O Autor (2021)

Figura 5 – Pressupostos dos erros do método auto regressão neural



Fonte: O Autor (2021)

4.2.3 Modelo Holt-Winters multiplicativo

O resultado da aplicação do método Holt-Winters multiplicativo é mostrado na Tabela 7 e na Figura 6. Este modelo calcula as variações sazonais ao longo do tempo, que para este caso entre os anos de 2016 e 2020. Percebe-se que o comportamento entre os meses dos anos analisados é semelhante, indicando haver certa sazonalidade. Assim, pode-se considerar com o método com bom desempenho nas previsões.

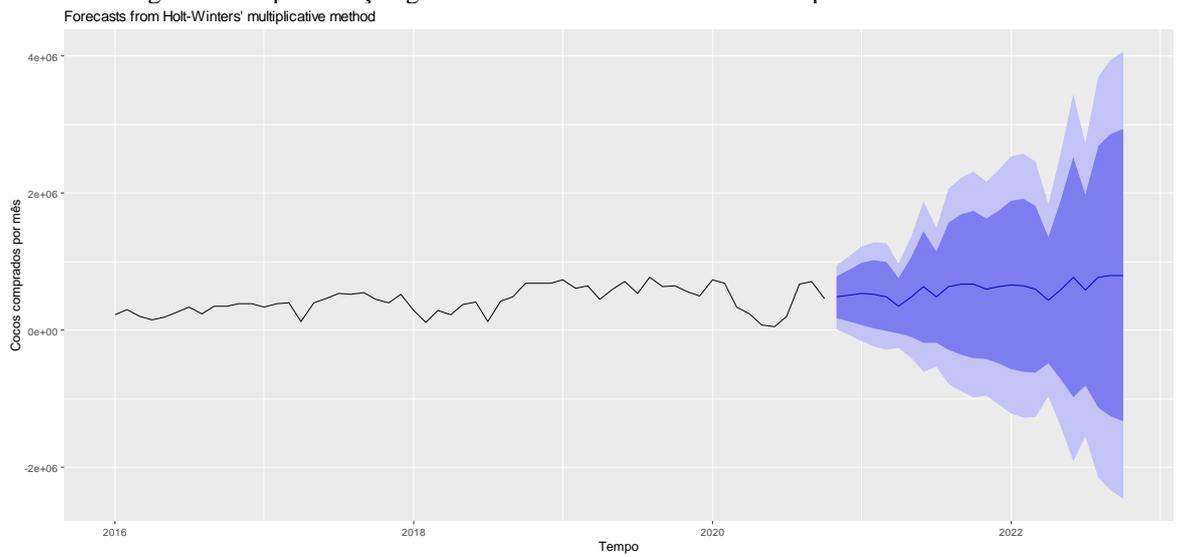
No comportamento dos erros, é possível verificar certa variável dos erros durante o tempo, porém os valores estão mais próximo do 0. Entretanto, não existe correlação dos erros entre os anos analisados, tendo resíduos dos erros independentes. E os resíduos não possuem tão aparente uma distribuição normal. Esses resultados são apresentados na Figura 7, indicando que método não é tão confiável quanto o STLF.

Tabela 7 – Resultado do método Holt-Winters multiplicativo

Ano	Mês	Previsão	Limite Inf (80%)	Limite Sup (80%)	Limite Inf (90%)	Limite Sup (90%)
2020	Novembro	486256,20	182755,67	789756,70	22092,22	950420,10
	Dezembro	509192,30	133151,22	885233,30	-65912,88	1084297,40
	Janeiro	536148,30	85008,15	987288,50	-153811,02	1226107,60
	Fevereiro	529362,10	33328,54	1025395,70	-229255,77	1287980,00
	Março	492644,90	-13605,07	998894,90	-281597,61	1266887,40
	Abril	357868,40	-41035,99	756772,80	-252203,21	967940,00
	Maió	484869,80	-96598,39	1066338,10	-404409,08	1374148,80
2021	Junho	633264,20	-178607,15	1445135,60	-608385,89	1874914,30
	Julho	486425,70	-176909,44	1149760,80	-528057,83	1500909,20
	Agosto	642508,30	-285679,79	1570696,50	-777032,91	2062049,60
	Setembro	669010,20	-351385,14	1689405,50	-891549,79	2229570,10
	Outubro	670511,40	-406196,88	1747219,60	-976171,80	2317194,60
	Novembro	605695,90	-415927,74	1627319,60	-956742,65	2168134,50
	Dezembro	631757,90	-485174,03	1748689,80	-1076442,08	2339957,80
2022	Janeiro	662665,50	-563221,79	1888552,70	-1212167,31	2537498,30
	Fevereiro	651869,70	-608037,85	1911777,30	-1274992,63	2578732,00
	Março	604498,80	-614549,09	1823546,70	-1259874,07	2468871,70
	Abril	437613,30	-482115,67	1357342,30	-968990,77	1844217,40
	Maió	590945,80	-702111,47	1884003,10	-1386614,66	2568506,30
	Junho	769325,10	-981686,06	2520336,30	-1908615,40	3447265,70
	Julho	589099,70	-804471,65	1982671,10	-1542183,77	2720383,20
2022	Agosto	775784,70	-1130263,80	2681833,20	-2139264,94	3690834,40
	Setembro	805426,70	-1248550,29	2859403,60	-2335860,02	3946713,40
	Outubro	804950,50	-1324509,36	2934410,30	-2451777,29	4061678,20

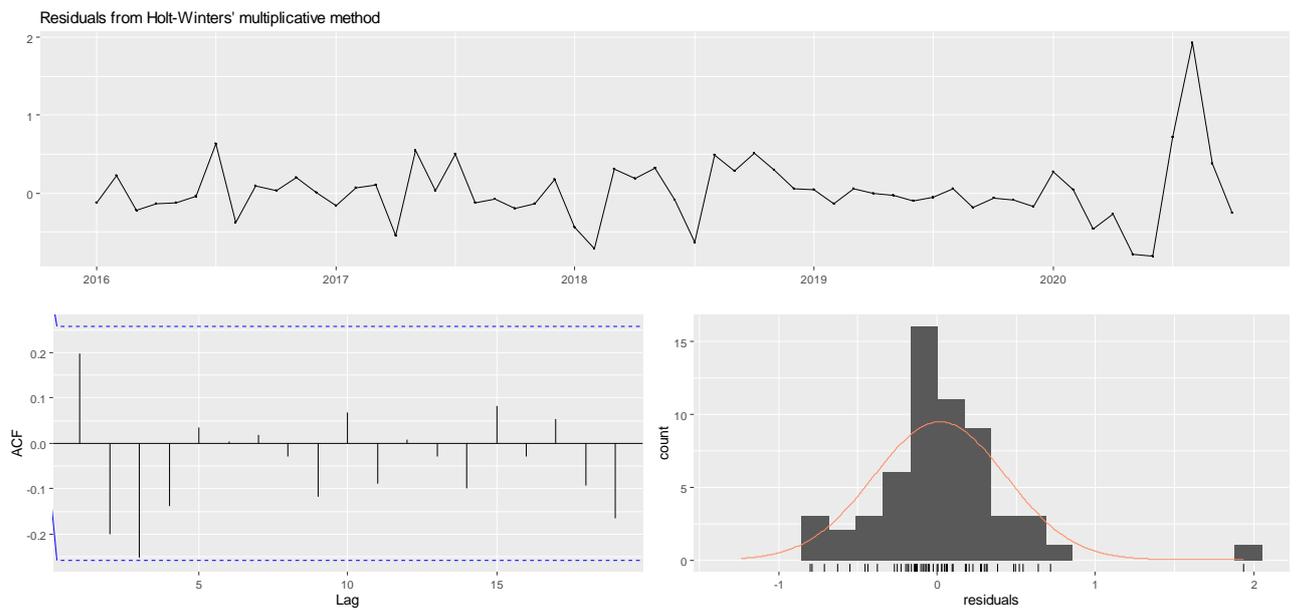
Fonte: O Autor (2021).

Figura 6 – Representação gráfica do método Holt-Winters multiplicativo



Fonte: O Autor (2021)

Figura 7 – Pressupostos dos erros do método Holt-Winters multiplicativo



Fonte: O Autor (2021)

4.2.4 Modelo Holt-Winters aditivo

O resultado da aplicação do método Holt-Winters aditivo é demonstrado na Tabela 8 e no Figura 8. Este modelo é apropriado quanto o período sazonal permanece durante um tempo. Semelhante ao resultado do método anterior, percebe-se que o mesmo comportamento entre os meses dos anos analisados, indicando certa sazonalidade de forma crescente. Assim, possuindo mesmo desempenho que o método multiplicativo.

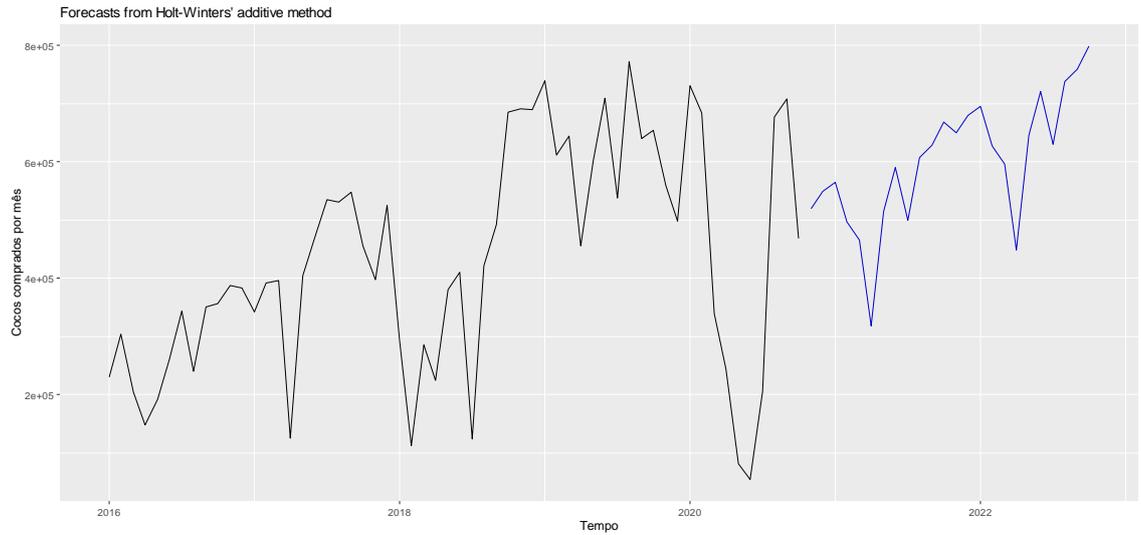
No comportamento dos erros, verifica-se certa variável dos erros durante o tempo (Figura 9). Também não existe correlação dos erros entre os anos analisados, e os resíduos dos erros são independentes. Esses resíduos possuem comportamento mais próximo de uma distribuição normal. Assim, indica que o método pode ser considerado mais confiável que o multiplicativo.

Tabela 8 – Resultado do método Holt-Winters aditivo

Ano	Mês	Previsão	Limite Inf (80%)	Limite Sup (80%)	Limite Inf (90%)	Limite Sup (90%)
2020	Novembro	519405,90	313254,92	725556,80	204125,20	834686,60
	Dezembro	549592,10	296082,67	803101,60	161882,87	937301,40
	Janeiro	565626,60	272297,52	858955,70	117018,48	1014234,70
	Fevereiro	497472,50	169108,40	825836,50	-4717,03	999661,90
	Março	465903,50	105889,60	825917,50	-84690,27	1016497,30
	Abril	318148,80	-70956,85	707254,40	-276936,94	913234,50
2021	Maio	515838,00	99662,00	932014,00	-120648,26	1152324,30
	Junho	590113,80	148516,97	1031710,70	-85250,30	1265478,00
	Julho	499581,40	33942,86	965219,90	-212551,28	1211714,10
	Agosto	607645,60	119140,96	1096150,20	-139457,77	1354748,90
	Setembro	629339,60	118986,38	1139692,80	-151178,27	1409857,40
	Outubro	668330,20	137020,42	1199640,00	-144237,98	1480898,40
	Novembro	649829,00	98347,38	1201310,60	-193589,35	1493247,30
	Dezembro	680015,20	109074,04	1250956,40	-193163,98	1553194,50
	Janeiro	696049,70	106285,50	1285814,00	-205916,83	1598016,30
	Fevereiro	627895,60	19885,76	1235905,40	-301975,18	1557766,30
	Março	596326,70	-29401,80	1222055,10	-360642,44	1553295,70
	Abril	448571,90	-194391,83	1091535,70	-534756,27	1431900,10
2022	Maio	646261,10	-13492,43	1306014,70	-362744,86	1655267,10
	Junho	720537,00	44405,90	1396668,00	-313516,26	1754590,20
	Julho	630004,50	-62121,05	1322130,00	-428510,18	1688519,20
	Agosto	738068,70	30305,70	1445831,70	-344361,39	1820498,80
	Setembro	759762,70	36696,15	1482829,20	-346072,15	1865597,50
Outubro	798753,30	60696,35	1536810,30	-330007,40	1927514,00	

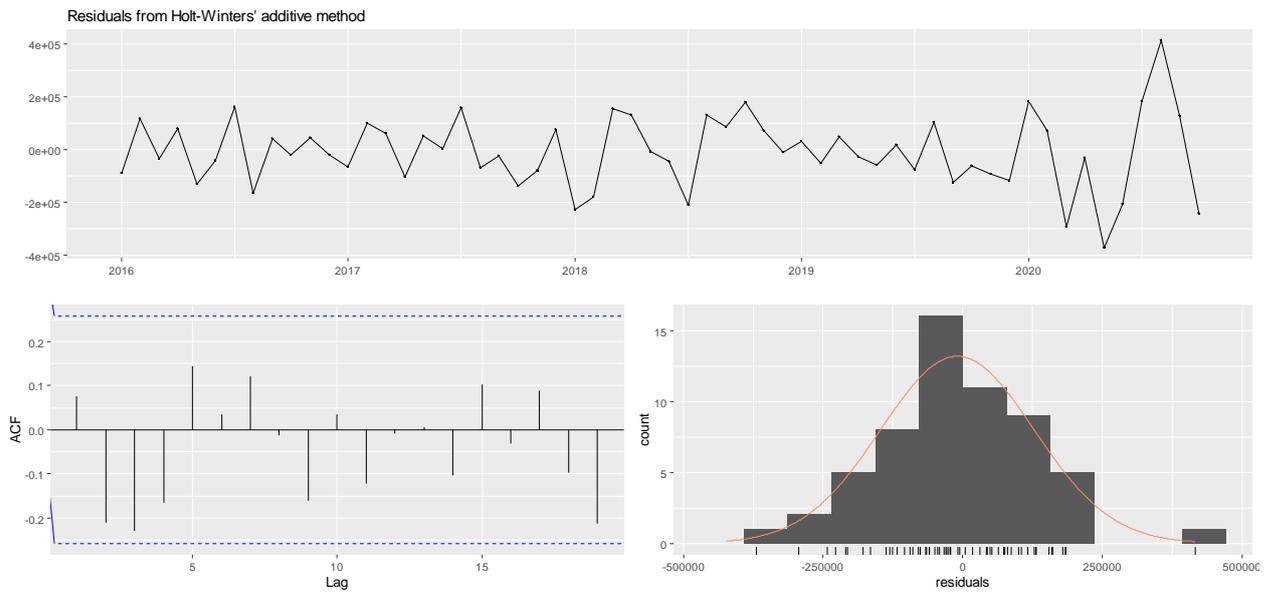
Fonte: O Autor (2021).

Figura 8 – Representação gráfica do método Holt-Winters aditivo



Fonte: O Autor (2021)

Figura 9 – Pressupostos dos erros do método Holt-Winters aditivo



Fonte: O Autor (2021)

4.2.5 Modelo Arima Auto Regressivo de Box & Jekins

A Tabela 9 apresenta os valores da previsão através do modelo Box & Jekins e na Figura 10 o seu comportamento. A previsão obteve bons valores até o mês de outubro de 2020, que após apresentou esse último valor de previsão para todo o restante do período. Assim, o método não possui bom desempenho.

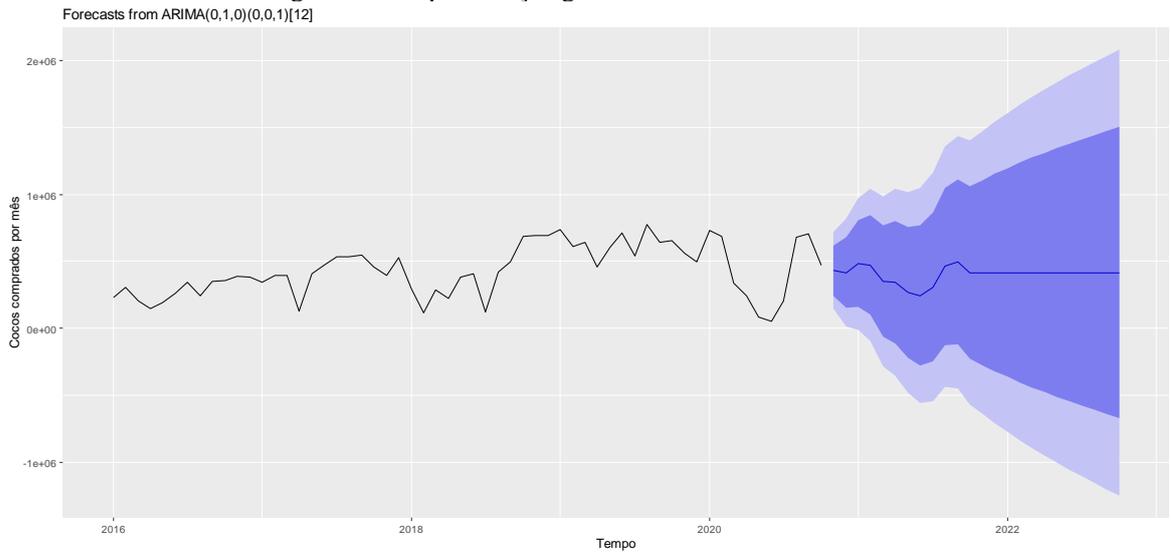
Os resultados dos pressupostos dos erros (Figura 11) demonstram a variação dos erros durante o tempo; no correlograma os valores dos resíduos dos erros estão dentro dos limites (mesmo alguns quase chegando no limite) e que existe correlação entre os tempos e são independentes; e no histograma os resíduos não apresentam uma distribuição normal. Esses resultados confirmam para considerar que este método não é confiável para o estudo de caso.

Tabela 9 – Resultado do método Box & Jekins

Ano	Mês	Previsão	Limite Inf (80%)	Limite Sup (80%)	Limite Inf (90%)	Limite Sup (90%)
2020	Novembro	430699,30	244813,24	616585,30	146411,12	714987,40
	Dezembro	414962,00	152079,48	677844,60	12917,86	817006,20
	Janeiro	482578,80	160614,71	804542,80	-9822,76	974980,30
	Fevereiro	473417,60	101646,99	845188,30	-95156,51	1041991,80
	Março	351209,60	-64441,67	766860,90	-284474,17	986893,40
	Abril	343239,00	-112083,48	798561,50	-353116,64	1039594,60
	Maiο	267364,40	-224439,60	759168,30	-484784,89	1019513,60
2021	Junho	244322,50	-281437,63	770082,60	-559758,22	1048403,20
	Julho	307593,60	-250058,89	865246,00	-545262,28	1160449,40
	Agosto	461631,20	-126185,80	1049448,20	-437357,33	1360619,80
	Setembro	494320,80	-122186,66	1110828,20	-448545,98	1437187,50
	Outubro	416255,90	-227664,89	1060176,70	-568535,96	1401047,80
	Novembro	416255,90	-275743,94	1108255,80	-642066,54	1474578,30
	Dezembro	416255,90	-320692,94	1153204,80	-710810,09	1543321,90
	Janeiro	416255,90	-363053,67	1195565,50	-775595,23	1608107,00
	Fevereiro	416255,90	-403227,60	1235739,40	-837035,96	1669547,80
	Março	416255,90	-441522,05	1274033,90	-895602,27	1728114,10
	Abril	416255,90	-478178,46	1310690,30	-951663,41	1784175,20
	Maiο	416255,90	-513390,61	1345902,40	-1005515,75	1838027,60
2022	Junho	416255,90	-547316,85	1379828,70	-1057401,45	1889913,30
	Julho	416255,90	-580088,54	1412600,40	-1107521,43	1940033,20
	Agosto	416255,90	-611816,11	1444327,90	-1156044,56	1988556,40
	Setembro	416255,90	-642593,41	1475105,20	-1203114,38	2035626,20
	Outubro	416255,90	-672501,04	1505012,80	-1248854,15	2081366,00

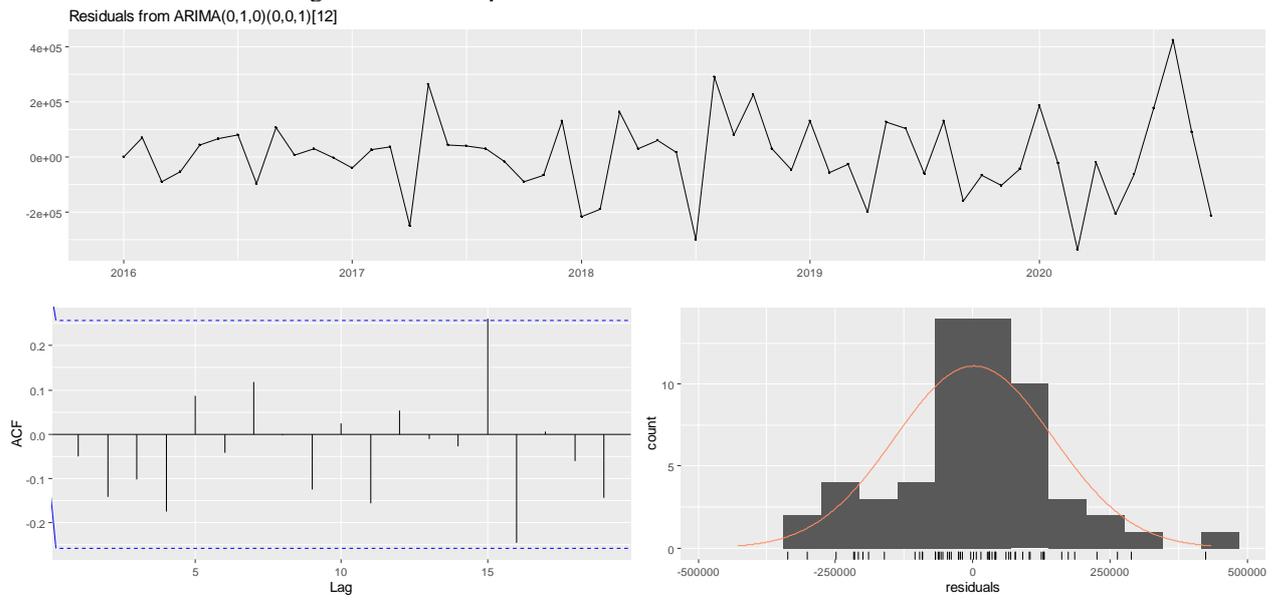
Fonte: O Autor (2021).

Figura 10 – Representação gráfica do método Box & Jenkins



Fonte: O Autor (2021)

Figura 11 – Pressupostos dos erros do método Box & Jenkins



Fonte: O Autor (2021)

4.3 Definição do modelo mais adequado

Conforme o objetivo do trabalho, o método mais adequado para o estudo de caso a ser utilizado no processo de tomada de decisão para previsão de demanda por meio da técnica com melhor resultado, é baseado em mensurar os erros calculados. Nesse sentido, buscou verificar a comparação dos últimos cinco meses que possuem demanda reais já realizadas, identificando o comportamento da demanda real e prevista. A Tabela 10 apresenta a comparação entre os métodos com melhores resultados conforme os erros. A Tabela 11 apresenta os resultados dos testes de normalidade e do teste t.

Tabela 10 – Comparação entre os erros dos métodos e demanda real

Mês e ano	Demanda real	Demandas previstas									
		STLF	Diferença (%)	AUTOREG. NEURAL	Diferença (%)	HOLT MULTI.	Diferença (%)	HOLT ADITIVO	Diferença (%)	BOX & JEKINS	Diferença (%)
Novembro 2020	350455	485657,60	38,58%	468649,70	33,73%	486256,20	38,75%	519405,90	48,21%	430699,30	22,90%
Dezembro 2020	320300	500556,10	56,28%	427358,90	33,42%	509192,30	58,97%	549592,10	71,59%	414962,00	29,55%
Janeiro 2021	413500	489772,30	18,45%	401997,10	-2,78%	536148,30	29,66%	565626,60	36,79%	482578,80	16,71%
Fevereiro 2021	326300	430054,70	31,80%	343456,90	5,26%	529362,10	62,23%	497472,50	52,46%	473417,60	45,09%
Março 2021	330823	379701,40	14,77%	302519,10	-8,56%	492644,90	48,91%	465903,50	40,83%	351209,60	6,16%
Total	1741378	2285742	31,26%	1943982	11,63%	2553604	46,64%	2598001	49,19%	2152867	23,63%

Fonte: Autoria própria (2021)

Tabela 11- Resultados dos testes de normalidade e teste t.

Dados	Shapiro-Wilk (p-value)	Kolmogorov-Smirnov (p-value)	Lilliefors (p-value)	Dados	Teste t (p-value)
Real	0,788 (0,06447)	0, 27724 (0,7514)	0, 27724 (0,2337)	-	-
STLF	0,85533 (0,212)	0,31111 (0,6201)	0,31111 (0,1147)	Real x STLF	-3,8110 (0,0060)
AUTOREG. NEURAL	0,97358 (0,8977)	0,17901 (0,9882)	0,17901 (0,8625)	Real x AUTOREG. NEURAL	-1,1855 (0,2780)
HOLT MULTI.	0,91894 (0,5231)	0,20247 (0,9577)	0,20247 (0,7171)	Real x HOLT MULTI.	-8,2518 (0,0001)
HOLT ADITIVO	0,97307 (0,8945)	0,17347 (0,9918)	0,17347 (0,8899)	Real x HOLT ADITIVO	-6,9310 (0,0001)
BOX & JEKINS	0,92816 (0,5839)	0,19217 (0,9745)	0, 19217 (0,7871)	Real x BOX & JEKINS	-2,8302 (0,0243)

Fonte: Autoria própria (2021)

Analisando a demanda real obtida nos últimos meses, percebe-se que a maioria dos métodos indicaram um valor maior que a demanda prevista para quase todos os meses analisados. Isso aconteceu devido alguns aspectos que influenciaram na compra de coco: no final do ano houve redução de oferta do fruto, pois fatores climáticos, como o calor, afetam a oferta de coco verde. É preciso salientar que elevadas temperaturas fazem com que a comercialização do coco verde seja direcionada para a venda do fruto in natura, não restando uma oferta razoável para a indústria. Por tanto, a valorização do coco verde in natura acaba por impactar a demanda; e no começo do ano a demanda por produtos no portfólio da empresa diminuiu. Mesmo assim, pode-se identificar que o método Arima de Box & Jenkins teve um comportamento semelhante a demanda real.

Embora o método STLF tenha sido considerado o mais adequado a ser utilizado devido aos melhores parâmetros de análise dos erros (Tabela 4), sua previsão se distanciou dos verdadeiros valores de demanda, repercutindo em um erro de 31,26% no acumulado dos cinco meses analisados. Alguns estudos, como Dantas e Oliveira (2015), se limitam a analisar parâmetros de erros como o MAPE e o RMSE. Por outro lado, acredita-se que a não verificação do poder de previsão com dados de teste acabada por não indicar corretamente, em alguns casos, qual modelo é o mais apropriado, sendo fundamental a comparação dos dados previstos com dados de teste (novos dados reais) para assegurar bom desempenho do modelo (ARAÚJO et al., 2020). Sem essa verificação, muitos engenheiros de produção poderiam escolher o método STLF e obter erros de previsão superiores a 56% (para o mês de dezembro 2020), algo muito prejudicial para a empresa.

Os métodos de Holt-Winter Aditivo e Holt-Winter Multiplicativo apresentaram erro acumulado superior a 40% no acumulado dos cinco meses analisados, alcançando um erro de 62,23% para fevereiro de 2021 (Holt-Winter Multiplicativo) e 71,59% para dezembro de 2020 (Holt-Winter Aditivo). Tais resultados, embora sugeriram que os métodos são ruins, na realidade isso não é bem a verdade. Os métodos de Holt-Winter são muito bem referenciados na literatura, contudo não se mostraram apropriados para a previsão da empresa estudo de caso, principalmente, em um período de incertezas muito grandes trazidas por uma pandemia mundial.

O método ARIMA de Box-Jenkins apresentou um erro moderado, gerando na casa dos 23% para o período dos cinco meses analisados, com destaque para o mês de março de 2021

que apresentou erro de 6,16%. Contudo, o que penalizou o desempenho desse método de previsão foi o mês de fevereiro de 2021, no qual o erro foi superior a 45%. Logo, a utilização desse método para previsão pela empresa estudo de caso deve ser feita com bastante cautela, dado que pode o mesmo apresentar precisão significativa quanto pode apresentar um grande erro de previsão. Ciente, que os métodos de previsão têm como objetivo auxiliar o gestor na tomada de decisão, não se pode desconsiderar, na totalidade, uso desse método de previsão, sendo a experiência do gestor um divisor de águas para o uso desse método pra o caso em questão. Estudo prévios, a exemplo, de Rodrigues et al. (2008) mostraram que o modelo de Box-Jenkins apresenta razoável poder de previsão, mas ainda sim necessita de um olhar do especialista para não gerar erros maiores. Ainda assim, seu uso não deve ser subestimado, pois seu poder de previsão tem se mostrado elevado em alguns casos (BORGES; LANDIM, 2018).

Por fim, o método de Autorregressão Neural se mostrou o mais preciso. Muito embora os meses de novembro e dezembro de 2020 tenham prejudicado o desempenho desse método, como valores de erro superiores a 33%, houve uma recuperação de desempenho nos meses seguintes, chegando a um erro acumulado de 11,63% para período de 5 meses analisado. Nunca é demais destacar que apenas uma variável (quantidade de coco verde comprada) foi utilizada como entrada desse modelo, sendo muito maior o poder de previsão dos métodos que fazem uso de redes neurais quando mais variáveis (múltiplos inputs de dados), mais neurônios na camada oculta e mais camadas ocultas (*deep learning*) são utilizados na determinação de padrões (FERNANDES et al., 1995; BATTAGELLO et al., 2004; MANO; ANTENEODO, 2009).

Tanto os dados reais quanto os preditos pelos cinco modelos apresentaram distribuição, ou seja, p-value maior que 0,05, permitindo a utilização do teste t para comparação dos valores (Tabela 11). Ficou evidenciado que apenas o método de Autorregressão Neural não apresentou diferença significativa na comparação entre os dados reais e os dados preditos, com valor da estatística do teste t igual a -1,1855 com p-value igual a 0,2780 (Tabela 11). Portanto, como o p-value foi maior que o nível de significância ($\alpha = 0,05$), logo não se pode rejeitar a hipótese de que os valores preditos e reais sejam, significativamente, iguais, ou seja, não se pode afirmar que os dados reais e preditos pelo método de Autorregressão Neural que são estatisticamente diferentes.

A aplicação de métodos confiáveis é relevante para estratégia da empresa, visando obter tomada de decisão mais assertiva para estimativas e situações futuras. Especificamente, a

previsão de demanda impacta no planejamento agregado de produção e, conseqüentemente, na geração de estoque, e em sua capacidade produtiva mais eficiente.

5. CONSIDERAÇÕES FINAIS

O objetivo deste trabalho foi alcançado, visto que buscou analisar a aplicação de diferentes métodos de previsão de demanda, verificando qual melhor se adequa para uma empresa do setor de produção de derivados de coco.

A produção da empresa oscila de acordo a sazonalidade ao longo do ano por condições climáticas (verão e inverno), tanto para a obtenção do fruto, quanto para escoamento da produção de produto acabado. A aplicação de um modelo de previsão de demanda se torna um forte aliado para o planejamento estratégico da empresa.

O trabalho se preocupou em ampliar opções de técnicas na tentativa de escolher o que melhor se adequa, agregando conhecimento sobre o tema. Após as análises, foram obtidos os cinco melhores métodos para este estudo de caso, que confirma a combinação dos menores erros obtidos: STFL, Auto regressão neural, Holt Multiplicativo, Holt Aditivo e Box & Jenkins. As previsões foram analisadas, verificando além do erro, o comportamento da previsão e dos pressupostos dos erros que foram importantes para confirmar o bom desempenho dos métodos.

Com base nos resultados, o método de Autorregressão Neural apresentou-se com a melhor adequação e sua previsão foi a mais próxima da realidade, mesmo em um cenário que teve influência direta da pandemia. Ainda assim, vale destacar que mesmo com esse fator atípico, o ano de 2020 teve uma produção maior que os anos de 2016, 2017 e 2018, o que mostra um cenário ainda crescente e com grande potencial ao longo dos próximos anos.

A implementação do método de previsão como ferramenta confiável impacta de forma positiva nas ações estratégicas da empresa, dando suporte para a tomada de decisão, melhorando o processo produtivo e potencializando os resultados financeiros.

Vale ressaltar que esse foi um estudo univariado. Se indicadores econômicos, políticos e sociais fossem inseridos nos modelo de previsão, a precisão aumentaria, especialmente em grandes sazonalidades. Outra limitação foi a impossibilidade de analisar os dados fora de período pandêmico, sendo importante ver o poder de previsão dos modelos para situações normais.

A aplicação do método de previsão de demanda é bastante ampla, como também a gama de técnicas é diversa. Assim, como sugestão para trabalhos futuros realizar aplicação das técnicas utilizadas neste estudo em outros setores produtivos ou produtos.

Em análises futuras, podem ser estudados mais linhas de produtos da mesma empresa para serem mais exploradas pelos modelos de previsão de demanda, verificando a diferença de comportamento, e também em relação a fatores de vendas e finanças.

Outra sugestão é em relação a questão do tempo. Os modelos de previsão trabalham melhor quando uma série de dados maior é utilizada, assim estudos futuros devem utilizar conjunto de dados maiores, tanto de treinamento, quanto de teste.

Além disso, a aplicação de métodos que integram análise qualitativa e quantitativa, buscando extrair os dados históricos com análise qualitativa de especialistas.

6. REFERÊNCIAS

ANDRADE, A. M.; PASSOS, P. R. A.; MARQUES, L. G. C.; OLIVEIRA, L. B.; VIDAURRE, G. B.; ROCHA, J. D. S. Pirolise de resíduos do coco-da-baía (*cocos nucifera* Linn) e análise do carvão vegetal. **Revista Arvore**, v. 28, n. 5, p. 707-714, 2004.

ARAGÃO, W. M.; RAMOS, S. R. R.; ALVES, M. C. S. Cultivares de coqueiro. In: FONTES, H. R.; FERREIRA, J. M. S. **A cultura do coqueiro**. 2ª Ed. Brasília: Embrapa Tabuleiros Costeiros, 2016, n. 1, p. 9-11.

ARAUJO, G. C.; SILVA, J. P. Z.; SOUZA, L. R.; LOUREIRO, M. B.; FERONI, R. C. Previsão de demanda e análise simplificada da gestão de estoque aplicada a uma empresa do setor alimentício. **Brazilian Journal of Production Engineering**, v. 4, n. 2, p. 48-64, 2018.

BRAINER, M. S. C. F. Produção e coco: o Nordeste é destaque nacional. **Caderno Setorial ETENE**, v. 3, n. 61, 2018.

CARVALHO, L. R. **Previsão de demanda de material de saúde na Marinha do Brasil**. Dissertação de Mestrado (Mestrado Profissional em Engenharia de Produção). Pontifca Universidade Católica do Rio de Janeiro, Rio de Janeiro - RJ, 2018.

CASULA, H. C. **Aplicação de técnicas de previsão de demanda em manufatura: estudo de caso em uma indústria de laminados**. Dissertação de Mestrado (Mestrado Profissional em Engenharia de Produção). Universidade Estadual de Campinas, Campinas - SP, 2012.

CONDÉ, M. Estudo e previsão de demanda aeroportuária para a cidade do Rio de Janeiro. **RELIT – Revista de Literatura dos Transporte**, v. 5, n. 1, p. 161-183, 2010.

CORRÊA, H. L.; CORRÊA, C. A. **Administração de Produção e de Operações. Manufatura e serviços: uma abordagem estratégica**. São Paulo: ATLAS. 2009. 690 p.

CUENCA, M. A. G. Importância econômica da cocoicultura no Brasil. In: FONTES, H. R.; FERREIRA, J. M. S. **A cultura do coqueiro**. 2ª Ed. Aracaju: Embrapa Tabuleiros Costeiros, 2016, n. 1, p. 45-48.

CUENCA, M. A. G. Aspectos da comercialização e mercados do coco. In: FONTES, H. R.; FERREIRA, J. M. S. **A cultura do coqueiro**. 2ª Ed. Aracaju: Embrapa Tabuleiros Costeiros, 2016, n. 1, p. 2-3.

FERNANDES, F. C. F.; GODINHO FILHO, M. **Planejamento e controle da produção: dos fundamentos ao essencial**, São Paulo: Editora Atlas. 2010. 275 p.

GEOMELOS, N. D.; XIDEAS, E. Forecasting spot prices in bulk shipping using multivariate and univariate models. **Cogent Economics & Finance**, v. 2, n. 1, 932701, 2014.

IBGE - Instituto Brasileiro de Geografia e Estatística. Sistema IBGE de Recuperação Automática – SIDRA. **Produção Agrícola Municipal**. Disponível em: <<https://sidra.ibge.gov.br/tabela/5457>>. Acesso em: 15 de maio de 2020.

KRAJEWSKI, L.; RITZMAN, L.; MALHOTRA, M. **Administração de produção e operações**. 8ª edição. São Paulo: Pearson Prentice Hall, 2009. 636 p.

MANCUZO, F. **Análise e previsão de demanda: estudo de caso em uma empresa distribuidora de rolamentos**. Dissertação de Mestrado (Mestrado Profissional em Engenharia). Universidade federal do Rio Grande do Sul, Porto Alegre - RS, 2003.

MARTINS, A. P.; SILVA, P. L. R.; WATANABE, T.; BORELLI, C.; MARCIANO, J. P. P.; SANCHES, R. A. O problema do pós-consumo do coco no Brasil: alternativas e sustentabilidade. **Sustentabilidade em Debate**, v. 7, n. 1, p. 44-57, 2016.

MARTINS, C. R.; JESUS JUNIOR, L. A. **Produção e comercialização de coco no Brasil frente ao comércio internacional: panorama 2014**. Documento 164. Aracaju: Embrapa Tabuleiros Costeiros, 2013. 51 p.

MOREIRA, D. A. **Administração da produção e operações**. 2ª Edição. São Paulo: Cengage Learning, 2008. 640p.

MORESI, E. **Metodologia de pesquisa**. Brasília: Universidade Católica de Brasília - UCB. 2003. 108 p.

OLIVEIRA, E. S.; DOURADO, J. D. A.; MELLO, J. A. V. B. Aplicação de modelos de previsão de demanda em uma fábrica de embalagens plásticas. **Revista da Universidade Vale do Rio Verde**, v. 15, n. 2, p. 354-373, 2017.

PASSOS, E. E. M. Exigências climáticas do coqueiro. In: FONTES, H. R.; FERREIRA, J. M. S. **A cultura do coqueiro**. 2ª Ed. Aracaju: Embrapa Tabuleiros Costeiros, 2016, n. 1, p. 3-7.

PEINADO, J.; GRAEML, A. R. **Administração da produção (operações industriais e de serviços)**. Curitiba: UnicenP, 2004. 750 p.

QUEIROZ, A. A.; CAVALHEIRO, D. **Método de previsão de demanda e detecção de sazonalidade para o planejamento da produção de indústrias de alimentos**. XXIII Encontro Nacional de Engenharia de Produção – ENEGEP, Ouro Preto-MG, 2003.

REIS, J. G. M.; URIO, L. C. S.; MACHADO, S. T.; SANTOS, R. Previsão de demanda no mercado de varejo: um estudo de caso em um comércio de baterias automotivas. **South American Development Society Journal**, v. 1, n. 1, p. 1-15, 2015.

RITZMAN, L. P. e KRAJEWSKI, L. J. **Administração da produção e operações**. São Paulo: Pearson Prentice Hall, 2004.

ROSSETTO, M.; DEIMLING, M. F.; ZANIN, A.; RODRIGUES, M. P.; ROCHA NETO, A. **Técnicas qualitativas de previsão de demanda: um estudo multicase com empresas do ramo de alimentos**. VIII Simpósio de Excelência em Gestão e Tecnologia - SEGeT, 2011.

SIQUEIRA, L. A.; ARAGÃO, W. M.; TUPINAMBÁ, E. A. **A introdução do coqueiro no Brasil: importância histórica e agronômica**. Documento 47. Aracaju: Embrapa Tabuleiros Costeiros, 24 p., 2002.

SILVA, A. C. Reaproveitamento da casca de coco verde. **Revista Monografias Ambientais - REMOA**, v. 13, n. 5, p. 4077-4086, 2014.

SLACK, N.; CHAMBERS, S.; JOHNSTON, R. **Administração da Produção**. 3ª edição. São Paulo: Atlas, 2009.

SLACK, N.; JONES, A. B.; JOHNSNTON, R. **Administração da produção**. 8ª edição. São Paulo: Atlas, 2018. 652 p.

SOUZA, R. M. **Sinais envolvidos na comunicação de *Amerrhinus Ynca Sahlberg, 1823* (coleóptera: curculinidae)**. Dissertação de Mestrado (Mestrado em Produção Vegetal). Universidade Estadual do Norte Fluminense, Centro de Ciências e Tecnologia Agropecuárias, Campos dos Goytacazes-RJ, 2006.

SOUZA, R. S.; TRIERWEILLER, A. C.; WEISE, A. D.; ROCHA, R. A.; MONTEIRO, M. I. Previsão da Demanda como suporte para o Planejamento e Controle da Produção na Sigma – Indústria Eletro Eletrônica. **INGEPRO – Inovação, Gestão e Produção**, v. 3, n. 4, 2011.

SOUZA, A. C. C.; RODRIGUES, A. L.; PACHECO, D. A. J. Métodos quantitativos de previsão de demanda aplicados em orçamento de despesas. **Espacios**, v. 36, n. 10, 2015.

TUBINO, D. F. **Planejamento e controle da produção - Teoria e Prática**. 2ª Edição. São Paulo: Atlas, 2009.

ZANELLA, L. C. H. **Metodologia de pesquisa**. 2ª Edição. Florianópolis: Departamento de Ciências da Administração/UFSC, 2011. 134p.

HYNDMAN, R.J., & ATHANASPOULOS, G. (2018). **Forecasting: principles and practice**. 2nd edition, OTexts: Melbourne, Australia. Disponível em: < <https://otexts.com/fpp2/>>. Acesso em: 18 de maio de 2021.

BAZIEWICZ, C. M. **Análise de uma metodologia de classificação de séries temporais para definição dos métodos de previsão**. Dissertação de Mestrado em Métodos Numéricos em Engenharia da Universidade Federal do Paraná, Curitiba, 2019.

COSTA, C. M. F. **Desenvolvimento de Modelos de Previsão de Variáveis Climáticas**. Dissertação de Mestrado em Estatística da Universidade do Minho, Escola de Ciências, Braga - Portugal, 2019.

HYNDMAN, R.J.; BILLAH, B. Unmasking the Theta method. **International J. Forecasting**, 19, 287-290, 2003.

HYNDMAN, R. J.; KING, M. L.; PITRUN, I.; BILLAH, B. Local linear forecasts using cubic smoothing splines. **Australian and New Zealand Journal of Statistics**, 47(1), 87-99, 2005.

LIMA, M. B. S. P.; SANTOS, W. B.; DORGUETT, E. L.; DINIZ, H. H. L.; SANTOS, R. C. B. **Aplicação do modelo de previsão de demanda holt-winters em uma regional de corte e dobra de aço.** XXXV Encontro Nacional de Engenharia de Produção – ENEGEP, Fortaleza-CE, 2015.

RODRIGUES, R. S. **Modelos de previsão de demanda e análises do cenário aeronáutico brasileiro.** Monografia de Graduação em Engenharia Aeroespacial da Universidade Federal de Minas Gerais, Belo Horizonte, 2018.

MAIA, Rodrigo Gomes Távora. **MÉTODOS DE PESQUISA OPERACIONAL NA DEFINIÇÃO DE METAS PARA INDICADORES DE SUSTENTABILIDADE EM UMA EMPRESA DO SETOR ELÉTRICO BRASILEIRO NO CONTEXTO DA AGENDA 2030.** Rio de Janeiro. 2019. Disponível em: <<http://monografias.poli.ufrj.br/monografias/monopoli10030951.pdf>>. Acesso em: 06 de maio de 2021.

BEHERA, H. S. **A hybrid ETS–ANN model for time series forecasting.** 2017. Disponível em: <<https://www.sciencedirect.com/science/article/abs/pii/S0952197617301550>>. Acesso em: 05 de maio de 2021.

DANTAS, Tiago Mendes; OLIVEIRA, Fernando Luiz Cyrino. **BAGGING ARIMA PARA PREVISÃO DE DEMANDA DE TRANSPORTE AÉREO.** Rio de Janeiro. 2015. Disponível em: <http://www.abepro.org.br/biblioteca/TN_STO_211_253_27492.pdf>. Acesso em: 06 de maio de 2021.

ARAÚJO, C. B. C. et al. **Previsão Sazonal de Vazões para a Bacia do Orós (Ceará, Brasil) Utilizando Redes Neurais e a Técnica De Reamostragem dos K-vizinhos.** 2020. Disponível em: <https://www.scielo.br/scielo.php?script=sci_arttext&pid=S0102-77862020000200197&tlng=pt>. Acesso em: 06 de maio de 2021.

PAULISTA, Paulo Henrique; RODRIGUES, Gabriel Alves; TURRIONI, João Batista. **PREVISÃO DO PREÇO DA ENERGIA: UMA APLICAÇÃO DA METODOLOGIA BOX-JENKINS.** Rio de Janeiro. 2008. Disponível em: <http://www.abepro.org.br/biblioteca/enegep2008_tn_wic_070_498_11575.pdf>. Acesso em: 05 de maio de 2021.

BORGES, Emanuel de Jesus Ramos Correia; LANDIM, Jeremias Lopes. **Previsão de vendas com modelo ARIMA BOX E JENKINS.** Cabo Verde. 2018. Disponível em: <https://www.researchgate.net/publication/298348418_Previsao_de_vendas_com_modelo_ARIMA_BOX_E_JENKINS>. Acesso em: 06 de maio de 2021.

FERNANDES, Luiz Gustavo L.; NAVAUX, Philippe O. A.; PORTUGAL, Marcelo Savino. **Previsão de Séries de Tempo: Redes Neurais Artificiais e Modelos Estruturais**. Porto Alegre.1995.Disponívelem:

<<https://gmap.pucrs.br//files/publications/articles/5afca684be812ed8e2a901173d20e6b6.pdf>.

>Acesso em: 10 de maio de 2021.

BATTAGELLO, Vinícius Antonio; CORDEIRO, Marciso Xavier; DAL PINO Jr, Arnaldo. **REDES NEURAS APLICADAS À PREVISÃO DE SÉRIES TEMPORAIS**. São José dos Campos. 2004. Disponível em:< <http://www.bibl.ita.br/xiencita/Artigos/Fund17.pdf>>. Acesso em: 10 de maio de 2021.

MANO, João Pedro; ANTENEODO, Célia. **Previsão de séries temporais mediante redes neurais**.2009.Disponívelem:<https://www.puc-rio.br/ensinopesq/ccpg/pibic/relatorio_resumo2009/relatorio/fis/joao_pedro.pdf>. Acesso em: 10 de maio de 2021.

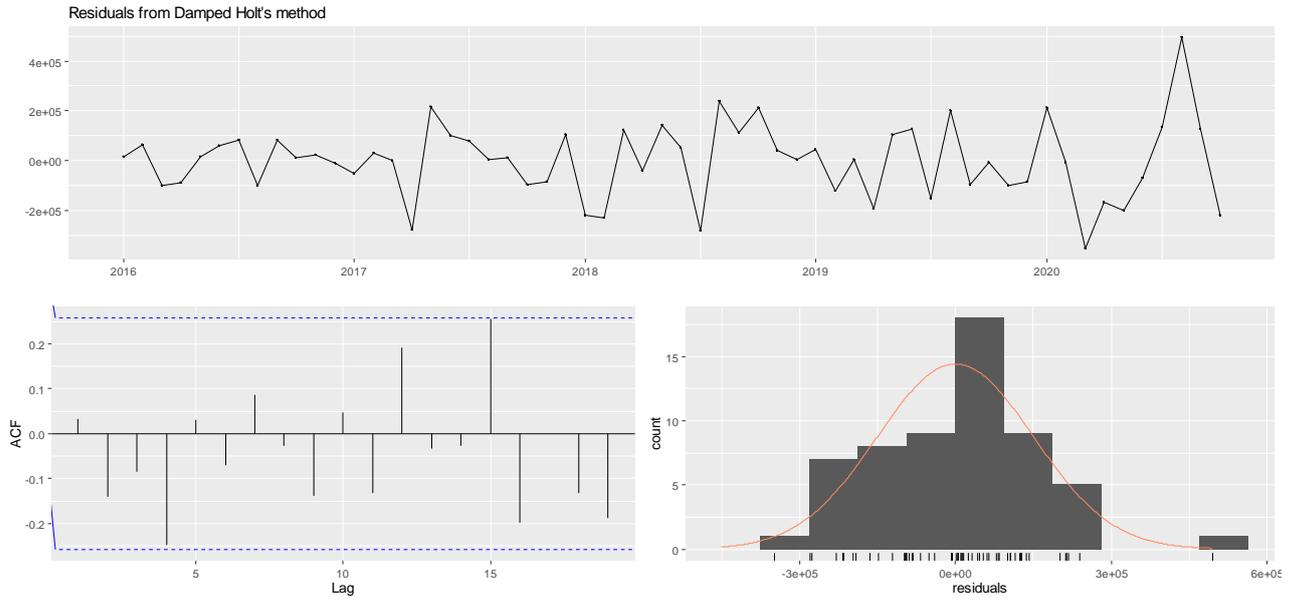
ANEXO A - Modelo de Holt com “Damp”

Tabela Anexo A – Resultado do método Holt com “Damp”

Ano	Mês	Previsão	Limite Inf (80%)	Limite Sup (80%)	Limite Inf (90%)	Limite Snf (80%)
2020	Novembro	513225,20	313069,72	713380,60	207113,83	819336,50
	Dezembro	514619,10	258055,53	771182,70	122238,96	906999,30
	Janeiro	515960,70	213316,46	818604,90	53106,29	978815,10
	Fevereiro	517251,70	174661,77	859841,70	-6694,40	1041197,90
	Março	518494,20	140145,49	896843,00	-60140,23	1097128,70
	Abril	519690,00	108675,43	930704,50	-108902,52	1148282,50
2021	Maio	520840,70	79566,16	962115,30	-154030,49	1195711,90
	Junho	521948,20	52354,26	991542,10	-196233,74	1240130,10
	Julho	523014,00	26709,24	1019318,70	-236018,62	1282046,60
	Agosto	524039,70	2385,68	1045693,70	-273761,26	1321840,60
	Setembro	525026,80	-20804,48	1070858,00	-309750,10	1359803,60
	Outubro	525976,70	-43009,08	1094962,60	-344211,97	1396165,40
	Novembro	526891,00	-64346,73	1118128,70	-377329,06	1431111,00
	Dezembro	527770,80	-84914,34	1140455,90	-409250,26	1464791,80
	Janeiro	528617,50	-104792,22	1162027,20	-440099,08	1497334,10
	Fevereiro	529432,40	-124047,79	1182912,60	-469979,30	1528844,10
	Março	530216,60	-142738,28	1203171,50	-498979,07	1559412,30
	Abril	530971,30	-160912,75	1222855,30	-527174,04	1589116,60
2022	Maio	531697,60	-178613,62	1242008,80	-554629,67	1618024,90
	Junho	532396,60	-195877,85	1260671,00	-581403,04	1646196,20
	Julho	533069,30	-212737,84	1278876,40	-607544,27	1673682,80
	Agosto	533716,60	-229222,22	1296655,50	-633097,66	1700531,00
	Setembro	534339,70	-245356,40	1314035,70	-658102,57	1726781,90
	Outubro	534939,20	-261163,05	1331041,50	-682594,15	1752472,60

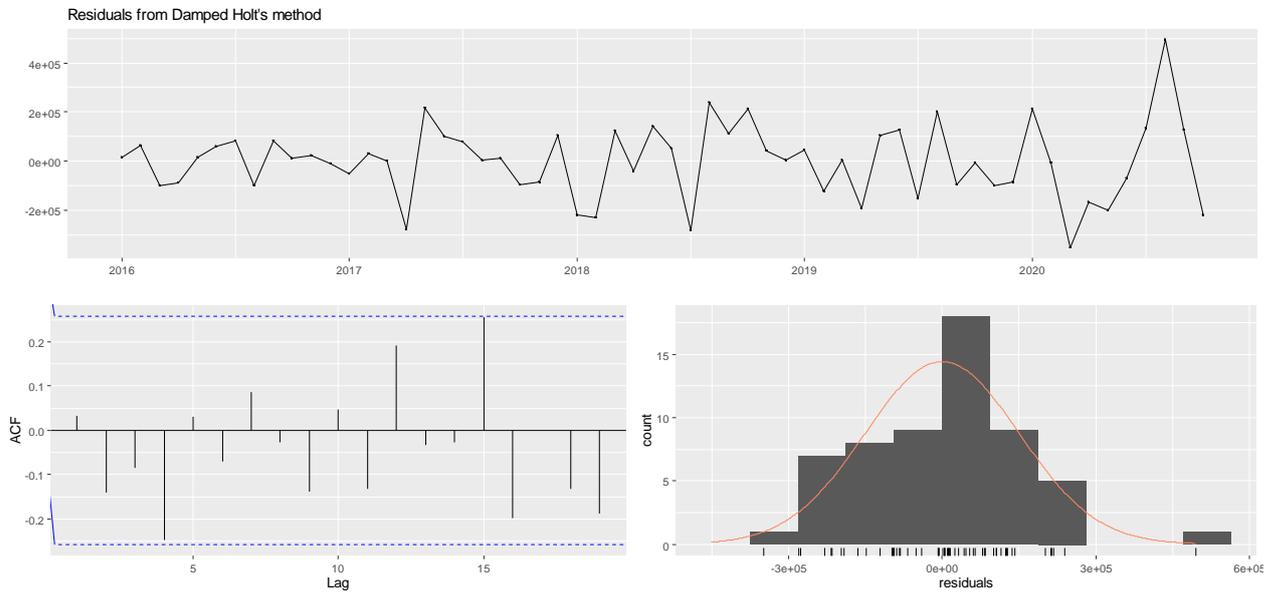
Fonte: Autoria própria (2021)

Figura Anexo A – Representação gráfica do método Holt com “Damp”



Fonte: Autoria própria (2021)

Figura Anexo A – Pressupostos dos erros do método Holt com “Damp”



Fonte: Autoria própria (2021)

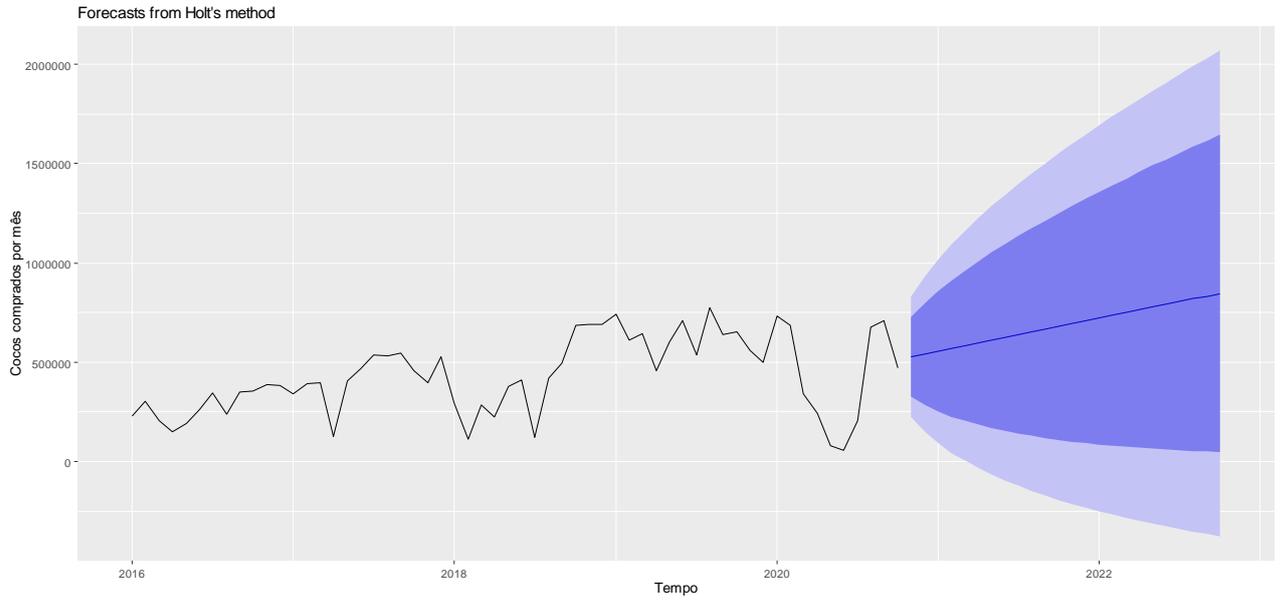
ANEXO B - Modelo de Holt

Tabela Anexo B – Resultado do método Holt

Ano	Mês	Previsão	Limite Inf (80%)	Limite Sup (80%)	Limite Inf (90%)	Limite Snf (80%)
2020	Novembro	527144,60	328253,48	726035,60	222966,90	831322,20
	Dezembro	541014,30	285057,60	796971,10	149562,30	932466,40
	Janeiro	554884,10	252433,37	857334,80	92325,63	1017442,50
	Fevereiro	568753,90	226050,72	911457,00	44634,63	1092873,10
	Março	582623,60	203914,16	961333,10	3437,48	1161809,80
	Abril	596493,40	184907,81	1008078,90	-32972,43	1225959,20
2021	Maio	610363,10	168332,70	1052393,60	-65664,09	1286390,40
	Junho	624232,90	153716,63	1094749,20	-95359,64	1343825,50
	Julho	638102,70	140722,90	1135482,40	-122574,04	1398779,40
	Agosto	651972,40	129101,40	1174843,50	-147689,80	1451634,70
	Setembro	665842,20	118660,32	1213024,10	-171000,27	1502684,70
	Outubro	679712,00	109248,71	1250175,20	-192736,30	1552160,20
	Novembro	693581,70	100745,28	1286418,20	-213083,38	1600246,80
	Dezembro	707451,50	93050,80	1321852,20	-232193,27	1647096,20
	Janeiro	721321,20	86082,89	1356559,60	-250191,98	1692834,50
	Fevereiro	735191,00	79772,25	1390609,80	-267185,49	1737567,50
	Março	749060,80	74059,91	1424061,60	-283263,96	1781385,50
	Abril	762930,50	68895,24	1456965,80	-298504,85	1824365,90
2022	Maio	776800,30	64234,35	1489366,30	-312975,29	1866575,90
	Junho	790670,10	60038,89	1521301,20	-326733,89	1908074,00
	Julho	804539,80	56275,16	1552804,50	-339832,23	1948911,90
	Agosto	818409,60	52913,32	1583905,80	-352315,92	1989135,10
	Setembro	832279,30	49926,82	1614631,90	-364225,59	2028784,30
	Outubro	846149,10	47291,90	1645006,30	-375597,57	2067895,80

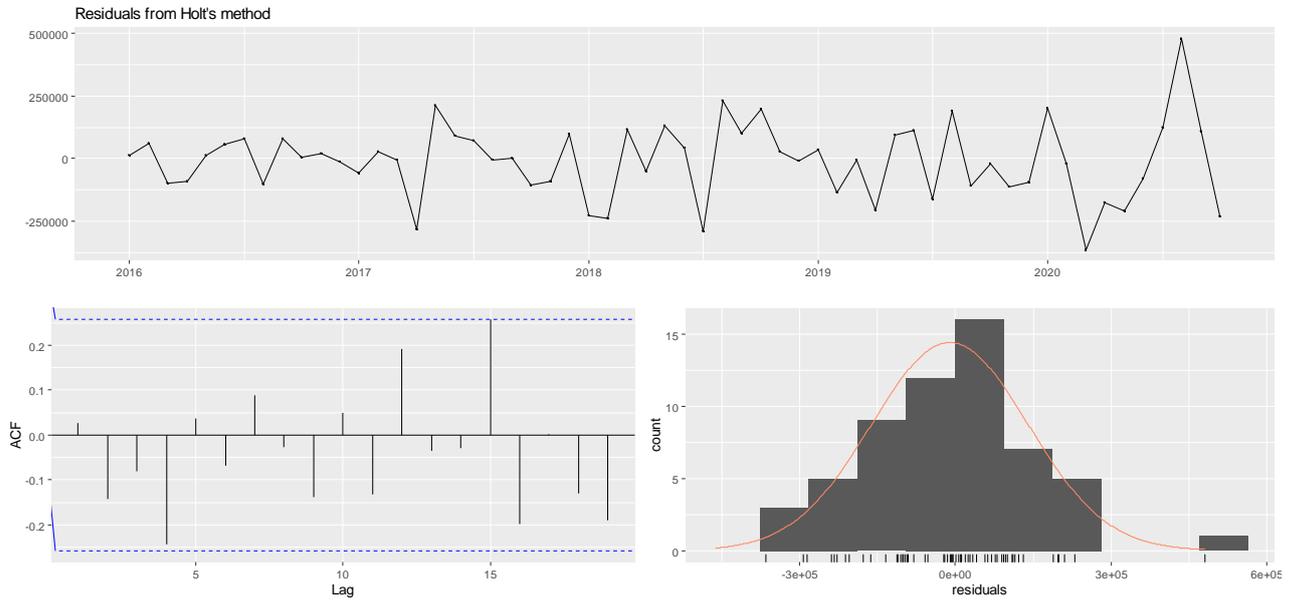
Fonte: Autoria própria (2021)

Figura Anexo B – Representação gráfica do método Holt



Fonte: Autoria própria (2021)

Figura Anexo B – Pressupostos dos erros do método Holt



Fonte: Autoria própria (2021)

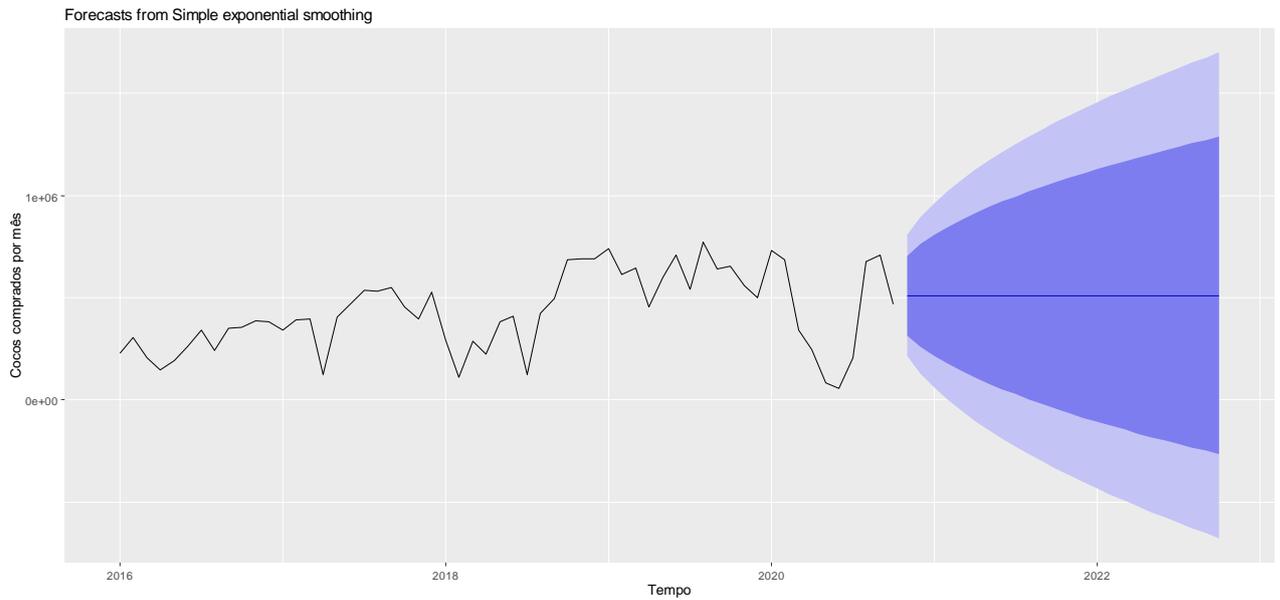
ANEXO C - Modelo de suavização exponencial

Tabela Anexo C – Resultado do método suavização exponencial

Ano	Mês	Previsão	Limite Inf (80%)	Limite Sup (80%)	Limite Inf (90%)	Limite Snf (80%)
2020	Novembro	510903,30	315983,77	705822,80	212799,61	809007,00
	Dezembro	510903,30	260705,19	761101,40	128258,32	893548,30
	Janeiro	510903,30	215599,11	806207,50	59274,52	962532,00
	Fevereiro	510903,30	176523,23	845283,30	-486,89	1022293,50
	Março	510903,30	141558,60	880248,00	-53960,66	1075767,20
	Abril	510903,30	109629,11	912177,50	-102792,61	1124599,20
2021	Maio	510903,30	80059,42	941747,10	-148015,54	1169822,10
	Junho	510903,30	52392,76	969413,80	-190328,05	1212134,60
	Julho	510903,30	26303,07	995503,50	-230228,79	1252035,40
	Agosto	510903,30	1547,97	1020258,60	-268088,45	1289895,00
	Setembro	510903,30	-22058,54	1043865,10	-304191,49	1325998,10
	Outubro	510903,30	-44662,89	1066469,50	-338761,87	1360568,40
	Novembro	510903,30	-66382,82	1088189,40	-371979,63	1393786,20
	Dezembro	510903,30	-87314,67	1109121,20	-403992,12	1425798,70
	Janeiro	510903,30	-107538,46	1129345,00	-434921,74	1456728,30
	Fevereiro	510903,30	-127121,52	1148928,10	-464871,46	1486678,00
	Março	510903,30	-146121,16	1167927,70	-493928,90	1515735,50
	Abril	510903,30	-164586,61	1186393,20	-522169,36	1543975,90
2022	Maio	510903,30	-182560,53	1204367,10	-549658,10	1571464,70
	Junho	510903,30	-200080,21	1221886,80	-576452,14	1598258,70
	Julho	510903,30	-217178,44	1238985,00	-602601,63	1624408,20
	Agosto	510903,30	-233884,25	1255690,80	-628150,96	1649957,50
	Setembro	510903,30	-250223,47	1272030,00	-653139,64	1674946,20
	Outubro	510903,30	-266219,24	1288025,80	-677603,05	1699409,60

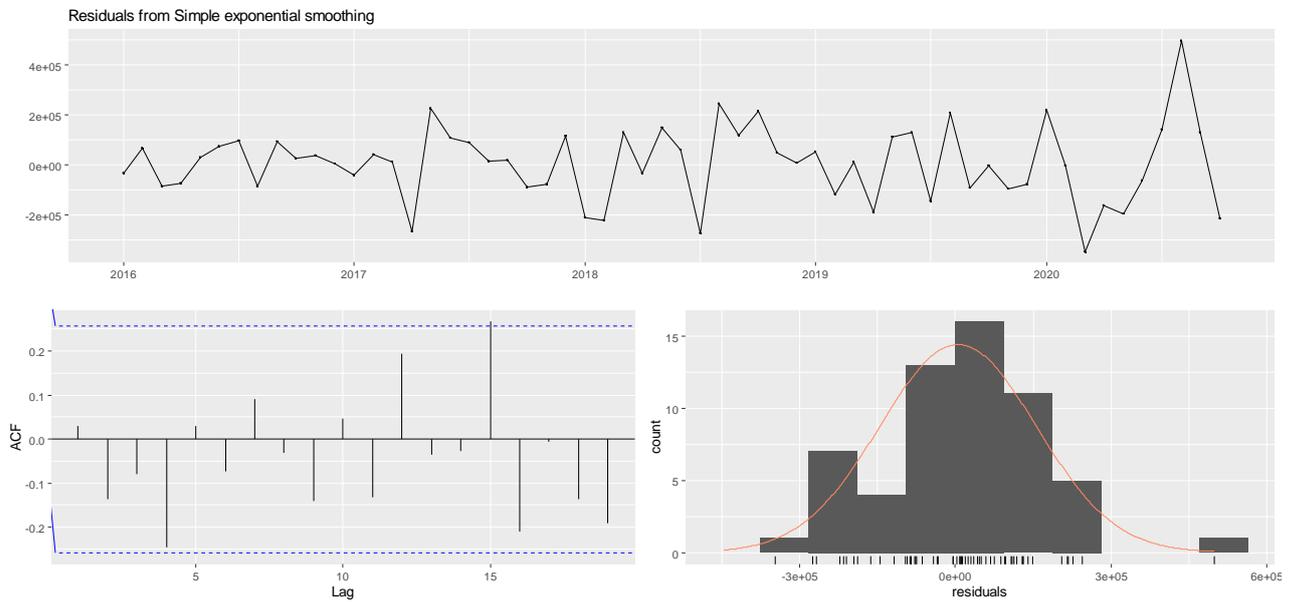
Fonte: Autoria própria (2021)

Figura Anexo C – Representação gráfica do método suavização exponencial



Fonte: Autoria própria (2021)

Figura Anexo C – Pressupostos dos erros do método suavização exponencial



Fonte: Autoria própria (2021)

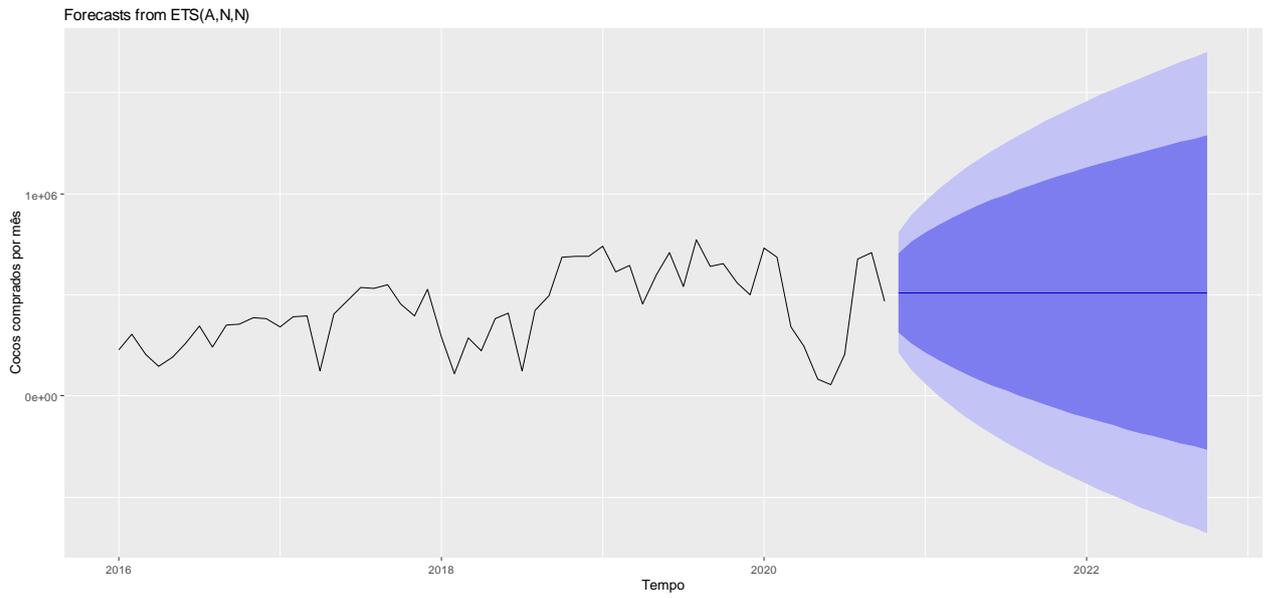
ANEXO D - Modelo de Forecast

Tabela Anexo D – Resultado do método forecast

Ano	Mês	Previsão	Limite Inf (80%)	Limite Sup (80%)	Limite Inf (90%)	Limite Snf (80%)
2020	Novembro	510869,20	315949,67	705788,70	212765,51	808972,90
	Dezembro	510869,20	260646,49	761091,90	128186,59	893551,80
	Janeiro	510869,20	215523,32	806215,00	59176,67	962561,70
	Fevereiro	510869,20	176433,90	845304,50	-605,44	1022343,80
	Março	510869,20	141457,84	880280,50	-54096,71	1075835,10
	Abril	510869,20	109518,32	912220,00	-102944,00	1124682,40
2021	Maio	510869,20	79939,61	941798,80	-148180,73	1169919,10
	Junho	510869,20	52264,69	969473,70	-190505,86	1212244,20
	Julho	510869,20	26167,36	995571,00	-230418,29	1252156,60
	Agosto	510869,20	1405,11	1020333,20	-268288,87	1290027,20
	Setembro	510869,20	-22208,13	1043946,50	-304402,21	1326140,60
	Outubro	510869,20	-44818,86	1066557,20	-338982,34	1360720,70
	Novembro	510869,20	-66544,86	1088283,20	-372209,39	1393947,70
	Dezembro	510869,20	-87482,52	1109220,90	-404230,77	1425969,10
	Janeiro	510869,20	-107711,89	1129450,20	-435168,92	1456907,30
	Fevereiro	510869,20	-127300,32	1149038,70	-465126,85	1486865,20
	Março	510869,20	-146305,15	1168043,50	-494192,22	1515930,60
	Abril	510869,20	-164775,60	1186514,00	-522440,35	1544178,70
2022	Maio	510869,20	-182754,39	1204492,70	-549936,52	1571674,90
	Junho	510869,20	-200278,79	1222017,10	-576737,78	1598476,10
	Julho	510869,20	-217381,61	1239120,00	-602894,29	1624632,60
	Agosto	510869,20	-234091,89	1255830,20	-628450,46	1650188,80
	Setembro	510869,20	-250435,47	1272173,80	-653445,81	1675184,20
	Outubro	510869,20	-266435,49	1288173,90	-677915,73	1699654,10

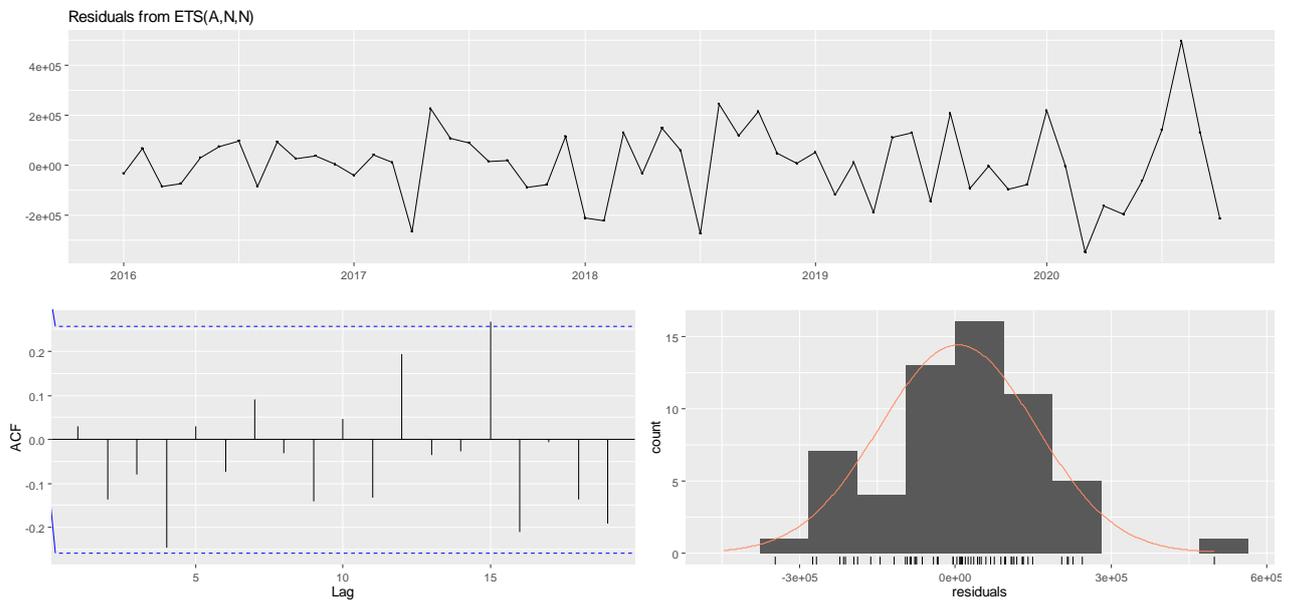
Fonte: Autoria própria (2021)

Figura Anexo D – Representação gráfica do método forecast



Fonte: Autoria própria (2021)

Figura Anexo D – Pressupostos dos erros do método forecast



Fonte: Autoria própria (2021)

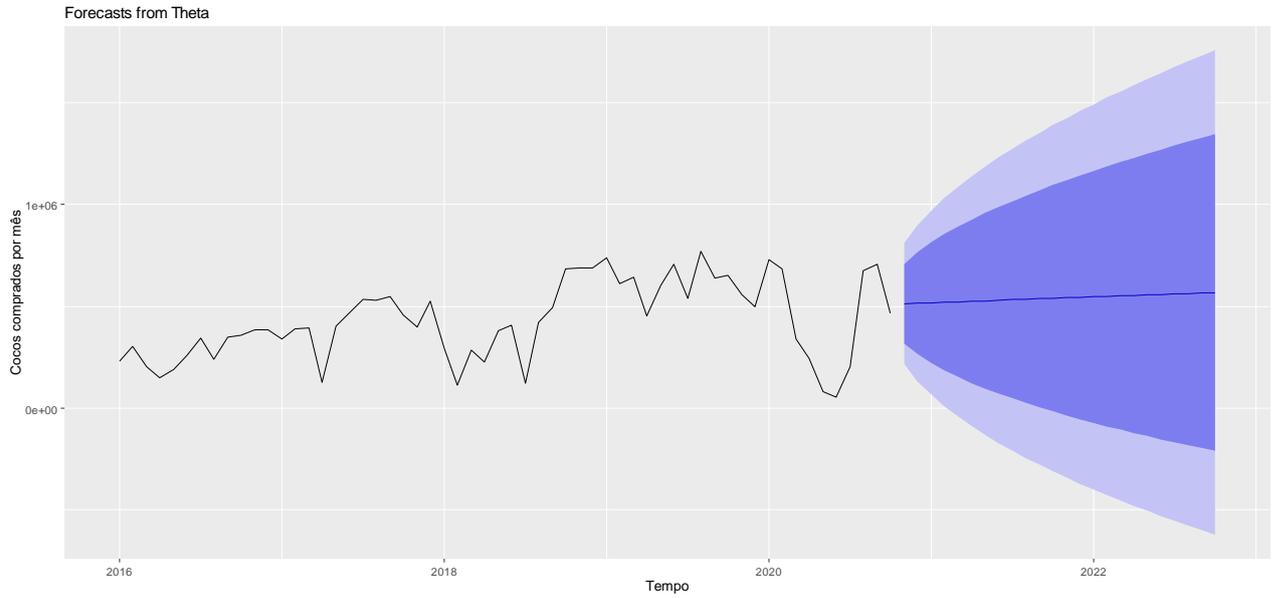
ANEXO E - Modelo de Thetaf

Tabela Anexo E – Resultado do método thetaf

Ano	Mês	Previsão	Limite Inf (80%)	Limite Sup (80%)	Limite Inf (90%)	Limite Snf (80%)
2020	Novembro	513882,60	318963,07	708802,10	215778,91	811986,30
	Dezembro	516280,20	266082,07	766478,30	133635,20	898925,10
	Janeiro	518677,80	223373,58	813981,90	67048,99	970306,50
	Fevereiro	521075,30	186695,27	855455,40	9685,16	1032465,50
	Março	523472,90	154128,24	892817,60	-41391,03	1088336,90
	Abril	525870,50	124596,33	927144,70	-87825,39	1139566,40
2021	Maio	528268,10	97424,23	959112,00	-130650,74	1187186,90
	Junho	530665,70	72155,15	989176,20	-170565,66	1231897,00
	Julho	533063,30	48463,04	1017663,50	-208068,82	1274195,30
	Agosto	535460,80	26105,52	1044816,20	-243530,90	1314452,60
	Setembro	537858,40	4896,60	1070820,30	-277236,35	1352953,20
	Outubro	540256,00	-15310,17	1095822,20	-309409,14	1389921,20
	Novembro	542653,60	-34632,51	1119939,70	-340229,32	1425536,50
	Dezembro	545051,20	-53166,77	1143269,10	-369844,23	1459946,60
	Janeiro	547448,80	-70992,98	1165890,50	-398376,26	1493273,80
	Fevereiro	549846,40	-88178,46	1187871,20	-425928,39	1525621,10
	Março	552243,90	-104780,51	1209268,40	-452588,25	1557076,10
	Abril	554641,50	-120848,37	1230131,40	-478431,12	1587714,20
2022	Maio	557039,10	-136424,71	1250502,90	-503522,28	1617600,50
	Junho	559436,70	-151546,81	1270420,20	-527918,74	1646792,10
	Julho	561834,30	-166247,46	1289916,00	-551670,64	1675339,20
	Agosto	564231,90	-180555,68	1309019,40	-574822,38	1703286,10
	Setembro	566629,40	-194497,32	1327756,20	-597413,48	1730672,40
	Outubro	569027,00	-208095,49	1346149,60	-619479,31	1757533,40

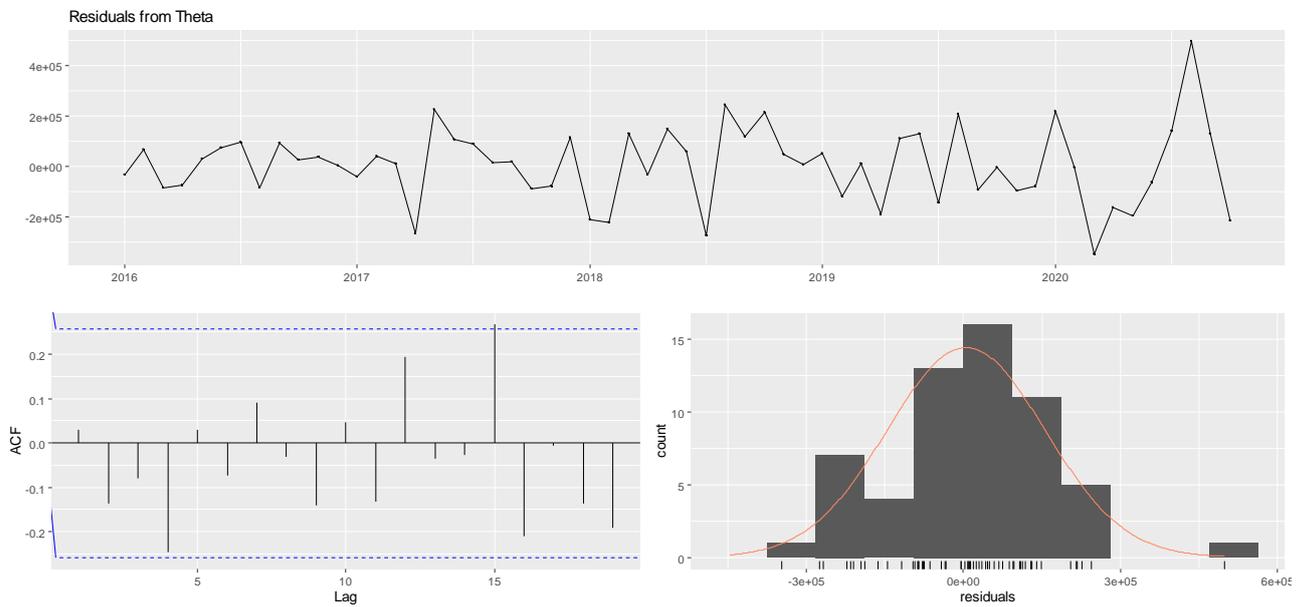
Fonte: Autoria própria (2021)

Figura Anexo E – Representação gráfica do método thetaf



Fonte: Autoria própria (2021)

Figura Anexo E – Pressupostos dos erros do método thetaf



Fonte: Autoria própria (2021)

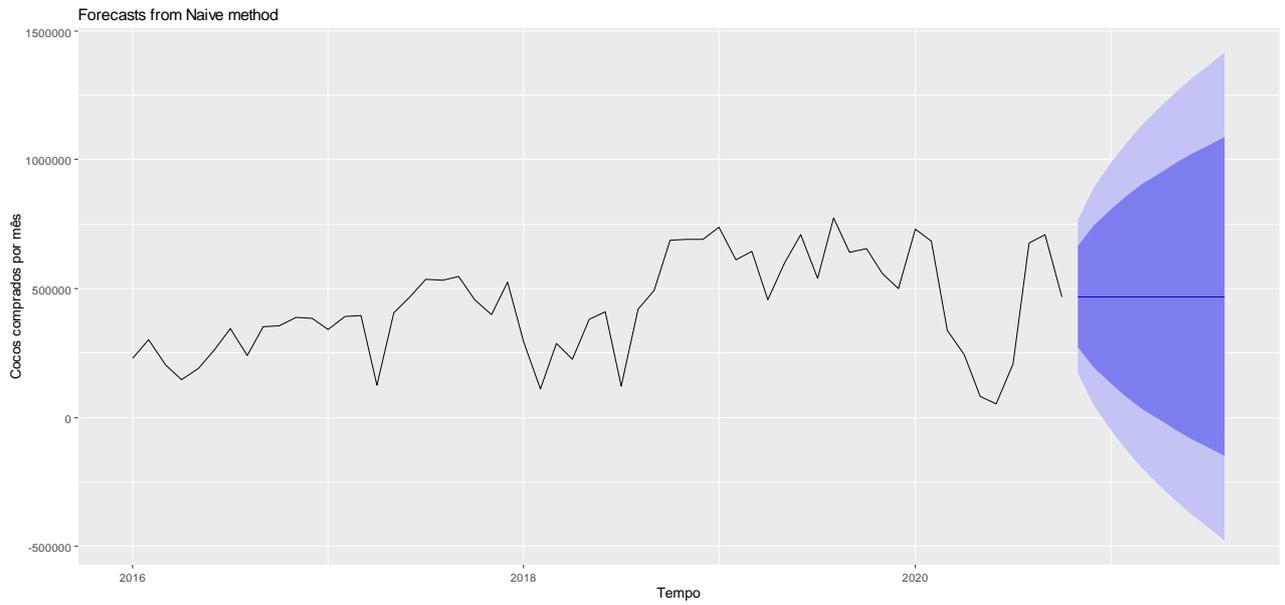
ANEXO F - Modelo de Naive

Tabela Anexo F – Resultado do método naive

Ano	Mês	Previsão	Limite Inf (80%)	Limite Sup (80%)	Limite Inf (90%)	Limite Snf (80%)
2020	Novembro	469049,00	273564,47	664533,50	170081,22	768016,80
	Dezembro	469049,00	192592,13	745505,90	46244,71	891853,30
	Janeiro	469049,00	130459,87	807638,10	-48778,39	986876,40
	Fevereiro	469049,00	78079,95	860018,10	-128886,57	1066984,60
	Março	469049,00	31932,31	906165,70	-199463,29	1137561,30
2021	Abril	469049,00	-9788,34	947886,30	-263269,52	1201367,50
	Mai	469049,00	-48154,44	986252,40	-321945,40	1260043,40
	Junho	469049,00	-83864,74	1021962,70	-376559,59	1314657,60
	Julho	469049,00	-117404,58	1055502,60	-427854,35	1365952,40
	Agosto	469049,00	-149127,35	1087225,30	-476370,14	1414468,10

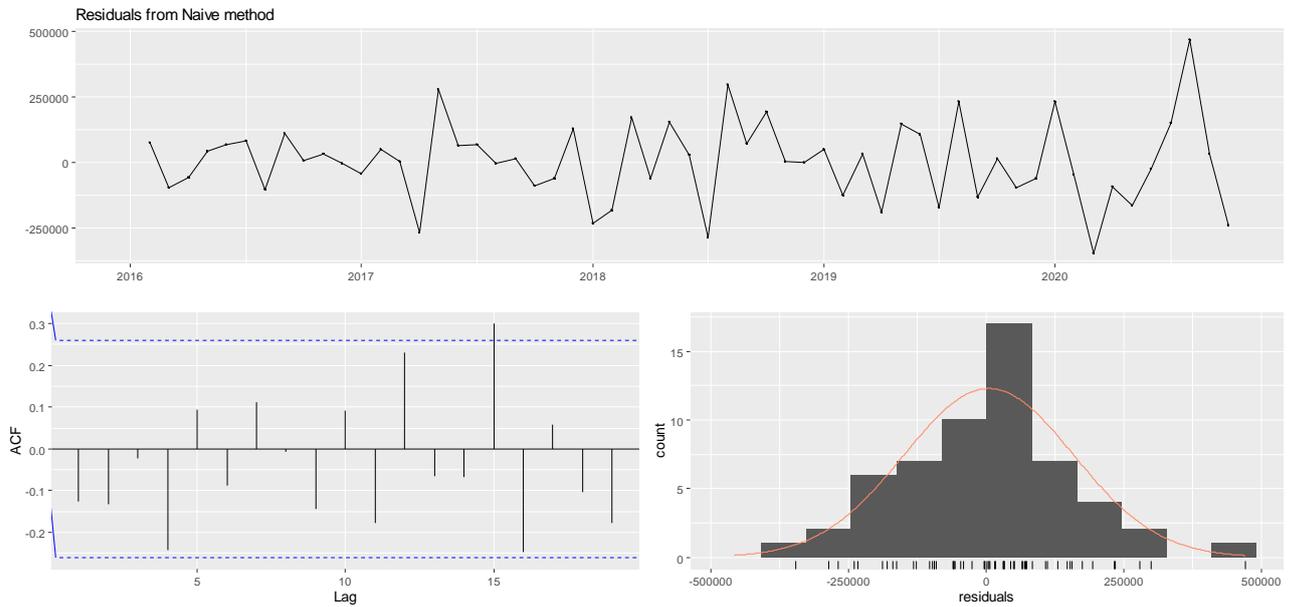
Fonte: Autoria própria (2021)

Figura Anexo F – Representação gráfica do método naive



Fonte: Autoria própria (2021)

Figura Anexo F – Pressupostos dos erros do método naive



Fonte: Autoria própria (2021)