

**UNIVERSIDADE DE ARARAQUARA**  
**MESTRADO PROFISSIONAL EM ENGENHARIA DE PRODUÇÃO**

**Caio Matheus Comar Cambui**

**PREVISÃO DE DEMANDA DE PRODUTOS FARMOQUÍMICOS POR MEIO DE  
SÉRIES TEMPORAIS**

Dissertação apresentada ao Programa de Mestrado Profissional em Engenharia de Produção da Universidade de Araraquara – UNIARA – como parte dos requisitos para obtenção do título de Mestre em Engenharia de Produção, Área de Concentração: Gestão Estratégica e Operacional da Produção.

**Prof. Dra. Bruna Cristine Scarduelli Pacheco**  
Orientadora  
**Prof. Dr. Jorge Alberto Achcar**  
Coorientador

Araraquara, SP – Brasil  
2023

## FICHA CATALOGRÁFICA

C188p Cambui, Caio Matheus Comar

Previsão de demandas de produtos farmoquímicos por meio de séries temporais/Caio Matheus Comar Cambui. – Araraquara: Universidade de Araraquara, 2023.

103f.

Dissertação (Mestrado) - Mestrado Profissional em Engenharia de Produção – Universidade de Araraquara - UNIARA

Orientador: Profa. Dra. Bruna Cristine Scarduelli Pacheco

1. Previsão de demanda. 2. Séries temporais. 3. Indústria farmoquímicas.  
I. Título.

CDU 62-1

## REFERÊNCIA BIBLIOGRÁFICA

CAMBUI, Caio Matheus Comar. **Previsão de Demanda de Produtos Farmoquímicos Por Meio de Series Temporais**. 2023. 103. Dissertação de Mestrado em Engenharia de Produção – Universidade de Araraquara, Araraquara-SP.

## ATESTADO DE AUTORIA E CESSÃO DE DIREITOS

NOME DO AUTOR: Caio Matheus Comar Cambui

TÍTULO DO TRABALHO: Previsão de Demanda De Produtos Farmoquímicos Por Meio de Séries Temporais

TIPO DO TRABALHO/ANO: Dissertação / 2023

Conforme LEI Nº 9.610, DE 19 DE FEVEREIRO DE 1998, o autor declara ser integralmente responsável pelo conteúdo desta dissertação e concede a Universidade de Araraquara permissão para reproduzi-la, bem como emprestá-la ou ainda vender cópias somente para propósitos acadêmicos e científicos. O autor reserva outros direitos de publicação e nenhuma parte desta dissertação pode ser reproduzida sem a sua autorização.



Assinatura Alunô(a)

---

**Caio Matheus Comar Cambui**

Universidade de Araraquara – UNIARA

Rua Carlos Gomes, 1217, Centro. CEP: 14801–340, Araraquara-SP

Email (do autor): [caiocambui@hotmail.com](mailto:caiocambui@hotmail.com)



UNIVERSIDADE DE ARARAQUARA - UNIARA  
MESTRADO PROFISSIONAL EM ENGENHARIA DE PRODUÇÃO

FOLHA DE APROVAÇÃO

Dissertação apresentada ao Programa de Mestrado Profissional em Engenharia de Produção da Universidade de Araraquara – UNIARA – para obtenção do título de Mestre em Engenharia de Produção.

Área de Concentração: Gestão Estratégica e Operacional da Produção.

NOME DO AUTOR: CAIO MATHEUS COMAR CAMBUÍ

TÍTULO DO TRABALHO:

DISSERTAÇÃO INTITULADA "PREVISÃO DE DEMANDA DE PRODUTOS FARMOQUIMICOS POR MEIO DE SERIES TEMPORAIS"

Assinatura do(a) Examinador(a)	Conceito
 Prof(a). Dr(a). Jorge Alberto Achcar (coorientador(a)) Universidade de Araraquara - UNIARA	(X)Aprovado ( ) Reprovado
 Prof(a). Dr(a). José Luis Garcia Hermosilla Universidade de Araraquara - UNIARA	(X)Aprovado ( ) Reprovado
 Documento assinado digitalmente PEDRO CARLOS OPRIME Data: 04/08/2023 10:18:14 -0300 Verifique em <a href="https://validar.jf.gov.br">https://validar.jf.gov.br</a>	(X)Aprovado ( ) Reprovado
Prof(a). Dr(a). Pedro Carlos Oprime Universidade Federal de São Carlos - UFSCAR	

Versão definitiva revisada pelo(a) orientador(a) em: 02/10/23



Prof(a). Dr(a). Jorge Alberto Achcar (coorientador(a))

Dedico esse trabalho a minha mãe Alexandra, a minha noiva Angélica e a minha avó Maria Regina, pois sem essas três mulheres eu não estaria onde estou e esse trabalho jamais seria realizado.

No momento que mais precisei elas estiveram lá.

## AGRADECIMENTOS

Para realização desse trabalho muitas pessoas me ajudaram e sem as quais eu não teria conseguido.

Primeiramente queria agradecer a Deus, pois sem ele nada seria possível.

Aos Meus pais Carlos Alberto Cambui e Alexandra Benedetti Comar Cambui, que me trouxeram ao mundo e sempre estiveram comigo me apoiando, sendo minha base em todos os momentos da minha vida.

A minha noiva Angélica Correia dos Santos, por todo amor, carinho e incentivo.

A minha avó Maria Regina Comar, por tudo o que faz por mim e pelo amor.

Ao Prof. Dr. Cláudio Luis Piratelli, por ter aceitado me orientar e me orientado durante o início do mestrado.

A Prof. Dra. Bruna Cristine Scarduelli Pacheco, por ter aceitado me orientar, no meio do processo substituir o Prof. Dr. Cláudio devido a problemas de saúde, por todo suporte e orientações incríveis.

Ao Prof. Dr. Jorge Alberto Achcar por ter sido meu coorientador e auxiliado no desenvolvimento da dissertação.

A toda a empresa que me acolheu e cedeu os dados para que eu pudesse realizar esse estudo.

Aos Professores do Programa de Mestrado em Engenharia de Produção e aos meus colegas pelas orientações e conversas em prol do desenvolvimento da pesquisa e do crescimento acadêmico da instituição.

E a todos que direta ou indiretamente fizeram parte dessa caminhada.

Deixo aqui os meus mais sinceros agradecimentos.

“O caminho é o que importa, não o seu fim. Se viajar depressa demais, vai perder aquilo que o fez viajar.” Louis L'Amour

## RESUMO

A ausência de um planejamento para previsão de demanda pode levar a dificuldades com alto estoque de produtos, perda de oportunidades e não cumprimento dos prazos. Para prever demanda existem diversos métodos, dentre eles o de series temporais que por meio de modelos matemáticos realizam previsões utilizando dados históricos, com a premissa de que o futuro é a continuação do passado. O objetivo deste estudo é apresentar o modelo de series temporais mais adequado para prever demanda de quatro produtos que fazem parte do portfólio da empresa farmoquímica objeto deste estudo, por meio da comparação com os resultados reais. A natureza dessa pesquisa é aplicada, e os procedimentos são pesquisa bibliográfica e modelagem matemática. A revisão bibliográfica realizada na base Scopus foi conduzida para analisar a utilização de previsão de demanda por meio series temporais e verificou-se a disseminação do assunto havendo destaque para os anos de 2019 e 2020. Nesta pesquisa foram selecionados quatro produtos principais da empresa farmoquímica estudada, em função de participação no faturamento e produção, para realização das previsões. Após a seleção dos produtos, foi comparada a previsão com os resultados reais obtidos, selecionando o método ARIMA como mais adequado a ser utilizado. O estudo também contribui com a criação de um passo a passo a ser utilizado pela própria empresa com outros produtos comercializados, e/ou outros pesquisadores para aplicação do método de previsão por meio de series temporais.

**Palavras-chave:** Previsão de Demanda. Series Temporais. Indústria Farmoquímica.

## ABSTRACT

*The absence of planning to forecast demand can lead to difficulties with high inventory of products, missed opportunities and non-compliance with deadlines. To forecast demand, there are several methods, among them the time series that, through mathematical models, provide forecast using historical data, with the premise that the future is the continuation of the past. The objective of this study is to present the most appropriate time series model to predict the demand for four products that are part of the portfolio of the pharminochemical company that is the object of this study, through comparison with actual results. The nature of this research is applied, and the procedures are literature search and mathematical modeling. The bibliographic review conducted in the Scopus database was conducted to analyze the use of demand forecasting through time series and the dissemination of the subject was defended, with emphasis on the years 2019 and 2020. In this research, four main products of the pharminochemical company were selected, due to participation in billing and production, for making provisions. After selecting the products, the prediction was verified with the actual results obtained, selecting ARIMA as the most appropriate method to be used. The study also contributes to the creation of a step-by-step guide to be used by the company itself with other marketed products, and/or other researchers for applying the forecasting method through time series.*

**Keywords:** *Demand Forecasting. Time Series. Pharmacochemical Industry.*



## Lista de figuras

Figura 1 – Tipos de Métodos Quantitativos. ....	22
Figura 2 – Fluxo de aplicação do Modelo Holt. ....	25
Figura 3 – Fluxo de aplicação do Modelo ARIMA. ....	27
Figura 4 – Fluxo de análise dos artigos. ....	35
Figura 5 – Distribuição dos trabalhos por Origem. ....	36
Figura 6 – Distribuição dos trabalhos por Ano. ....	36
Figura 7 – Distribuição dos trabalhos por áreas do conhecimento. ....	37
Figura 8 – Distribuição dos trabalhos por Tipo. ....	37
Figura 9 – Distribuição dos trabalhos por Idioma. ....	38
Figura 10 – Pareto das palavras chaves encontradas. ....	38
Figura 11 – Passo a Passo para Desenvolvimento do Estudo. ....	43
Figura 12 – Matriz faturamento x produção para escolha dos produtos.. ....	45
Figura 13 – Series temporais dos Produtos... ....	48
Figura 14 – Análise da dispersão e valores dos conjuntos de dados (Boxplot Produto 6).....	50
Figura 15 – Análise da dispersão e valores dos conjuntos de dados (Boxplot Produto 9).....	52
Figura 16 – Análise da dispersão e valores dos conjuntos de dados (Boxplot Produto 10).....	54
Figura 17 – Análise da dispersão e valores dos conjuntos de dados (Boxplot Produto 3 (20L)).. .....	58
Figura 18 – Análise da dispersão e valores dos conjuntos de dados (Boxplot Produto 3 (5L)). .....	59
Figura 19 – Análise da dispersão e valores dos conjuntos de dados (Boxplot Produto 3 (1L)).. .....	60
Figura 20 – Modelo de médias móveis ajustado (produto 6). ....	63
Figura 21 – Gráficos de resíduos do modelo de médias móveis ajustado (produto 6).....	64
Figura 22 – Gráficos de resíduos do modelo ARIMA(2,1,3) (produto 6). ....	65
Figura 23 – Gráfico dos valores preditos (FITS) do modelo ARIMA(2,1,3) ajustado.. ....	67
Figura 24 – Gráfico das autocorrelações parciais do modelo ARIMA (2,1,3) (produto 6). ....	67
Figura 25 – Modelo de médias móveis ajustado (produto 9).. ....	68
Figura 26 – Gráficos de resíduos do modelo de médias móveis ajustado (produto 9). ....	69
Figura 27 – Gráficos de resíduos do modelo ARIMA(2,1,3) (produto 9).....	70
Figura 28 – Gráfico dos valores preditos (FITS) do modelo ARIMA(2,1,3) ajustado. ....	72
Figura 29 – Gráfico das autocorrelações parciais do modelo ARIMA (2,1,3) (produto 9).....	72
Figura 30 – Modelo de médias móveis ajustado (produto 10). ....	73
Figura 31 – Gráficos de resíduos do modelo de médias móveis ajustado (produto 10).....	74

Figura 32 – Gráficos de resíduos do modelo ARIMA(2,1,3) (produto 10). .....	75
Figura 33 – Gráfico dos valores preditos (FITS) do modelo ARIMA(2,1,3) ajustado. ....	76
Figura 34 – Gráfico das autocorrelações parciais do modelo ARIMA (2,1,3) (produto 10). ..	76
Figura 35 – Modelo de médias móveis ajustado (log(PTM 20 L)).. .....	78
Figura 36 – Gráficos de resíduos do modelo de médias móveis ajustado (log(PTM 20 L)). ..	79
Figura 37 – Gráficos de resíduos do modelo ARIMA(2,1,3) (log(PTM 20 L) .....	80
Figura 38 – Gráfico dos valores preditos (FITS) do modelo ARIMA(2,1,3) ajustado. ....	82
Figura 39 – Gráfico das autocorrelações parciais do modelo ARIMA (2,1,3) (log(PTM 20 L))..	82
Figura 40 – Modelo de médias móveis ajustado (log(PTM 5L)). .....	83
Figura 41 – Gráficos de resíduos do modelo de médias móveis ajustado (log(PTM 5 L)).....	84
Figura 42 – Gráficos de resíduos do modelo ARIMA(2,1,3) (log(PTM 5 L)). .....	85
Figura 43 – Gráfico dos valores preditos (FITS) do modelo ARIMA(2,1,3) ajustado... ..	87
Figura 44 – Gráfico das autocorrelações parciais do modelo ARIMA (2,1,3) (log(PTM 5 L)).	87
Figura 45 – Modelo de médias móveis ajustado (log(PTM 1L)).. .....	88
Figura 46 – Gráficos de resíduos do modelo de médias móveis ajustado (log(PTM 1 L)). ....	89
Figura 47 – Gráficos de resíduos do modelo ARIMA(2,1,3) (log(PTM 1 L)).....	90
Figura 48 – Gráfico dos valores preditos (FITS) do modelo ARIMA(2,1,3) ajustado. ....	92
Figura 49 – Gráfico das autocorrelações parciais do modelo ARIMA (2,1,3) (log(PTM 1 L))..	92

## **Lista de Quadros**

Quadro 1 – Métodos Qualitativos de previsão. ....	21
Quadro 2 – Estudos Correlatos. ....	32
Quadro 3 – Matriz faturamento x produção para escolha dos produtos. ....	45

## Lista de Tabelas

Tabela 1 – Demanda produtos 3, 6, 9 e 10. ....	46
Tabela 2 – Estatísticas dos Dados.....	48
Tabela 3 – Estatística descritivas do Produto 6 (média e desvio-padrão para cada ano e cada mês)... ..	51
Tabela 4 – Estatística descritivas do Produto 9 (média e desvio-padrão para cada ano e cada mês). ....	53
Tabela 5 – Estatística descritivas do Produto 10 (média e desvio-padrão para cada ano e cada mês). ....	55
Tabela 6 – Transformação dos dados em logaritmo.....	55
Tabela 7 – Estatística descritivas do Produto 3 para todas as apresentações (média e desvio-padrão para cada ano e cada mês). ....	61
Tabela 8 – Estimativas dos parâmetros do modelo ARIMA (2,1,3) ajustado (produto 6).....	64
Tabela 9 – Resultados de previsão (FITS) obtidos pelo modelo ARIMA (2,1,3) ajustado. ...	65
Tabela 10 – Estimativas dos parâmetros do modelo ARIMA (2,1,3) ajustado (produto 9)....	69
Tabela 11 – Resultados de previsão (FITS) obtidos pelo modelo ARIMA (2,1,3) ajustado. .	70
Tabela 12 – Estimativas dos parâmetros do modelo ARIMA (2,1,3) ajustado (produto 10)...	74
Tabela 13 – Resultados de previsão (FITS) obtidos pelo modelo ARIMA (2,1,3) ajustado..	75
Tabela 14 – - Estimativas dos parâmetros do modelo ARIMA (2,1,3) ajustado (log(PTM 20 L)). .....	79
Tabela 15 – Resultados de previsão (FITS) obtidos pelo modelo ARIMA (2,1,3) ajustado..	80
Tabela 16 – Estimativas dos parâmetros do modelo ARIMA (2,1,3) ajustado (log(PTM 5 L)). .....	84
Tabela 17 – Resultados de previsão (FITS) obtidos pelo modelo ARIMA (2,1,3) ajustado. .	85
Tabela 18 – Estimativas dos parâmetros do modelo ARIMA (2,1,3) ajustado (log(PTM 1 L)). .....	89
Tabela 19 – Resultados de previsão (FITS) obtidos pelo modelo ARIMA (2,1,3) ajustado..	90

## **Lista de Abreviaturas e Siglas**

ANOVA – Análise de Variância.

ARIMA – Autoregressive Integrated Moving Average.

COVID-19 – Corona Virus Disease 19.

ERP – Enterprise Resource Planning.

RNA – Rede Neural Artificial.

## SUMÁRIO

<b>1 INTRODUÇÃO</b> .....	15
1.1 Contextualização e problemática.....	15
1.2 Objetivos.....	17
1.2.1 Objetivo geral .....	17
1.2.2 Objetivos específicos.....	17
1.3 Justificativa.....	17
1.4 Metodologia da Pesquisa e estrutura do trabalho .....	18
<b>2 MEDIDAS DE DESEMPENHO E ERROS DE PREVISÃO</b> .....	19
2.1 Técnicas para previsão de demanda .....	20
2.1.1 Séries Temporais .....	22
2.1.1.1 Método Baseado em Médias Móveis Simples.....	23
2.1.1.2 Método Baseado em Médias Móveis Ponderada.....	24
2.1.1.3 Método de Suavização Exponencial Simples.....	24
2.1.1.4 Método de Suavização com Tendência (Modelo Holt).....	25
2.1.1.5 Método de Suavização Exponencial com Variação de Tendência (Modelo Holt-Winters) .....	26
2.1.1.6 Método Box-Jenkins (ARIMA).....	27
2.1.2 Erros de Previsão .....	30
2.1.3 Estudos correlatos sobre previsão de demanda utilizando series temporais .....	31
<b>3. METODOLOGIA</b> .....	36
3.1 Características da pesquisa .....	36
3.2 Procedimentos operacionais .....	41
<b>4. APLICAÇÃO DO MÉTODOS DE SÉRIES TEMPORAIS EM UMA EMPRESA DO SETOR FARMOQUÍMICO</b> .....	44
4.1 Mapeamento do Estado Atual.....	44
4.2 Definição dos produtos a serem estudados.....	44
4.3 Levantamento dos Dados.....	46
4.4 Análise descritiva dos dados.....	48
4.4.1 Análise descritiva do Produto 6.....	49
4.4.2 Análise descritiva do Produto 9.....	51
4.4.3 Análise descritiva do Produto 10.....	53
4.4.4 Análise descritiva do Produto 3.....	55
4.5 Análise estatística dos dados .....	63
4.5.1 Produto 6 .....	63
4.5.2 Produto 9 .....	68

4.5.3 Produto 10 .....	73
4.5.4 Produto 3 (20L) na escala logarítmica.....	78
4.5.5 Produto 3 (5L) na escala logarítmica.....	83
4.5.6 Produto 3 (1L) na escala logarítmica.....	88
4.6 Discussão dos resultados obtidos .....	93
4.7 Validação dos Resultados .....	94
<b>5. CONCLUSÃO .....</b>	<b>95</b>
<b>REFERÊNCIAS .....</b>	<b>97</b>

# 1 INTRODUÇÃO

Esta seção tem como objetivo contextualizar o tema de previsão de demanda, apresentar o problema de pesquisa identificado, objetivos, justificativa, além das características da pesquisa e estrutura do trabalho.

## 1.1 Contextualização e problemática

Segundo o grupo IQVIA 2020, o Brasil é o principal mercado farmacêutico da América Latina e responde por cerca de 2% da economia mundial, sendo que o aumento das vendas foi de 13,6% maior no primeiro semestre de 2020. De acordo com o *Institute for Healthcare Informatics* (IMS) o Brasil subiu para 5º colocado no *ranking* global de consumo de medicamentos e permanece nessa posição até 2022. Para que venda de produtos farmacêuticos ocorra é necessária a produção de intermediários químicos (indústria química), em seguida a produção de fármacos (indústria farmoquímica) para então poder produzir os medicamentos farmacêuticos (COSTA et al., 2014).

A pandemia de COVID-19, que se iniciou em 2020, mostrou a grande dificuldade na logística e produção causando incerteza, aumento de custo, indisponibilidade, instabilidade e desabastecimento em diversos setores (JUNQUEIRA, 2020). As empresas farmoquímicas não estiveram fora deste cenário e, portanto, sendo questionadas sobre a capacidade de manter a produção destes produtos (PARANHOS et al., 2021). Diante deste contexto, uma das ferramentas para que as empresas possam se tornar cada vez mais competitivas, além de poderem se preparar melhor e equilibrar seus processos é a previsão de demanda.

Tanizaki et al. (2020) destacam que para uma melhor produção, é preciso mudar de um método baseado em experiência e intuição para um método mais analítico e preciso, e com isso a previsão de demanda auxilia a ter um direcionamento das decisões, pois apresenta dados capazes de auxiliar o processo de gestão. A importância da previsão de demanda nas empresas se dá devido à necessidade de planejamento e operações serem mais eficazes, já que é a entrada para o sistema de controle de estoque (WANG; PETROPOULOS, 2016).

Já Lee (2001), afirma que a demanda por um produto ou serviço é vista como um ponto de entrada chave na cadeia de suprimentos, sendo também um ponto de previsão ou, mais complexamente, uma previsão com significância e variabilidade baseada em métodos estatísticos ou outros métodos científicos, se utilizando de muitas soluções técnicas para melhorar a precisão dessas previsões e utilizar as características da demanda para organizar o estoque, o reabastecimento, a produção e o planejamento da capacidade empresarial.



A previsão de demanda é um dos pilares de qualquer estudo para melhoria do processo produtivo, pois por meio dela pode-se ter a visão das receitas e os requisitos de infraestrutura, o que auxilia na tomada de decisão (MARTINS; STRAMBI, 2021).

De acordo com Fattah et al. (2018) o mercado evolui e os clientes estão mais rigorosos no que se refere ao atendimento e cumprimento dos prazos. A ausência de uma previsão de demanda adequada pode gerar custos elevados, já que leva as empresas a investirem em altos estoques para evitar a falta de matéria prima e muitas vezes pela demanda ser intermitente acabam com os produtos ou matérias primas paradas no estoque.

Segundo Zhu et al. (2021) ter uma previsão de demanda é de suma importância para processo produtivo de uma farmacêutica, pois o atendimento do pedido pode mudar e isso acarreta perdas de vendas e faturamento, devido aos clientes necessitarem dos produtos não podendo arcar com incertezas ou atrasos, com isso é necessário estar preparado para produzir e entregar o produto a todo momento.

Esse estudo visa estudar modelos de previsão de demanda por series temporais de produtos em uma indústria farmoquímica de médio porte no interior de São Paulo. Por não existir um método de previsão de demanda no sistema produtivo, ocorrem problemas como a falta de matéria prima, e com a chegada e pedidos faz-se necessária a compra emergencial, o que gera atraso no processo produtivo, e conseqüentemente na entrega ao cliente. O inverso também ocorre quando se tem matéria prima em abundância e não se tem pedidos para utilizar.

Outro aspecto do problema é a alta mudança na programação de produção, pois como ela é utilizada também para o planejamento de compras, causa a perda de oportunidades de produção, gastos desnecessários com compras de matéria prima e grandes estoques de produtos acabados que acabam parados na prateleira. Similarmente existe o problema de se reembalar o produto, porque ele é embalado inicialmente em uma devida embalagem e por necessidade de demanda precisa-se mudar a apresentação, então se detém em retrabalho trocando a embalagem inicial para outra embalagem, causando uma perda de tempo produtivo e divergências nos estoques.

Este estudo pretende responder a seguinte questão: Qual o modelo de séries temporais que melhor se adequa para previsão de demanda em uma indústria farmoquímica sediada no interior de São Paulo?

## **1.2 Objetivos**

### **1.2.1 Objetivo geral**

O objetivo do estudo é apresentar o modelo de séries temporais que tenha o menor erro e apresente pouca disparidade quando comparado ao real obtido em uma indústria farmoquímica.

### **1.2.2 Objetivos específicos**

Os objetivos específicos são:

- Projetar, por meio de series temporais, a demanda para os três meses seguintes;
- Determinar qual o resultado das previsões e seus respectivos erros;
- Construir um passo a passo para aplicação do modelo de previsão para que a empresa possa fazer uso e/ou outros pesquisadores.

## **1.3 Justificativa**

O presente estudo se justifica pelo necessidade de um modelo de previsão de demanda, pois a previsão de demanda é a base para a eficiência da cadeia de suprimentos, porque por meio dela se faz todo o gerenciamento operacional auxiliando na tomada de decisão para o fornecimento de matéria prima, planejamento de produção, gerenciamento de estoque, até definição de metas financeiras, sendo também muito importante, pois incompatibilidade com a demanda e oferta pode ocasionar o não atendimento de uma demanda podendo levar a perda de vendas e até de clientes (ZHU et al., 2021).

Segundo Rodriguez e Corrêa (2017) a previsão de demanda auxilia na resolução de problemas como “superprodução”, que gera também um aumento dos custos e de menor produção, que ocasiona não arcar com os compromissos de vendas e perda de oportunidade de negócios. Já de acordo com Melo e Alcântara (2012) a previsão de demanda equaciona corretamente a demanda e oferta ocasionando que a competitividade da empresa aumente, também podendo auxiliar a determinar um fluxo produtivo para que meses de menor expressão tenham produtividade e meses de maior expressão não ocasionem problemas.

De acordo com Silva (2019) a previsão de demanda é base de toda a decisão estratégica de uma empresa. Sendo assim a previsão de demanda traz melhorias significativas para as empresas com uma economia solida e prospera, alto retorno monetário, maior competitividade,

melhor relacionamento com clientes e aumento de sua satisfação (MOON; MENTZER; SMITH, 2003).

De acordo com Kotler (1991) e Kahn (2002) para que uma organização tenha uma operação eficiente de produção e serviços, é imprescindível a utilização de previsão de demanda, pois só assim ela pode se comprometer com altos níveis de serviço junto ao cliente, disponibilizar informações de demanda mais aderente a realidade aos fornecedores, evitar perdas de vendas, perdas de estoque e planejar expansões de capacidade de forma antecipada.

Jain e Malehorn (2006) apresenta que não existe um modelo padrão de previsão que sirva para qualquer caso, a partir dessa premissa realizaram um estudo com indústrias americanas de diversos setores, para verificar qual era o método de previsão de demanda mais utilizado, dentre eles o que mais se destacou foi o método de series temporais, devido sua alta precisão, facilidade na utilização, alta performance, horizonte de previsão podendo ser longo ou curto, custo baixo, tempo despendido para realização do método e não ser necessário a utilização de ferramentas tecnológicas, como *softwares*, para realização.

A utilização de series temporais para o desenvolvimento desse estudo foi de maneira intencional.

#### **1.4 Metodologia da Pesquisa e estrutura do trabalho**

Esta pesquisa é de natureza aplicada, concebida em função de um problema com relação a previsão de demanda em uma indústria farmoquímica do interior do estado de São Paulo. Os objetivos são exploratórios e descritivos, pois visa tornar o problema explícito, descrevendo os resultados encontrados, e fazendo uso de uma revisão da literatura pesquisar como situações semelhantes foram abordadas. A abordagem é quantitativa, fazendo uso de dados estatisticamente tratados para análise da demanda, por meio de modelagem para identificar o modelo de séries temporais mais adequado (TURRIONI; MELLO, 2012). O enquadramento metodológico da pesquisa e procedimentos operacionais desta, seguem detalhados na seção três deste estudo.

Além da introdução a dissertação está estruturada em outras quatro seções: a seção dois traz um breve referencial teórico e uma revisão da literatura sobre os métodos de previsão da demanda e estudos correlatos a este; a seção três aborda a metodologia da pesquisa com suas características e procedimentos operacionais; a seção quatro traz a aplicação prática do estudo com a análise de dados e resultados; finalmente na seção cinco apresentam-se as conclusões, limitações da pesquisa e sugestões para futuros estudos.

## 2 MEDIDAS DE DESEMPENHO E ERROS DE PREVISÃO

Nesta seção apresenta-se uma conceituação sobre os métodos de previsão de demanda e estudos correlatos sobre previsão de demanda utilizando series temporais.

O PCP participa do planejamento de toda empresa seja ele de curto, médio e longo prazo, se caracterizando pela sua complexidade no processo de decisões, relacionando-se com as funções vitais da empresa e operando com os recursos de informações, para transformá-los em uma sequência de operações do processo produtivo, desse modo o PCP está altamente ligado a tomada de decisão, seja ela de nível estratégico, tático ou operacional (SOUZA et al.; 2011).

A previsão de demanda é de suma importância para gestão estratégica e operacional nas empresas, permitindo a visão futura influenciando assim no ganho de competitividade. Baseia-se na determinação de dados futuros baseado em modelos estatísticos, matemáticos ou econométricos ou modelos subjetivos apoiados em metodologia de trabalho clara e previamente definidas (MARTINS; LAUGENI; 2015).

Portanto de acordo com Souza et al. (2011) a partir das informações obtidas das previsões de demanda o PCP irá elaborar toda o planejamento e controle de suprimentos emitindo as ordens para que seja realizada a produção e compra dos materiais.

Existem duas formas de abordagem para os problemas de previsão de demanda a quantitativa e a qualitativa. A quantitativa é conhecida pelos métodos de *forecasting*, ao partir do levantamento de dados históricos para descrever a variação da demanda. As qualitativas são baseadas em opiniões de especialistas e são suscetíveis a tendência, o que não garante a confiabilidade dos dados (PELLEGRINI; FOGLIATTO, 2001). Há também a abordagem combinada qualitativa e quantitativa que utiliza das vantagens de cada método, pois junta a objetividade do método quantitativo e a subjetividade do método qualitativo se tornando um modelo de previsão ideal (CALISING, 2015).

Oliveira, Dourados e Mello (2017) apresenta que os métodos de previsão de demanda que são divididos em dois, os métodos qualitativos que consistem em técnicas de previsão subjetivas, dentre elas como exemplo os métodos de Predição, Opinião de executivos e Método de Delphi e os métodos quantitativos que consistem em técnicas mais objetivas utilizando modelos matemáticos entre elas têm-se a Técnica de Correlação e Series Temporais.

De acordo com Tubino (2017) um modelo de previsão de demanda é dividido em cinco etapas:

1. **Objetivo do Modelo:** identifica o porquê se fazer previsão, qual resultado se quer obter, quais recursos disponíveis e o produto/família que se trabalhará.
2. **Coleta e Análise de Dados:** consiste em analisar e coletar dados, para identificar e desenvolver qual será o método utilizado.
3. **Seleção da Técnica de Previsão:** qual técnica ira se utilizar para gerar as previsões.
4. **Obtenção das previsões:** resultado das três etapas anteriores, trazendo as projeções futuras de acordo com o horizonte determinado.
5. **Monitoramento do Modelo:** monitorar o real com o previsto de acordo com o tempo, para identificar se o modelo ainda atende as necessidades.

### 2.1 Métodos para previsão de demanda

Os métodos existentes de previsão de demanda são subdivididos em métodos quantitativos ou qualitativos (OLIVEIRA; DOURADOS; MELLO, 2017).

Devido aos julgamentos e avaliações dos especialistas baseados em sua experiência no mercado, trazendo assim confiabilidade para as previsões, os modelos qualitativos também são chamados de subjetivos, sendo os principais apresentados no quadro 1 (SILVA, 2019).

Quadro 1. Métodos Qualitativos de previsão

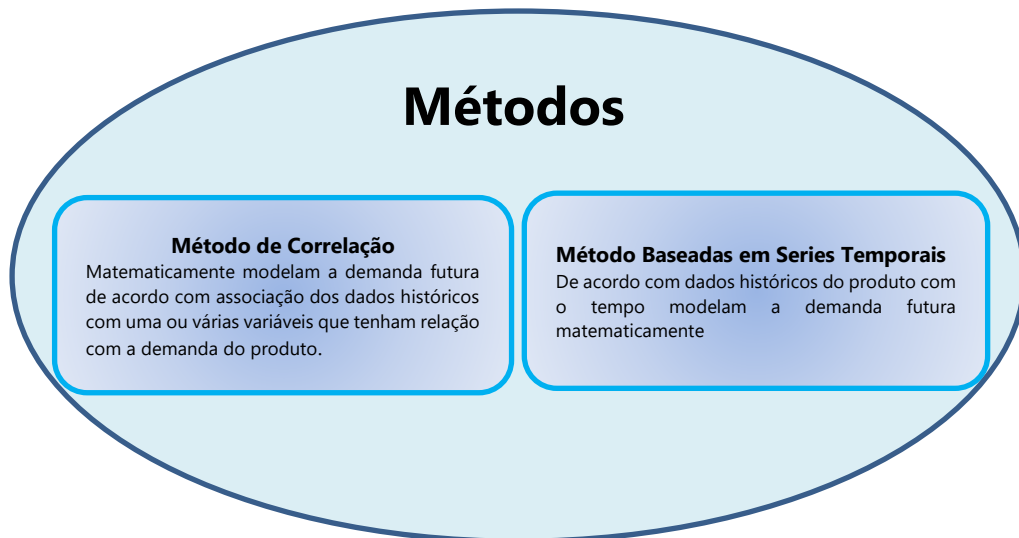
Método	Características
<b>Predição</b>	Apresenta um grande risco de erro, pois elabora as previsões por meio do " <i>feeling</i> " do gestor.
<b>Opinião de Executivos</b>	São previsão realizadas por meio da opinião/julgamentos dos executivos de diversas áreas da empresa, muitas vezes prevalecendo a opinião do mais experiente, com mais poder hierárquico ou com maior poder de convencimento.

<b>Método de Delphi</b>	Em busca de minimizar a influência ou pressão sobre os participantes esse método é dividido em 4 etapas: 1° debate sobre quem serão os participantes, 2° por meio de questionários, coletar anonimamente, a opinião dos participantes, 3° entregar ao responsável os resultados para que se faça um tratamento estatístico e 4° apresentação dos resultados para os participantes para que se valide e adeque aos objetivos.
<b>Opinião da Equipe de vendas</b>	Realiza as previsões por meio de informações do grupo de vendas, seja por produto, serviço, região ou setor para se gere uma visão global da demanda
<b>Pesquisa de Mercado</b>	É um estudo feito partir a opinião dos clientes sendo levado em consideração sua intenção de compra, percepções e desejos
<b>Analogia com Produtos Similares</b>	É um estudo partir de produtos similares ou substituídos.

Fonte: Elaborado pelo próprio autor com base em Silva (2019)

De acordo com Veiga, Veiga e Tortato (2016) as previsões quantitativas partem do conceito básico que o comportamento de vendas do passado continuará no futuro. Analisando dados do passado de maneira objetiva e por meio de modelos matemáticos para projetar demanda futura, as previsões quantitativas se dividem em duas técnicas conforme figura 1 (TUBINO, 2017).

Figura 1. Tipos de Métodos quantitativos



Fonte: Elaborado pelo próprio autor com base em Tubino (2017)

Segundo Lage Junior (2019) sobre as técnicas de correlação tem-se os seguintes métodos:

1. Regressão Linear, mostra por meio de uma equação matemática a influência de uma variável independente em uma variável dependente.
2. Regressão Curvilínea, basicamente é a mesma da linear porém na equação a variável independente é de característica não linear.
3. Regressão Múltipla, similar as outras duas anteriores, porém o que diferencia é que agora são duas ou mais variáveis independentes que influencia na variável dependente.

As séries temporais são utilizadas neste estudo e seguem detalhadas no item 2.1.1.

### 2.1.1 Séries Temporais

Box et al. (1994) conceituam séries temporais como uma sequência de dados ordenados ao longo do tempo de característica inerente a dependência do mesmo entre os valores e que a análise é constituída pelas descrições dessas dependências.

Partindo da premissa que o futuro é a continuação do passado, as series temporais a partir de modelos matemáticos procuram realizar as previsões relacionando os dados históricos do produto com o tempo (CORRÊA; GIANESI; CAON, 2014; TUBINO, 2017; LAGE JÚNIOR, 2019).

De acordo com Santos (2015) a series temporais são regidas por um sistema causal que se relaciona com o tempo criando padrões não aleatórios, a identificação e análise do

comportamento desses padrões não aleatórios durante o passado, faz com que se possa obter previsões do futuro auxiliando na tomada de decisão.

A seguir, são descritos resumidamente alguns métodos apresentados na literatura para análise de séries temporais.

### 2.1.1.1 Método Baseado em Médias Móveis Simples

Sendo um dos métodos mais comuns para previsão, a média móvel simples consiste em a média aritmética dos  $n$  últimos períodos observados, sendo calculada por meio da seguinte equação (1) (CORRÊA; GIANESI; CAON, 2014; SILVA, 2019).

$$Pd = \frac{\sum_{i=1}^n Di}{n} \quad (1)$$

Onde:

$Pd$  = Demanda Prevista para período  $j$

$i$  = Índice do período

$i$  = Demanda decorrida do período  $i$

$n$  = Número de período

Analisando a equação o valor de  $n$  influencia diretamente na previsão, ou seja, quanto mais histórico estar presente, mais será a influência de demandas mais antigas sobre as novas. Por esse motivo Tubino (2017) traz que sempre que surge um dado novo, o dado mais antigo deve ser eliminado. Levando em consideração que esse modelo deve ser utilizado para demandas mais estáveis em que não existe variações (SILVA, 2019).

O modelo de média móvel usado neste trabalho considera uma série temporal estacionária e localmente constante  $Z_1, Z_2, \dots, Z_n$ , composta por seu nível e ruído adicional definido por,

$$Z_t = \mu_t + a_t \quad (2)$$

onde  $t = 1, 2, \dots, n$ ; “ $a_t$ ” denota erro (componente estocástica) onde  $E(a_t) = 0$ ;  $\text{var}(a_t) = \sigma^2$  e  $\mu_t$  é um parâmetro desconhecido que varia ao longo do tempo (BOX et. al, 1994 e MORETTIN e TOLOI, 1987). O termo  $E(a_t)$  denota a média ou valor esperado de  $a_t$  e  $\text{var}(a_t)$  denota a variância de  $a_t$ . A técnica da média móvel consiste em calcular a média aritmética das  $k$  observações mais recentes, ou seja,

$$M_t = (Z_t + Z_{t-1} + Z_{t-2} + \dots + Z_{t-k})/k \quad (3)$$



O comprimento da média é dado por  $k$ . Assim,  $M_t$  é uma estimativa de  $\mu_t$  que não leva em conta as observações mais antigas, apenas as últimas  $k$  observações onde a cada período a observação mais antiga é substituída pela mais recente, e uma nova média é calculada. A previsão do futuro valores é dado pela última média móvel calculada, ou seja,

$$Z(h)_t = M_t \quad (4)$$

para todo  $h > 0$ . Observa-se que a equação acima corrige a previsão de  $Z_{t+h}$  a cada instante; ou seja, a cada nova observação na série,  $Z_{t+h}$  é atualizado. Assumir que o ruído em  $z_t$  tem uma distribuição normal com média igual a zero e variância igual a  $\sigma^2$  implica que a previsão, dada por,  $\widehat{Z(h)}_t$  tem para distribuição normal com média igual a  $\mu_t$  e variância igual a  $\sigma^2/k$ . Portanto, um intervalo de confiança para  $\mu_t$  com um coeficiente de confiança igual a  $100(1 - \alpha)\%$  é dado por,

$$\left( \widehat{Z(h)}_t - z_{\alpha/2} \sigma / \sqrt{k} ; \widehat{Z(h)}_t + z_{\alpha/2} \sigma / \sqrt{k} \right) \quad (5)$$

onde  $z_{\alpha/2}$  é um percentil da distribuição normal padronizada  $N(0,1)$ .

### 2.1.1.2 Método Baseado em Médias Móveis Ponderada

Sendo quase idêntica ao método baseado em médias móveis e sendo aplicado para demandas que não apresentem sazonalidade e/ou tendência, o método de médias móveis ponderada utilizando todos os dados históricos presentes crescentemente ao longo do período, sendo representado pela seguinte equação (6) (SILVA, 2019).

$$P_D = (D_1 \cdot PE_1) + (D_2 \cdot PE_2) + (D_3 \cdot PE_3) + \dots + (D_n \cdot PE_n) \quad (6)$$

Onde:

$P_D$  = Demanda prevista para período  $j$

$PE_1 + PE_2 + PE_3 + \dots + PE_n = 1$

$PE_i$  = Peso atribuído ao período  $i$  (Atribuído pelo feeling e sempre dando um peso maior para os períodos mais recentes, e a soma dos pesos devem ser igual a 1)

### 2.1.1.3 Método de Suavização Exponencial Simples

Tendo como base a média ponderada e sendo aplicada para demandas que não apresentem sazonalidade e/ou tendência a suavização exponencial utiliza pesos por meio de

coeficientes de ponderação, fazendo com que se atribua peso decrescente ao longo do período realizado, sendo representado pela seguinte equação (7) (CORRÊA, GIANESI e CAON, 2014; SILVA, 2019).

$$P_j = \alpha \cdot \bar{D} + (1 - \alpha) \cdot D_{j-1} \quad (7)$$

Onde:

$\alpha$  = Coeficiente de ponderação, com  $0,05 \leq \alpha \leq 1$

$\bar{D}$  = Demanda média dos últimos períodos

$D_{j-1}$  = Demanda real no período anterior ao período  $j$

Vale ressaltar ao ver a equação que segundo Tubino (2017) e Corrêa, Gianesi e Caon (2014) a influência do coeficiente de ponderação sobre a previsão, por isso deve se considerar que ele varie entre 0,05 até 1, pois quanto maior for o valor do coeficiente, maior vai ser a variação aleatória da demanda e quanto menor, mais defasadas do real ficarão as previsões.

Constituindo que  $(1 - \alpha)$  se refere a taxa que indica a queda da influência dos dados históricos de demanda para o último mês (sendo  $(1 - \alpha)^2$  para o penúltimo mês,  $(1 - \alpha)^3$  para o antepenúltimo mês e assim sucessivamente) e levando em conta que a atribuição de um valor para “ $\alpha$ ” gera os mesmos resultados obtidos pela utilização do modelo de média móvel simples (LAGE JUNIOR, 2019; SILVA, 2019).

#### 2.1.1.4 Método de Suavização com Tendência (Modelo Holt)

Esse método é composto de uma previsão suavizada adicionando um componente de tendência ao processo, ela é representada pela seguinte equação (8) (LAGE JÚNIOR, 2019).

$$P_{T+k} = S_T + kT_T \quad (8)$$

Onde:

$P_{T+k}$  = Previsão para período (k)

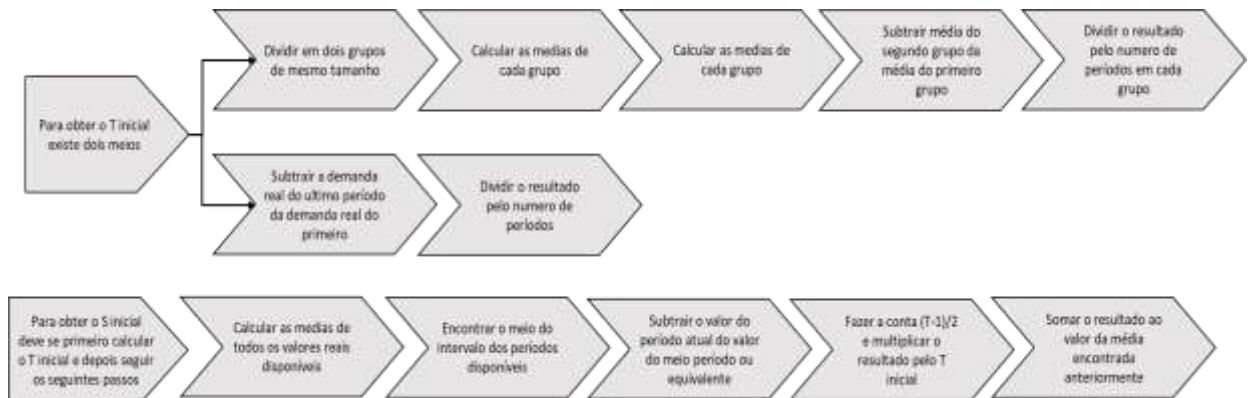
$S_T$  = Previsão suavizada exponencialmente para o último período (T)

$k$  = Número de períodos a frente do período T

$T_T$  = Estimativa de tendência para o período (último período)

Para que o modelo funcione deve primeiro encontrar os valores do T inicial e S inicial seguindo o seguinte fluxo (figura 2):

Figura 2. Fluxo de aplicação do Modelo Holt



Fonte: Elaborado pelo próprio autor com base em Lage Júnior (2019)

Com os valores descobertos pode-se realizar as previsões e para cada valor real que se obtiver pode-se suavizar exponencialmente os valores de  $T_T$  e  $S_T$  de acordo com as seguintes equações (9) (10) (LAGE JÚNIOR, 2019).

$$S_T = \alpha_T + (1 - \alpha) \cdot (S_{T-1} + T_{T-1}) \quad (9)$$

$$T_T = \beta \cdot (S_T - S_{T-1}) + (1 - \beta) \cdot T_{T-1} \quad (10)$$

Onde:

$\alpha$  = Constante de suavização, com  $0 \leq \alpha \leq 1$

$d_T$  = Demanda do período T

$\beta$  = Constante de suavização de tendência

A escolha objetiva dos valores de  $\alpha$  e  $\beta$  são para minimizar os erros de previsão somados a um passo à frente e evita o acompanhamento da tendência às mudanças aleatórias dos dados, a vantagem desse método é que com a otimização desses dois valores traz flexibilidade na qual o nível e a tendência podem ser suavizados com diferentes pesos (LAGE JÚNIOR, 2019; DE LUEGIO, 1998; HYNDMAN et al., 2008).

### 2.1.1.5 Método de Suavização Exponencial com Variação de Tendência (Modelo Holt-Winters)

Para sanar os problemas com demandas de alta variabilidade e sazonalidade do método de Holt, o método de Holt-Winters foi elaborado levando em consideração coeficientes de nível, tendência e sazonalidade, sendo muito mais usual e simples de calcular e com parâmetros de maior robustez (LAGE JUNIOR, 2019; HOLT, 2004).

Segundo Lage Junior (2019) para se calcular esse novo modelo deve-se calcular os valores de  $T_T$  e  $S_T$  de acordo com como foi dito na seção anterior e em seguida seguir os seguintes passos:

1. Calcular os valores iniciais dos fatores de sazonalidade divide-se a demanda pelo  $S_T$  inicial e desconta-se a tendencia de acordo com a equação (11):

$$F_T = \frac{d_t}{S_T - T_T(T-t)} \quad (11)$$

2. Após encontrar esses valores, se deve calcular a média dos fatores dos períodos equivalentes, para obter apenas um parâmetro de cada período.
3. Realizar as previsões de acordo com a equação (12)

$$P_{T+k} = (S_T + kT_T). F_{T+k-L} \quad (12)$$

Onde:

$L$  = Número de variações sazonais

4. Utilizando os valores reais disponíveis deve-se atualizar os valores de  $T_T$ ,  $S_T$  e  $F_T$  deve-se utilizar as seguintes equações (13) (14) (15):

$$S_T = \alpha \cdot \left( \frac{d_t}{F_{T-L}} \right) + (1 - \alpha) \cdot (S_{T-1} + T_{T-1}) \quad (13)$$

$$T_T = \beta \cdot (S_T - S_{T-1}) + (1 - \beta) \cdot T_{T-1} \quad (14)$$

$$F_T = \gamma \cdot \left( \frac{d_t}{S_T} \right) + (1 - \gamma) \cdot F_{T-L} \quad (15)$$

Onde:

$\gamma$  = Constante de suavização ( $0 \leq \gamma \leq 1$ ) com as mesmas característica de  $\alpha$  e  $\beta$

### 2.1.1.6 Método Box-Jenkins (ARIMA)

O modelo de média móvel autorregressiva (ARIMA) explora a autocorrelação entre a serie temporal e a correlação entre os erros sucessivos, após isso identifica a existência de algo em comum entre as observações e dados de demanda sazonal verificando se existe um padrão de ciclo de variação ao longo do tempo, a suposição de autocorrelação é, como regra geral, válida

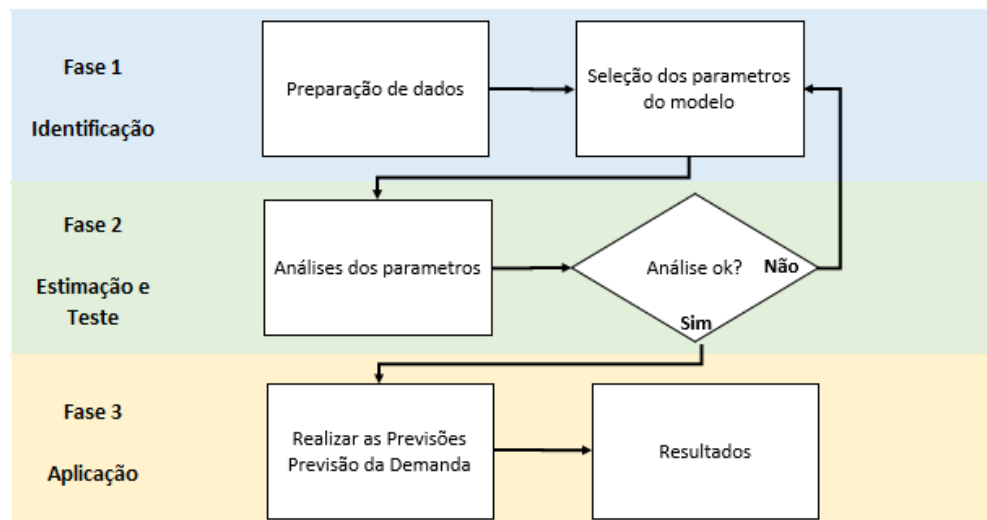
Segundo Zhang (2003) o modelo ARIMA se divide em três fases que são:

- Identificação, que se divide em preparação dos dados, em que há a seleção dos dados e análises e seleção do modelo;

- Avaliação do modelo, que ocorre por meio de inspeção e observação. Se acaso o modelo for reprovado na avaliação deve-se retornar a fase de Identificação e selecionar um outro modelo;
- Geração das previsões.

Pode-se observar o funcionamento do modelo ARIMA no fluxo contido na figura 3.

Figura 3. Fluxo de aplicação do Modelo ARIMA



Fonte: elaborado pelo próprio autor com base em Zhang (2003)

É importante salientar que os modelos apresentados acima apresentam somente a parte sistemática e todos os modelos baseados em amostras aleatórias devem incluir um erro aleatório (variável não-observada) para a obtenção das inferências e previsões de interesse. Neste estudo vamos considerar apenas o uso dos modelos de médias móveis simples e modelos ARIMA.

Uma classe de modelos amplamente utilizada para séries temporais, principalmente na área de finanças, é a classe de modelos ARIMA (*Autoregressive Integrated Moving Average*), geralmente conhecida como método de Box-Jenkins (BOX et al.,1994), que é precisa para previsão de curto prazo, mas nem tanto com a previsão de longo prazo. A análise de uma série temporal no domínio do tempo é realizada por um parâmetro conhecido como coeficiente de correlação serial, ou coeficiente de autocorrelação. Este parâmetro indica a dependência de valores sucessivos de uma série temporal. A maioria dos problemas de previsão envolve o uso de dados de séries temporais. Montgomery et al. (2008) sugerem que os problemas de previsão são frequentemente classificados como curto prazo, médio prazo e longo prazo. O uso de observações disponíveis no tempo  $t$  de uma série temporal usada para prever um valor em algum momento futuro é geralmente considerado como base para planejamento econômico e de

negócios, planejamento da produção, controle de estoque e produção e controle e otimização de processos (BOX et al., 1994).

Geralmente, as previsões são feitas no tempo  $t$ , tomando o mês atual  $Y_t$  e os meses anteriores  $Y_1, Y_2, \dots, Y_{t-1}$ , para prever valores futuros dados por  $F_{t+1}, F_{t+2}, \dots, F_{t+m}$ . A modelagem ARIMA é essencialmente uma abordagem exploratória com grande flexibilidade para montar um modelo apropriado que é adaptado da própria estrutura dos dados. A natureza estocástica da série temporal pode ser modelada aproximadamente com a ajuda da função de autocorrelação e da função de autocorrelação parcial, em que variáveis aleatórias, componentes periódicos, padrões cíclicos e correlação serial podem ser descobertos. Como resultado, as previsões dos valores das séries podem ser facilmente obtidas com alto grau de precisão (Ho e Xie, 1998). O processo é construído por meio da identificação do modelo, estimação dos parâmetros e verificação do ajuste do proposto modelo (Ho e Xie, 1998).

Os modelos ARIMA contêm três componentes: componentes autorregressivos (AR), componentes integrados (I) e componentes de média móvel (MA). A parte AR descreve a relação entre as observações atuais e as observações passadas. A parte MA representa a estrutura de autocorrelação do erro. O componente I representa o nível de diferenciação da série para eliminar a não estacionariedade. Geralmente denotado por ARIMA ( $p, d, q$ ) onde  $p$  indica a ordem de autorregressão,  $d$  denota ordem de diferenciação,  $q$  denota a ordem do movimento médio. Uma breve descrição dessa classe de modelos é fornecida a seguir.

- **Modelo AR:** Um modelo AR( $p$ ) expressa o valor atual da série temporal como uma combinação linear de valores  $p$  anteriores e um termo de ruído branco (choque aleatório). Bell (1984) expressa o valor atual da série temporal do modelo AR( $p$ ) como:

$$Y_t = \phi_1 Y_{t-1} + \dots + \phi_p Y_{t-p} + a_t \quad (16)$$

onde  $\phi_1, \phi_2, \dots, \phi_p$ , são os parâmetros AR( $p$ ),  $a_t$  é o ruído aleatório na distribuição normal com média zero e variância  $\sigma^2$  no tempo  $t$ , e  $p$  é a ordem de AR( $p$ ).

- **Modelo MA:** O modelo MA( $q$ ) expressa o valor atual de uma série temporal como uma combinação linear de ruído atual e  $q$  valores anteriores de ruído branco. A média (puramente) móvel (MA) é o modelo (Bell, 1984):

$$Y_t = a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q} \quad (17)$$

- **Modelo ARMA:** Para aumentar a flexibilidade na construção de séries em tempo real, os componentes autorregressivos e de média móvel são combinados, levando ao modelo ARMA(p,q) (Bell, 1984):

$$Y_t = \phi_1 Y_{t-1} + \dots + \phi_p Y_{t-p} + a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q} \quad (18)$$

O tipo misto de série que é explicado por seus próprios valores defasados e por termos de ruído defasados são chamados de modelos ARMA(p,q). Se o processo for estacionário, um modelo ARMA pode ser usado para representar os dados. Se não for estacionário, a diferenciação é aplicada para tornar o modelo estacionário e isso leva ao modelo ARIMA (AKGUN, 2003).

- **Modelo ARIMA:** A primeira destas condições implica que a série  $Y_t$  dada em (9) é estacionária. Na prática, a série  $Y_t$  pode não ser estacionária, mas com a primeira diferença estacionária  $Y_t - Y_{t-1}$ ; se  $Y_t - Y_{t-1}$  não for estacionário, podemos precisar tomar a segunda diferença  $(Y_t - Y_{t-1}) - (Y_{t-1} - Y_{t-2})$  e assim por diante. Em geral, podemos precisar tomar a  $d$ -ésima diferença de  $Y_t$  (embora raramente  $d$  seja maior que 2). Assim, tem-se o ARIMA (p, d, q) onde  $d$  é a ordem de diferenciação. Assim, um ARIMA (p, d, q) pode ser dado para  $t = t + v$  por,

$$Y_{t+v} = \phi_1 Y_{n+v-1} + \dots + \phi_{p+d} Y_{n+v-p-d} + a_{n+v} - \theta_1 a_{n+v-1} - \dots - \theta_q a_{n+v-q} \quad (19)$$

### 2.1.2 Erros de Previsão

Os erros de previsão são nada mais nada menos que medidas de acurácia que identificam a precisão de um método ou critério de seleção de métodos de previsão e para selecionar qual erro deverá ser utilizado, depende da seleção do método ou do número de series temporais analisadas (LEMOS, 2006).

Os erros auxiliam na flexibilidade do sistema produtivo, fazendo com que o método de previsão responda rapidamente as mudanças de padrões da demanda do mercado durante o tempo (KAHN, 1998).

Os autores Elsayed e Boucher (1994), Armstrong e Collopy (1992) e Kahn (1998) sugerem os seguintes erros para utilização:

- MAE (erro absoluto médio) – Mais utilizado para medir a acurácia dos modelos;
- MSE (erro quadrático médio) – Medida de acurácia mais indicada para estudos empíricos, porém não é indicada para comparação de diferentes séries, pois depende da escala dos dados;
- MAPE (média dos erros percentuais absolutos) – É o erro mais utilizados para estudos empíricos que comparam métodos de previsão, pois utiliza o percentual do erro e não depende da unidade dos dados;
- RMSE (raiz do erro quadrático médio) – É indicado apenas para comparação de métodos;
- MdRAE (mediana dos erros relativos absolutos) – Indicado quando está se analisando poucas series temporais, porém é limitada por problemas de interpretação dos tomadores de decisão;
- MdAPE (medianas dos erros percentuais absolutos) – Indicado para quando está se analisando diversas series temporais;
- RMSE (Raiz do erro quadrático médio) – Pode ser utilizado na medição de acurácia do método, mas desaconselhado quando se quer comparar os métodos.

### 2.1.3 Estudos correlatos sobre previsão de demanda utilizando series temporais

Este item apresenta estudos correlatos ao que se pretende desenvolver, ou seja, autores que estudaram a previsão de demanda por meio das séries temporais. Os critérios utilizados para esta pesquisa seguem detalhados na seção 3, sobre a metodologia. Apresentam-se no quadro 2 os artigos encontrados entre os anos 2015 e 2021.

Quadro 2 - Estudos correlatos

Autores	Ano	Características	Origem Dados
Veiga; Veiga; Tortato.	2016	Descreve as características fundamentais de um processo de previsão de demanda e revisa os principais métodos de previsão mais comuns e fáceis de usar, em especial os baseados em séries temporais.	Teoria



<b>Autores</b>	<b>Ano</b>	<b>Características</b>	<b>Origem Dados</b>
Tratar; Mojškerc; Toman.	2016	Por meio de previsão de demanda em dados econômicos desenvolveu um método de suavização fácil de usar e que produz melhores previsões quando aplicado a séries temporais com várias entradas zero e ruído substancial.	Demanda de negócios e economia
Martin et al.	2016	Analisou o crescimento da frota de automóveis em Joinville - SC para que o conhecimento da evolução de demanda possibilite aos órgãos públicos o dimensionamento urbano, desenvolvimento de tráfego, entre outros.	Dados e carros cadastrados mensalmente no DETRAN
Vargas; Cortés	2017	Por meio de previsão de demanda verificou o melhor método, (considerando sua precisão e facilidade de implementação) para resolver o problema de previsão de demanda em uma empresa de autopeças no México.	Dados de demanda das peças
Santa Cruz; Corrêa	2017	Fez um estudo sobre a previsão de demanda intermitente de uma indústria de sistemas de refrigeração de peças de reposição.	Demanda de clientes
Belvedere; Goodwin	2017	Por meio de análises baseada em emoções verificou se a precisão das previsões de demanda de curto prazo era influenciada pelo nível de envolvimento dos analistas com a categoria do produto ou por suas preferências pessoais no mercado da Moda.	dados de opiniões de participantes
Fattah et al.	2018	Por meio de das series temporais elaborou um plano de produção baseado nas previsões minimizando o custo total de produção composto pela aquisição e processamento dos produtos em uma empresa do setor Alimentício.	Demanda do produtor final
Lee; Kim	2019	Por series temporais construiu diversos modelos de previsão de demanda de peças de reposição usando métodos qualitativos quantitativos e propôs implicações gerenciais e teóricas com base em nossos resultados para melhor a gestão e a previsão de demanda de peças de reposição no meio militar.	Dados de peças mais utilizadas
Rivera-Castro et al.	2019	Por meio de revisão da literatura comparou o desempenho da técnica proposta. para encontrar equilíbrio entre acessibilidade e precisão de métodos para séries temporais em um contexto de dados massivo dentro da indústria de eletrônicos na Rússia	Demanda dos produtos
Yin et al.	2019	Realizaram um estudo sistemático de oito modelos de previsão em uma ampla gama de oito conjuntos de dados, variando de tráfego, demanda de commodities de supermercados e produção de energia solar.	Dados Series temporais
Kim	2019	Para encontrar um método de previsão de demanda sobre peças de reposição no meio militar, se usou de series temporais para resolver trazendo uma abordagem que mostra melhor desempenho na previsão de demanda com maior precisão quantitativa e melhor precisão de previsão do que a série temporal existente.	Dados de peças mais utilizadas

<b>Autores</b>	<b>Ano</b>	<b>Características</b>	<b>Origem Dados</b>
Kačmáry; Malindžák; Spišák	2019	Descreve a metodologia pela qual uma empresa de Eletro-moção, lidando com peças de reposição relativamente caras, resolveu problema de previsão de demanda.	Dados de pedidos
Bandeira et al.	2020	Trouxe uma comparação de estratégia de seleção de métodos de previsão e duas estratégias de combinação de métodos de previsão solucionar problemas de previsão de demanda com características diferentes em uma empresa do setor de elevadores do Brasil.	Dados de demanda
Abolghasemi et al.	2020	Validou um modelo de previsão que pode capturar os efeitos de eventos sistemáticos quantificáveis que necessitariam de julgamento e ajustes em duas empresas de Bens de consumo rápido na Austrália.	dados de opiniões de participantes
Salais-Fierro et al.	2020	Por meio de das series temporais, trouxe um modelo de previsão mais assertivo para veículos leves na Industria Automotiva	dados de opiniões de participantes e demanda
Brinkhoff; Robson	2020	Por meio de da previsão de demanda por series temporais, trouxe um modelo mais assertivo, fazendo assim o cálculo da área produtiva e total de produção encontrando assim o rendimento na indústria de Macadâmia na Austrália.	dados de plantio por área
Das; Chakrabarti	2021	Analisou as tendências dos WPIs mensais de setenta e sete commodities da <i>ManufChem-Items Wadi</i> , identificou quais são dos WPIs do grupo <i>ManufChem-Items</i> com tendência não linear e desenvolveu um modelo adequado para gerar previsões para os índices <i>WPINonLinear</i> com doze meses de antecedência.	Dados WIP da empresa
Zhu X et al.	2021	Para superar o problema de previsão de demanda, por meio de series temporais propôs um modelo que resolveram os problemas de demanda e organização de estoque em duas empresas do setor farmacêutico.	Dados de quantidade vendida, TP, distribuidor e nível de estoque do CD)
Elsamie; Ali; Zhou	2021	Por meio de da Previsão de demanda da safra de algodão egípcio, trouxe o olhar para o desenvolvimento das áreas cultivadas, produtividade e produção da Safra de algodão egípcio no futuro e fazendo propostas e recomendações que contribuirão para políticas de planejamento e produção no futuro.	dados de plantio por área

Fonte: Elaborado pelo autor.

O campo no quadro 2 descrito como origem dos dados utilizados foi útil como fonte de informação para se verificar a aplicação das séries temporais, nos artigos selecionados, para se observar quais dados são utilizados para se prever demanda sejam eles referentes a demanda dos produtos, dados históricos de venda, dados históricos de consumo e de pedidos. Dentre os

métodos de séries temporais os que mais aparecem nos trabalhos são dados de demanda do produto e dados de venda.

Segundo Vargas e Cortés (2017) que buscaram uma alternativa para prever demanda com maior assertividade para enfrentar o problema de previsão de demanda de autopeças, se utilizou da previsão de demanda por meio series temporais trazendo que os modelos clássicos são ótimos e simples quando a demanda apresenta um comportamento suave e os modelos ARIMA são o que obtiveram os melhores resultados inclusive para grandes horizontes de tempo, também alertou para sempre respeitar as metodologias quando se for selecionar o modelo mais adequado para cada serie temporal.

Já Cruz e Correia (2017) buscavam estimar a demanda futura com mais assertividade para superar o problema de “superprodução” e comprometimento das vendas futuras para peças de reposição de sistemas de refrigeração, em que por meio da previsão de demanda por series temporais das 10 séries temporais apresentadas, pode observar que os modelos clássicos são de grande valia para implementação e rapidez auxiliando muito na assertividade e para previsão de longo prazo o RNA foi o que apresentou os erros menores em relação ao real, porém com uma dificuldade evidente na aplicação.

Fattah et al. (2018) se utilizaram de previsão por meio de series temporais para solucionar um problema de produção em que apresentou uma comprovação do modelo ARIMA para prever demanda e fornecer aos gerentes de dados confiáveis e condizentes com a realidade para ser elaborado os planos de produção da empresa orientando assim a tomada de decisão estratégica para a empresa.

Devido ao problema de não se conseguir prever o plantio de macadâmia e com isso determinar a área produtiva Brinkhoff e Robson (2020) utilizaram previsão de demanda por meio de series temporais para conseguirem resolver o problema, e com isso apresentaram resultados positivos e determinado a área de plantio e com isso a produção total auxiliando nas decisões tomadas pela empresa.

Os artigos apresentados destacam a importância de se utilizar previsão de demanda por meio de series temporais para a resolução de problemas como superprodução, não atendimento dos prazos de entrega, atrasos gerados por falta do produto, falta de organização nos estoques e inclusive problemas de previsão em si. Os trabalhos apresentam que a previsão de demanda por meio de series temporais pode ser utilizada em diversas empresas e setores para melhoria do sistema produtivo.

Pode-se observar que a aplicação de previsão de demanda por meio de series temporais é um dos métodos utilizados para prever demanda, esse método possui facilidade de utilização

e alta performance nos resultados, porém para que se tenha confiabilidade é de suma importância que o procedimento, para seleção e utilização do método de séries temporais, seja respeitado, pois caso isso não ocorra pode ocasionar grandes erros e falhas nas previsões.

Quando se trata de resolução de problemas de estratégia, planejamento e informações confiáveis para tomada de decisão sobre o futuro pode-se observar a grande contribuição do método de previsão de demanda por meio de series temporais, pois os trabalhos apresentam os ganhos com a utilização do método para o processo de gestão no fluxo produtivo, nas tomadas de decisões e busca por soluções, seja realizando previsões em curto, médio ou longos períodos.

Analisando os trabalhos, muitos deles destacam sobre a realização de aplicações de series temporais para prever demanda e os resultados para as empresas estudadas, porém poucos mostram todo caminho, ou seja, o passo a passo para desenvolvimento desse tipo de estudo, como se chegar ao resultado.

Com toda informação que os trabalhos trazem pode-se afirmar que os problemas apresentados nessa pesquisa são problemas em comum em todas as áreas desde agrícola, industrial e até pública. O uso da previsão de demanda por meio de séries temporais pode ser uma alternativa para solução destes problemas, trazendo ganhos aos cenários estudados.

### 3. METODOLOGIA

O objetivo desta seção é abordar o enquadramento metodológico da pesquisa, bem como apresentar os procedimentos operacionais relacionados ao estudo prático realizado.

#### 3.1 Características da pesquisa

Turrioni e Mello (2012), Moresi (2003), Gil (2010), Cervo, Bervidan e Silva (2010) e Lakatos e Marconi (2010) amparam a seguinte classificação metodológica:

1. Em relação a Natureza
  - Estudo de Natureza Aplicada – Visa o interesse prático e solução de problemas;
  - Estudo de Natureza Básica – Visa a busca por novos conhecimentos contribuindo para o avanço da ciência, inicialmente sem aplicação prática;
2. Em relação ao Objetivos
  - Objetivos Exploratório – Busca um maior entendimento de um determinado fenômeno pouco explorado, a fim de torná-lo compreensível ou formular alguma hipótese;
  - Objetivos Descritivos – Verifica a frequência de ocorrência de um determinado fenômeno e suas características, por meio de coletas de dados em que serão feitos análises, observações e registros;
  - Objetivos Explicativos – Investiga por meios de pesquisas empíricas, visando testar e explicar o porquê de um fenômeno;
3. Em relação a Abordagem
  - Abordagem do problema Quantitativa – Tem como finalidade as análises e variáveis mensurando-as;
  - Abordagem do problema Qualitativa – Tem como finalidade variáveis subjetivas
  - Abordagem do problema Combinada – Integração dos métodos qualitativos e quantitativos;
4. Em relação aos Procedimentos Técnicos
  - Procedimento de Modelagem Matemática – Por meio de técnicas matemáticas se constrói um modelo, baseado no real, descrevendo e determinado como será o funcionamento desse sistema e como ele responderá sobre as modificações propostas.

- Procedimento de Levantamento ou *Survey* – Se utiliza de técnicas quantitativas para se obter informação de um determinado grupo, mais utilizado quando se deseja saber sobre opiniões, costumes ou características de um público-alvo;
- Procedimento de Pesquisa Experimental – Tem como finalidade o teste de hipótese do que se está estudando por meio da manipulação de variáveis relacionado ao objeto de estudo;
- Procedimento de Estudo de Caso – É uma investigação empírica feita pelo pesquisador em que ele se insere na realidade do objeto e analisa os resultados. Desde modo o pesquisador não influencia em nada, apenas é um expectador;
- Procedimento de Pesquisa Ação – Por meio de técnicas existentes informa qual ação se deve tomar para a melhoria pratica;
- Procedimento *Soft System Methodology* (SSM) – Com a perspectiva qualitativa, essa metodologia é uma modelagem de processos organizacionais para se chegar a uma solução geral de problemas ou no gerenciamento da mudança;

Tendo em vista o enquadramento descrito este estudo pode ser classificado do seguinte modo:

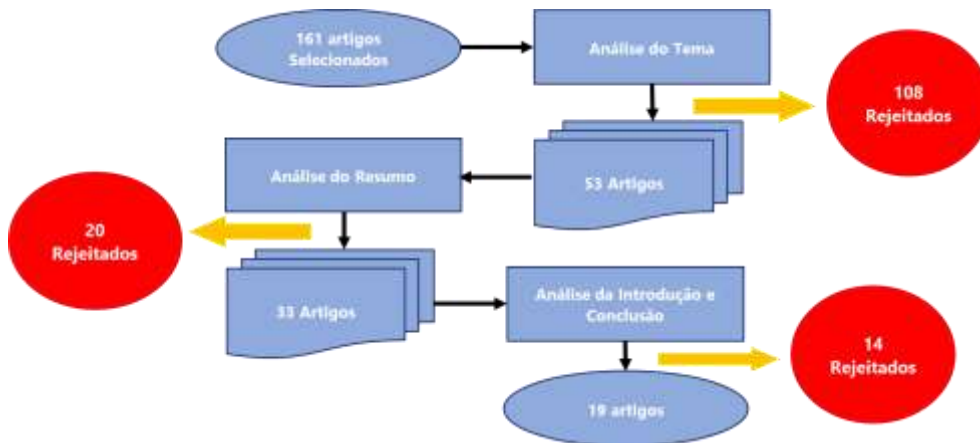
- Natureza aplicada, pois visa solucionar um problema com dados reais em uma empresa farmoquímica.
- Objetivos exploratório e descritivos, visando tornar o problema explicito, descrevendo os resultados encontrados, utilizando o embasamento teórico de uma revisão de literatura observando como situação semelhantes foram abordadas.
- Abordagem quantitativa, se utilizada de dados históricos estatisticamente tratados para análise de demanda.
- Procedimento de modelagem matemática estatística, pois identifica o modelo de series temporais mais adequado para se utilizar como método de previsão de demanda.

O processo de escolher, visualizar, conhecer, condensar, analisar e sintetizar uma gama de artigos científicos de um determinado assunto, a fim de sintetizar uma conclusão teórica, se denomina revisão bibliográfica sistemática (CONFORTO; AMARAL; SILVA, 2011 p.3).

A revisão da literatura teve início com consulta a Base *Scopus* em Outubro de 2021 utilizando as seguintes palavras chaves: *Demand; forecasting; Demand forecast; Demand Forecasting; Times Series* e *Long and Short*, após foram filtrados artigos de 2015 até 2021 totalizando 161 artigos.

Na sequência realizou-se um filtro para análise do tema por meio da leitura dos títulos e palavras-chave verificando a aderência ao projeto, diminuindo a quantidade de trabalhos para 53. Na etapa seguinte foram lidos os resumos (também verificando a aderência), trazendo um total de 33 artigos. Após leitura da introdução e conclusão destes 19 foram selecionados para base desta pesquisa, devido a sua similaridade com o problema e método pretendido nesse estudo, conforme a figura 4 abaixo:


Figura 4. Fluxo de análise dos artigos.



Fonte: Elaborado pelo autor

Na figura 5 pode-se identificar que os trabalhos possuem diversas origens ao redor do globo dando ênfase no continente asiático que possui 5 trabalhos e 2 são de origem da Coreia do Sul e 2 da China, na sequência empatados aparecem América do Sul e Europa com 4 trabalhos cada, em que 3 trabalhos são do Brasil e 1 da Colômbia se tratando de América do Sul enquanto na Europa está bem distribuído entre Rússia, Itália, Eslovênia e Eslováquia com 1 trabalho cada. Em seguida aparece Oceania, América do Norte e África com 2 trabalho cada sendo de origem 2 da Austrália (Oceania), 2 México (América do Norte) e 1 Marrocos e 1 Egito (África).


Figura 5 – Distribuição dos trabalhos por Origem.



Fonte: Elaborado pelo autor.

Os artigos selecionados estão distribuídos de janeiro de 2015 até outubro de 2021, ou seja, por volta de 5 anos, pode-se notar que o tema teve crescimento principalmente nos anos de 2019 e 2020 (figura 6).

Figura 6 – Distribuição dos trabalhos por ano.



Fonte: Elaborado pelo autor.

As publicações estão distribuídas em diversas áreas do conhecimento e como pode-se notar há uma predominância com a implementação de estudo em indústrias. Na figura 7 pode-se observar um total de 10 trabalhos em indústrias, 2 em moda e alimentação e seguidos de economia, farmacêutica, conceito, moda e agrícola com 1 trabalho cada.



Figura 7 – Distribuição dos trabalhos por áreas do conhecimento.



Fonte: Elaborado pelo autor.

Dentre os estudos apresentam-se 18 de natureza aplicada fazendo uso de modelagem e apenas um estudo teórico, conforme figura 8.

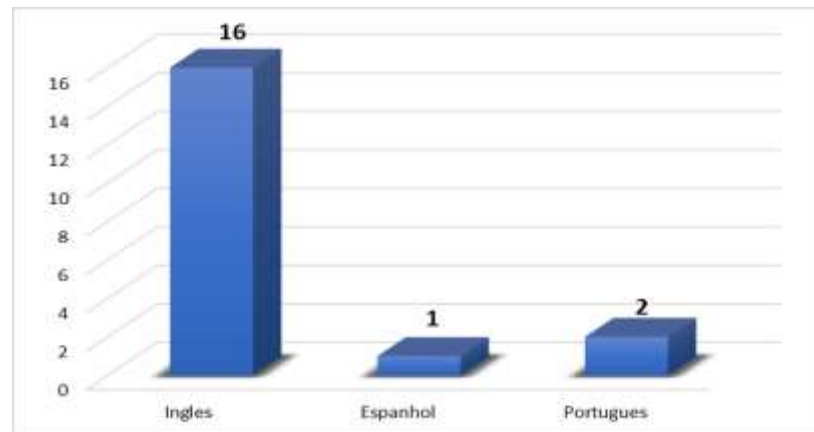
Figura 8 – Distribuição dos trabalhos por tipo.



Fonte: Elaborado pelo autor.

A maioria dos trabalhos (16 deles) estão produzidos em inglês, sendo seguida por trabalhos produzidos em português (2 deles) e apenas um único trabalho produzido em espanhol, de acordo com a figura 9.

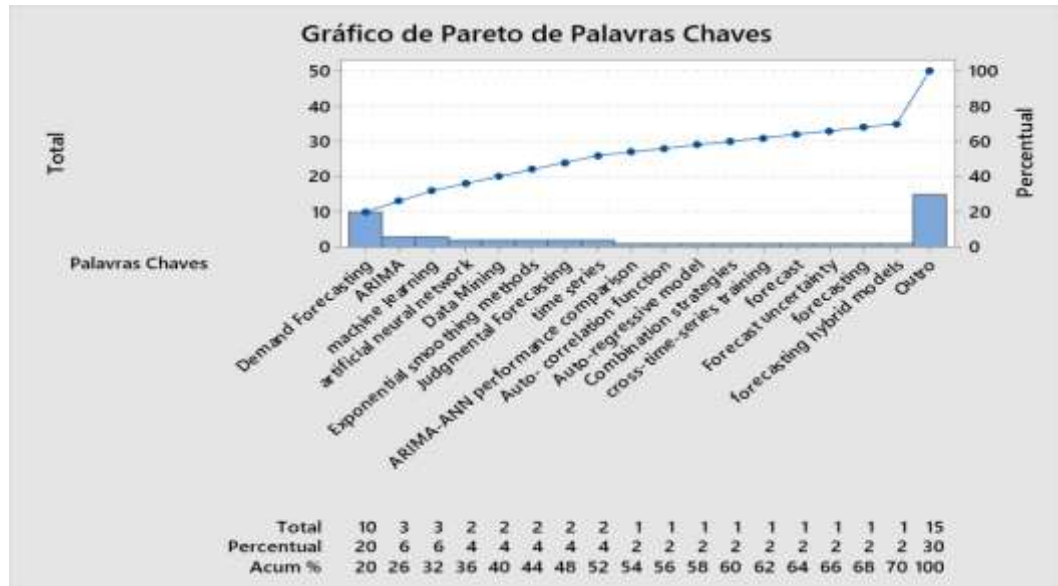
Figura 9 – Distribuição dos trabalhos por idioma.



Fonte: Elaborado pelo autor.

No Pareto da figura 10 observa-se que 20% das palavras chaves dos trabalhos analisados são “*Demand Forecasting*” seguidos pelo restante das palavras chaves “ARIMA” e “*Machine learning*” que quase não representam ocorrências.

Figura 10 – Pareto das palavras chaves encontradas



Fonte: Elaborado pelo autor.

### 3.2 Procedimentos operacionais

O estudo foi realizado em uma empresa que atua no setor farmacêutico, veterinário e agrícola há mais de 22 anos no interior de São Paulo. A Empresa se dedica à produção de suplementos minerais para área humana e veterinária, ativos para mercado de cosméticos e

produtos acabados para nutrição vegetal. Atualmente, com mais de 64 produtos em sua linha, e diversas patentes criadas a empresa continua inovando, por meio de esforços em pesquisa e desenvolvimento, para atender de maneira cada vez mais eficiente às necessidades de seus clientes.

Devido à falta de previsão de demanda, a empresa passa por algumas dificuldades como altos estoques de produtos não utilizados e muitos desses por vezes acabam ultrapassando seu prazo de validade, isso também afeta a financeiro e compras, pois em vezes tem de comprar matéria prima emergencialmente, se uma cotação previa e negociação, em que o custo é muito mais alto

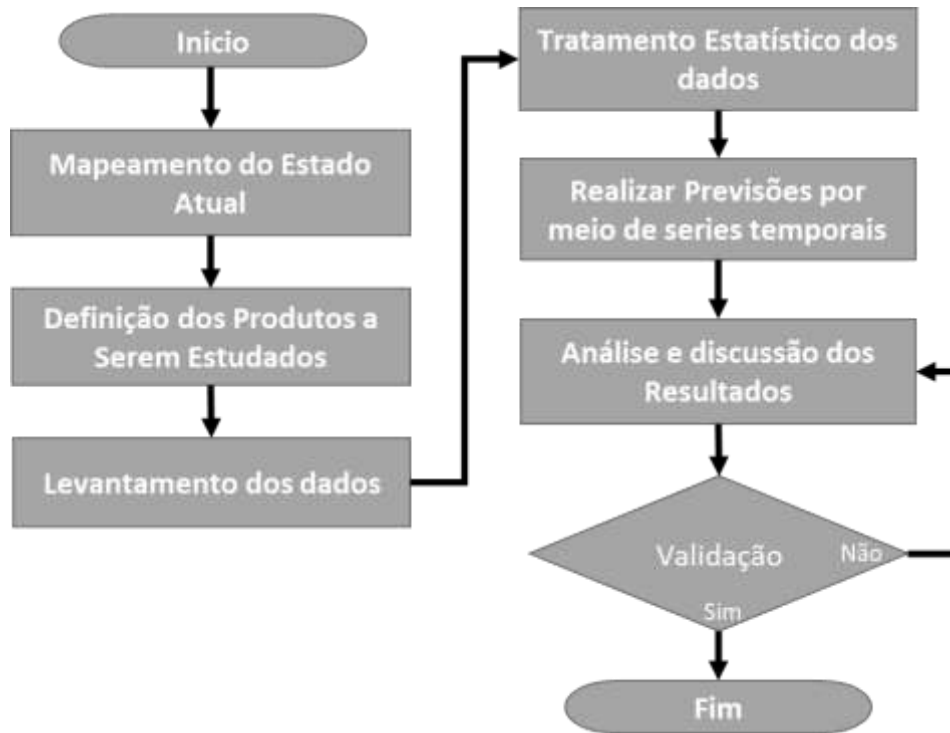
Outro grande problema é a produção de produtos que por vezes não são embalados e ficam na prateleira ocupando espaço e sendo um ativo parado, e a perda de oportunidades de produção em que devido à falta de previsão de demanda não se tem um plano de produção adequado se produzido de maneira equivocada. Porém o principal problema é o não cumprimento de alguns prazos de entrega para o cliente final, o que é muito prejudicial para reputação da empresa.

Para realizar esse estudo primeiramente efetuou-se o mapeamento do estado atual da empresa e identificação os principais problemas, devido a não existência de um sistema de previsão de demanda. Na sequência realizou-se um estudo para levantamento dos produtos a serem analisados, seguido de tratamento estatístico dos dados apurados.

Após as análises foram realizadas as previsões por meio de series temporais utilizando o *software* Minitab® para facilitar e agilizar a obtenção dos resultados. Foram realizadas a seguir as análises e discussões para definição do melhor modelo de previsão e após isso, apresentado aos diretores da empresa em busca de uma validação do estudo.

A figura 11 representa uma visão passo a passo para todo o desenvolvimento desse estudo.

Figura 11 – Passo a Passo para Desenvolvimento do Estudo.



Fonte: Elaborado pelo autor

## **4. APLICAÇÃO DO MÉTODOS DE SÉRIES TEMPORAIS EM UMA EMPRESA DO SETOR FARMOQUÍMICO**

Essa seção tem como objetivo principal detalhar todo o desenvolvimento do estudo apresentando como foi realizado e o resultado encontrado.

### **4.1 Mapeamento do Estado Atual**

Para início do processo foi realizado um mapeamento do processo desde a compra da matéria prima, passando pelo processamento, produção do produto a granel, embalagem, estoque, expedição e venda do produto.

Após entendimento de todo o processo produtivo e reuniões realizadas com especialistas do processo como: supervisor de compras, supervisor de almoxarifado, supervisor de produção, gerente de produção, gerente comercial e vendas, coordenador de PCP e outros colaboradores que se relacionam com o processo foi identificado os seguintes problemas relacionados a falta de um processo de previsão de demanda.

- Altos estoques
- Vencimento de produtos na prateleira
- Gastos altos com a compra de matéria prima
- Não cumprimento dos prazos de entrega para o cliente
- Retrabalho

De acordo com o observado foi proposto definir um método de previsão de demanda para os produtos de empresa para se melhorar o fluxo e as programações, após isso foi levantado todo o portfólio de produtos da empresa, porem como a empresa possui mais de 64 produtos, o estudo teve de ser direcionado para aqueles produtos mais relevantes.

### **4.2 Definição dos produtos a serem estudados**

Para a aplicação do método proposto levantou-se os 10 produtos mais relevantes de acordo com os dados de venda de cada um. Após isso, foi definido junto à área comercial, em uma reunião, os que possuíam maior faturamento, na sequência em outra reunião, agora em conjunto com o PCP e representantes da produção, foi elencado dos 10 produtos os quais possuíam a maior produção. Para realizar as definições de quais produtos seriam estudados, nas

reuniões foi apenas perguntado para os participantes, de acordo com a percepção de cada um se possuía um impacto alto ou baixo, o Quadro 3 apresenta os resultados das análises realizadas.

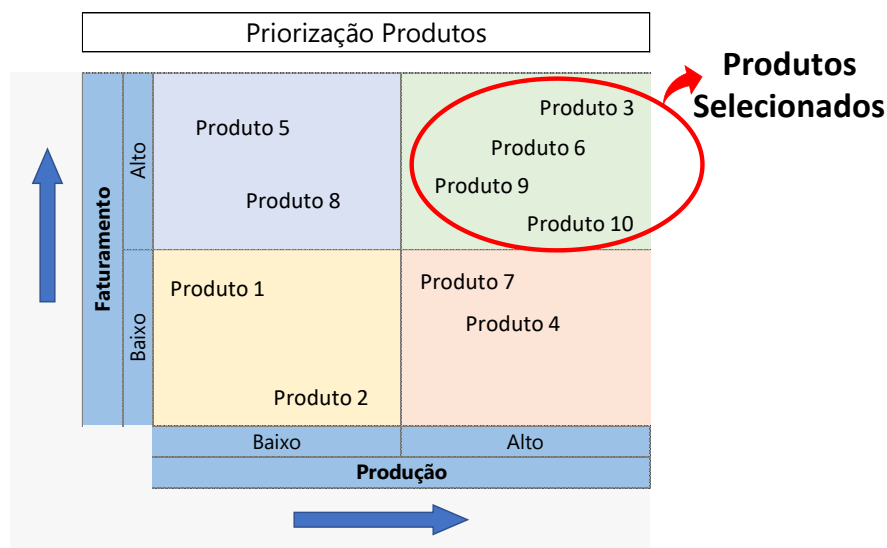
Quadro 3 – Matriz faturamento x produção para escolha dos produtos.

Área Comercial										
Produtos	Produto 1	Produto 2	Produto 3	Produto 4	Produto 5	Produto 6	Produto 7	Produto 8	Produto 9	Produto 10
Faturamento	Baixo	Baixo	Alto	Baixo	Alto	Alto	Baixo	Alto	Alto	Alto
PCP e Produção										
Produtos	Produto 1	Produto 2	Produto 3	Produto 4	Produto 5	Produto 6	Produto 7	Produto 8	Produto 9	Produto 10
Produção	Baixo	Baixo	Alto	Alto	Baixo	Alto	Baixo	Baixo	Alto	Alto

Fonte: Elaborado pelo autor

Unindo a percepção de todos os envolvidos com os interesses da empresa, por meio de uma matriz de Valor de Faturamento x Total de Produção, chegou-se a um montante de 4 produtos de acordo com a figura 12.

Figura 12 – Matriz faturamento x produção para escolha dos produtos.



Fonte: Elaborado pelo autor

Por fim, com o aval e opiniões dos gerentes comercial, produção e administrativo foram definidos os produtos que são alvo desse estudo, chamados de produto 3, produto 6, produto 9 e produto 10, que juntos representam 70% do valor do faturamento total da empresa. Os produtos são apresentados desse modo, pois a empresa não autorizou a divulgação dos nomes e dados financeiros.

### 4.3 Levantamento dos Dados

Com a definição de quais produtos seriam objeto de estudo e por meio da utilização de dados obtidos junto ao ERP (sistema de informação) da empresa, foram levantados os dados de demanda dos produtos selecionados, e filtrados trazendo a demanda mês a mês durante os anos de 2017, 2018, 2019, 2020 e 2021.

Os produtos 6, 9 e 10 são substâncias farmacológicas inativos e inerentes incorporadas como veículo para certos medicamentos, ou seja são excipientes para produtos farmacêuticos, eles são vendidos por quilo e em qualquer quantidade.

Já o produto 3 é um fertilizante orgânico para aplicação agrícola que possui aminoácidos que agem como transporte e armazenamento, suporte mecânico, integração do metabolismo, controle do crescimento e diferenciação foliar, ele é vendido por unidade sendo de 1L, 5L e 20L.

A tabela 1 abaixo apresenta o levantamento realizado para todos os produtos. Observa-se uma grande limitação dos dados mensais, pois em alguns meses tem-se observações dadas por milhares de unidades e outros meses com valores muito pequenos (por exemplo o valor 1) o que torna muito difícil obter previsões mensais com grande precisão usando modelos usuais de series temporais. O ideal para esse caso seria agrupar os dados (por exemplo, dados trimestrais) mas o tamanho da amostra seria drasticamente reduzido dado o período de acompanhamento (apenas 5 anos, ou 60 meses). Se fossem considerados dados trimestrais, as séries seriam reduzidas para apenas 20 observações.

Tabela 1 – Demanda produtos 3, 6, 9 e 10.

Ano	Mês	Quantidade em KG			Quantidade em Unidade		
		Produto 6	Produto 9	Produto 10	Produto 3 (20L)	Produto 3 (5L)	Produto 3 (1L)
2017	Jan	2153	3860	1280	551	8	1
2017	Fev	2250	4800	3450	132	13	12
2017	Mar	105	2861	1150	197	29	62
2017	Abr	2650	2539	391	9	144	48
2017	Mai	2000	1	4494	1630	49	204
2017	Jun	2802	1003	2000	10	100	24
2017	Jul	3228	1777	2800	128	1	1
2017	Ago	2893	1985	3452	84	116	96
2017	Set	1357	4408	1307	60	21	124
2017	Out	4001	7676	6327	1630	4	25
2017	Nov	1604	2964	2090	1262	248	326
2017	Dez	2280	2432	2375	556	48	120
2018	Jan	266	1159	855	240	1	180

2018	Fev	2584	2812	3002	55	140	1
2018	Mar	1007	2580	1	257	8	60
2018	Abr	988	1634	3515	33	280	96
2018	Mai	1	1976	1	1	1	1
2018	Jun	1767	778	855	480	224	192
2018	Jul	2546	2717	2356	302	20	1
2018	Ago	1463	3572	6878	53	108	228
2018	Set	2489	3971	4218	1	1	1
2018	Out	3667	5871	2945	242	460	144
2018	Nov	1	1	1	28	282	293
2018	Dez	1026	1	4066	679	12	348
2019	Jan	1026	1	4370	220	12	36
2019	Fev	2413	2033	608	373	20	1
2019	Mar	988	2014	2014	48	257	276
2019	Abr	1	1026	19	376	40	1
2019	Mai	1976	3002	2983	625	220	1
2019	Jun	988	1976	988	10	12	1
2019	Jul	2983	3971	2489	1	80	1
2019	Ago	2388	3282	6778	4	35	116
2019	Set	2983	4978	2470	30	160	240
2019	Out	1501	2470	4484	17	16	24
2019	Nov	950	1	1	337	100	1
2019	Dez	2983	4465	2983	90	120	48
2020	Jan	1	988	1482	370	13	1
2020	Fev	1482	2489	1995	143	252	120
2020	Mar	1843	2470	1976	317	46	1
2020	Abr	4674	4047	4028	18	126	1
2020	Mai	1976	2470	2470	32	160	480
2020	Jun	3458	4389	3876	1590	3	255
2020	Jul	3094	10468	3684	7	361	1
2020	Ago	5567	3852	3453	816	83	29
2020	Set	1972	5423	7395	16	41	1
2020	Out	5916	2958	493	974	74	144
2020	Nov	1972	2958	1479	350	514	1
2020	Dez	1	1	1	1638	246	168
2021	Jan	1	1	1	181	26	125
2021	Fev	629	680	643	1149	3	145
2021	Mar	3451	9860	6409	162	25	363
2021	Abr	493	2958	2958	118	8	1
2021	Mai	4471	7990	7990	187	216	468
2021	Jun	4930	1972	5423	55	432	29
2021	Jul	1	1	1	758	46	770
2021	Ago	2958	3451	3944	398	68	24
2021	Set	986	2958	3138	1454	68	1
2021	Out	1	1	1	742	1	1
2021	Nov	1	1	1	237	4	1
2021	Dez	119	629	1	793	1	1

Fonte: Elaborado pelo autor



#### 4.4 Análise descritiva dos dados

Primeiramente foi realizada análises estatísticas dos dados utilizando o *software* Minitab®. A Tabela 2 apresenta alguns dados de todo o banco analisado como a quantidade de dados, a média, o desvio padrão e o valor dos quartis.


Tabela 2 – Estatísticas dos Dados.

Variável	N	N*	Média	EP Média	DesvPad	Mínimo	Q1	Mediana	Q3	Máximo
Produto 6	60	0	1938,0	192,0	1486,0	1,0	959,0	1972,0	2942,0	5916,0
Produto 9	60	0	2760,0	296,0	2296,0	1,0	1009,0	2514,0	3858,0	10468,0
Produto 10	60	0	2547,0	271,0	2098,0	1,0	696,0	2423,0	3828,0	7990,0
Produto 3 (20L)	60	0	387,6	60,9	471,7	1,0	36,8	208,5	554,8	1638,0
Produto 3 (5L)	60	0	103,5	16,1	124,8	1,0	12,0	47,0	156,0	514,0
Produto 3 (1L)	60	0	107,8	19,5	151,4	1,0	1,0	32,5	162,3	770,0

Fonte: Elaborado pelo autor

Feito isso, a próxima etapa foi gerar um gráfico de series temporais dos produtos para verificar como os dados estão se comportando ao longo do tempo, a figura 13 apresenta os gráficos de series temporais dos produtos de acordo com o banco de dados.

Figura 13 – Series temporais dos Produtos.




Fonte: Elaborado pelo autor

Todos os produtos apresentam diversos *outliers* ao longo do tempo, porém nenhum deslocamento brusco para justificar alguma mudança drástica na demanda, sendo muito difícil observar alguma tendência nos gráficos que apresentam uma variação aleatória, ou seja, sem padrões. Podem-se observar leves mudanças aditivas em que os valores tendem a aumentar conforme o tempo.

#### **4.4.1 Análise descritiva do Produto 6**

Inicialmente foi realizado o *boxplot* dos dados do produto 6 para identificar variabilidade nos dados e de acordo com a Figura 14 pode-se observar que existe diferença significativa entre os anos, tendo o de 2017 com uma menor variabilidade, já na análise por mês pode-se observar uma grande variabilidade entre os meses, apresentando destaque para os meses de abril e outubro que possuem grande variabilidade.

Figura 14 – Análise da dispersão e valores dos conjuntos de dados (*Boxplot* Produto 6).



Fonte: Elaborado pelo autor.

A Tabela 3 apresenta as análises descritivas dos dados do produto 6 tanto por ano, quando por mês e pode-se destacar o ano de 2020 com o ano de maior média e dentre todos os meses o que apresenta a maior média são os meses de agosto e outubro com um valor de 3054 kg e 3017Kg respectivamente.

Tabela 3 – Estatística descritivas do Produto 6 (média e desvio-padrão para cada ano e cada mês).

Variável	Ano	N	Média	Desvio Padrão	Mínimo	Mediana	Máximo
Produto 6	2017	12	2277	990	105	2265	4001
	2018	12	1484	1158	1	1245	3667
	2019	12	1765	996	1	1739	2983
	2020	12	2663	1943	1	1974	5916
	2021	12	1503	1894	1	561	4930

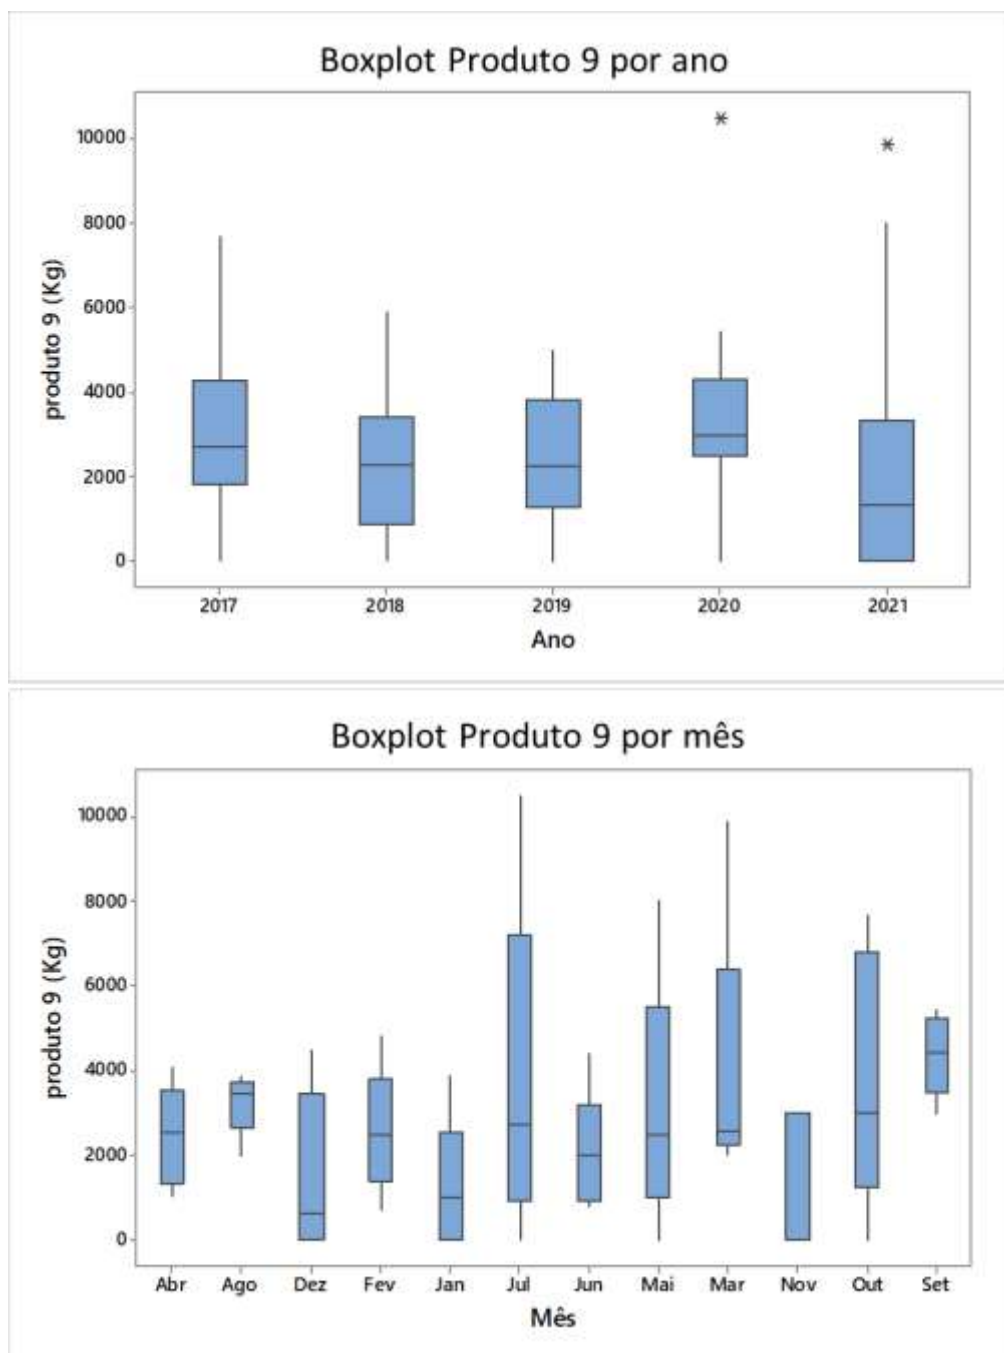
Variável	Mês	N	Média	Desvio Padrão	Mínimo	Mediana	Máximo
Produto 6	Abr	5	1761	1909	1	988	4674
	Ago	5	3054	1527	1463	2893	5567
	Dez	5	1282	1318	1	1026	2983
	Fev	5	1872	812	629	2250	2584
	Jan	5	689	920		266	2153
	Jul	5	2370	1349	1	2983	3228
	Jun	5	2789	1526	988	2802	4930
	Mai	5	2085	1586	1	1976	4471
	Mar	5	1479	1262	105	1007	3451
	Nov	5	906	903	1	950	1972
	Out	5	3017	2302		3667	5916
	Set	5	1957	812	986	1972	2983

Fonte: Elaborado pelo autor.

#### 4.4.2 Análise descritiva do Produto 9

O *boxplot* dos dados do produto 9 para identificar variabilidade nos dados e de acordo com a Figura 15 pode-se observar que não existe diferença entre os anos, porém o ano de 2021 apresenta uma maior variabilidade, já na análise por mês pode-se observar uma grande variabilidade entre os meses, apresentando destaque para os meses de março, maio, julho e outubro que possui grande variabilidade.

Figura 15 – Análise da dispersão e valores dos conjuntos de dados (*Boxplot* Produto 9).



Fonte: Elaborado pelo autor.

A Tabela 4 apresenta as análises descritivas dos dados do produto 9 tanto por ano, quando por mês e pode-se destacar o ano de 2020 com o ano de maior média e dentre todos os meses o que apresenta a maior média é o mês de setembro com um valor de 4348 kg. Os meses de julho e outubro apresentam grande variabilidade.

Tabela 4 – Estatística descritivas do Produto 9 (média e desvio-padrão para cada ano e cada mês).

Variável	Ano	N	Média	Desvio Padrão	Mínimo	Mediana	Máximo
Produto 9	2017	12	3026	1997	1	2700	7676
	2018	12	2256	1716	1	2278	5871
	2019	12	2435	1606	1	2252	4978
	2020	12	3543	2624	1	2958	10468
	2021	12	2542	3271	1	1326	9860

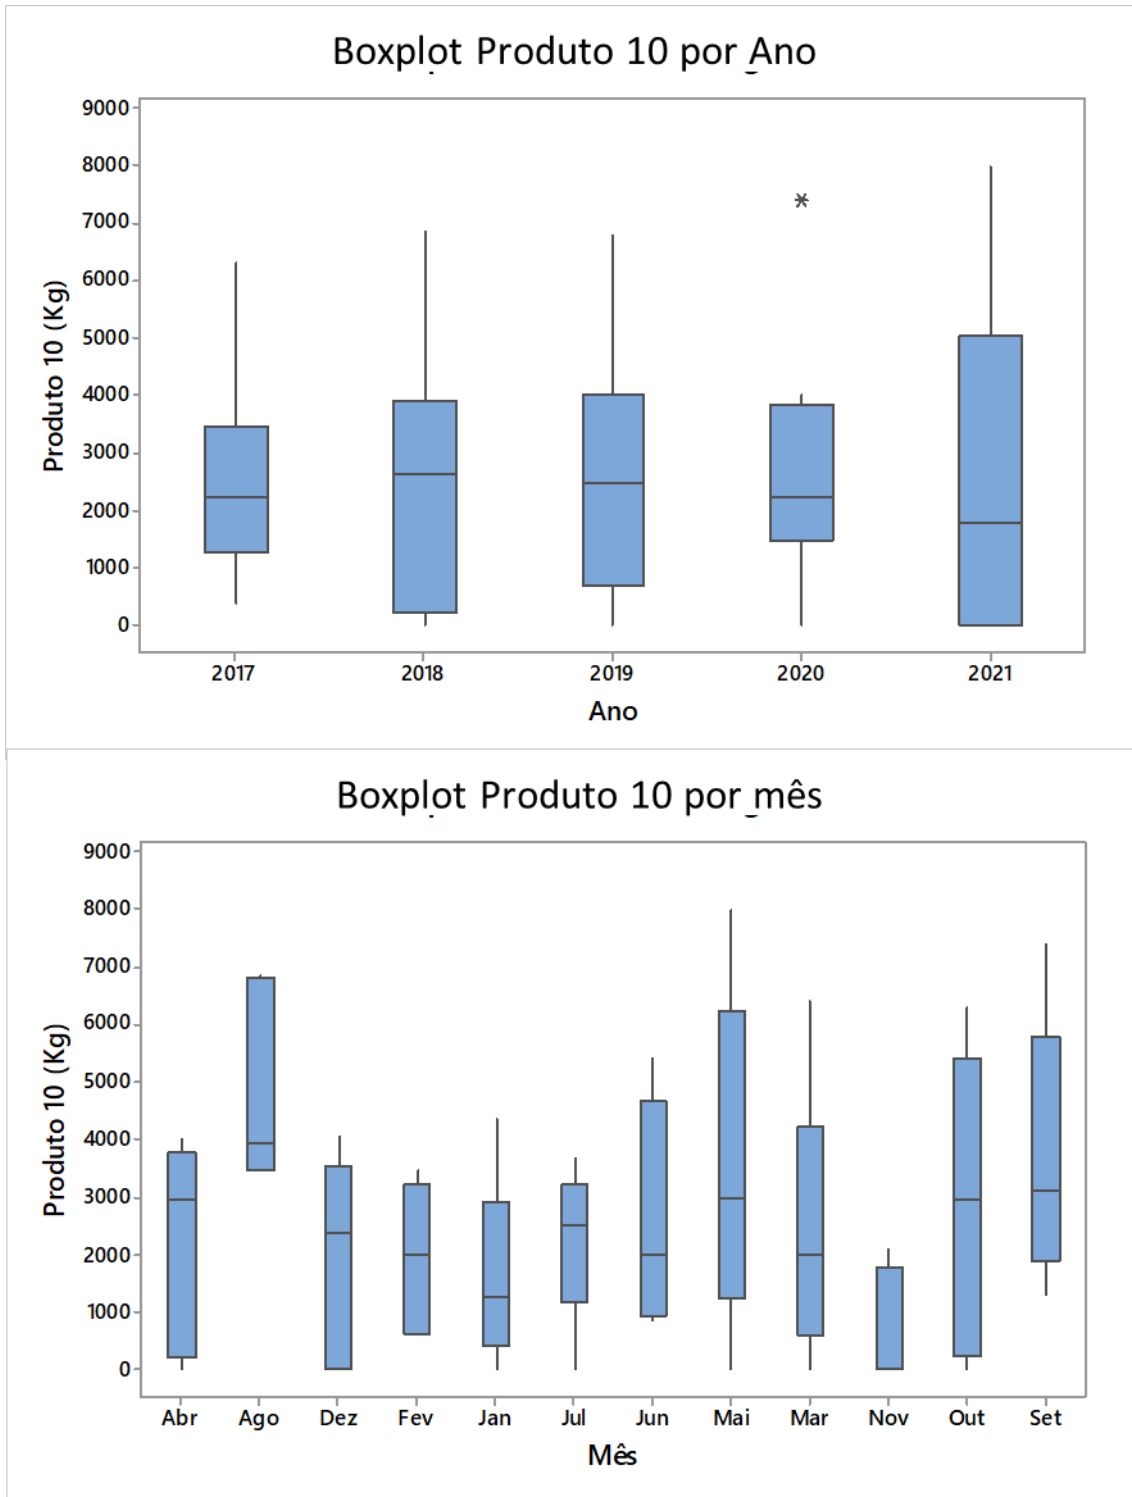
Variável	Mês	N	Média	Desvio Padrão	Mínimo	Mediana	Máximo
Produto 9	Abr	5	2441	1174	1026	2539	4047
	Ago	5	3228	726	1985	3451	3852
	Dez	5	1506	1931	1	629	4465
	Fev	5	2563	1491	680	2489	4800
	Jan	5	1202	1581	1	988	3860
	Jul	5	3787	4006	1	2717	10468
	Jun	5	2024	1431	778	1972	4389
	Mai	5	3088	2966	1	2470	7990
	Ma	5	3957	3314	2014	2580	9860
	Nov	5	1185	1621	1	1	2964
	Ouc	5	3795	3009	1	2958	7676
	Set	5	4348	953	2958	4408	5423

Fonte: Elaborado pelo autor.

#### 4.4.3 Análise descritiva do Produto 10

O *boxplot* dos dados do produto 10 identifica a variabilidade nos dados e de acordo com a Figura 16 pode-se observar que não existe diferença entre os anos e novamente o ano de 2021 apresenta uma maior variabilidade, já na análise por mês pode-se observar uma grande variabilidade entre os meses, apresentando destaque para o mês de agosto que possui o maior número de demanda e o mês de novembro os menores números de demanda.

Figura 16 – Análise da dispersão e valores dos conjuntos de dados (*Boxplot* Produto 10).



Fonte: Elaborado pelo autor.

A Tabela 5 apresenta as análises descritivas dos dados do produto 10 tanto por ano, quando por mês e pode-se dizer que as médias dentre todos os anos são praticamente iguais,

tendo uma diferença média de 164 kg a cada ano, agora para os meses pode-se observar o mês de agosto muito superior que os outros com um total médio de 4901 kg.

Tabela 5 – Estatística descritivas do Produto 10 (média e desvio-padrão para cada ano e cada mês).

Variável	Ano	N	Média	Desvio Padrão	Mínimo	Mediana	Máximo
Produto 10	2017	12	2593	1652	391	2233	6327
	2018	12	2391	2134	1	2651	6878
	2019	12	2516	2016	1	2480	6778
	2020	12	2694	1975	1	2233	7395
	2021	12	2543	2881	1	1801	7990

Variável	Mês	N	Média	Desvio Padrão	Mínimo	Mediana	Máximo
Produto 10	Abr	5	2182	1849	19	2958	4028
	Ago	5	4901	1771	3452	3944	6878
	Dez	5	1885	1824	1	2375	4066
	Fev	5	1940	1310	608	1995	3450
	Jan	5	1598	1651	1	1280	4370
	Jul	5	2266	1368	1	2489	3684
	Jun	5	2628	1975	855	2000	5423
	Zai	5	3588	2945	1	2983	7990
	Mar	5	2310	2433	1	1976	6409
	Nov	5	714	1000	1	1	2090
	Out	5	2850	2666	1	2945	6327
	Set	5	3706	2317	1307	3138	7395

Fonte: Elaborado pelo autor.

#### 4.4.4 Análise descritiva do Produto 3

Como os dados desse produto são de contagem de unidades e possui alguns *outliers* que podem influenciar na análise, segundo Goovaerts (1997) nesse caso é essencial transformar os dados para logaritmo, então a primeira coisa foi transformar os dados, a Tabela 6 abaixo apresenta essa transformação.

Tabela 6 – Transformação dos dados em logaritmo

Ano	Mês	Produto 3 (20L)		Produto 3 (5L)		Produto 3 (1L)	
		Dado	Log	Dado	Log	Dado	Log
2017	Jan	551	6,31173	8	2,07944	1	0
2017	Fev	132	4,8828	13	2,56495	12	2,48491
2017	Mar	197	5,2832	29	3,3673	62	4,12713
2017	Abr	9	2,19722	144	4,96981	48	3,8712
2017	Mai	1630	7,39634	49	3,89182	204	5,31812
2017	Jun	10	2,30259	100	4,60517	24	3,17805



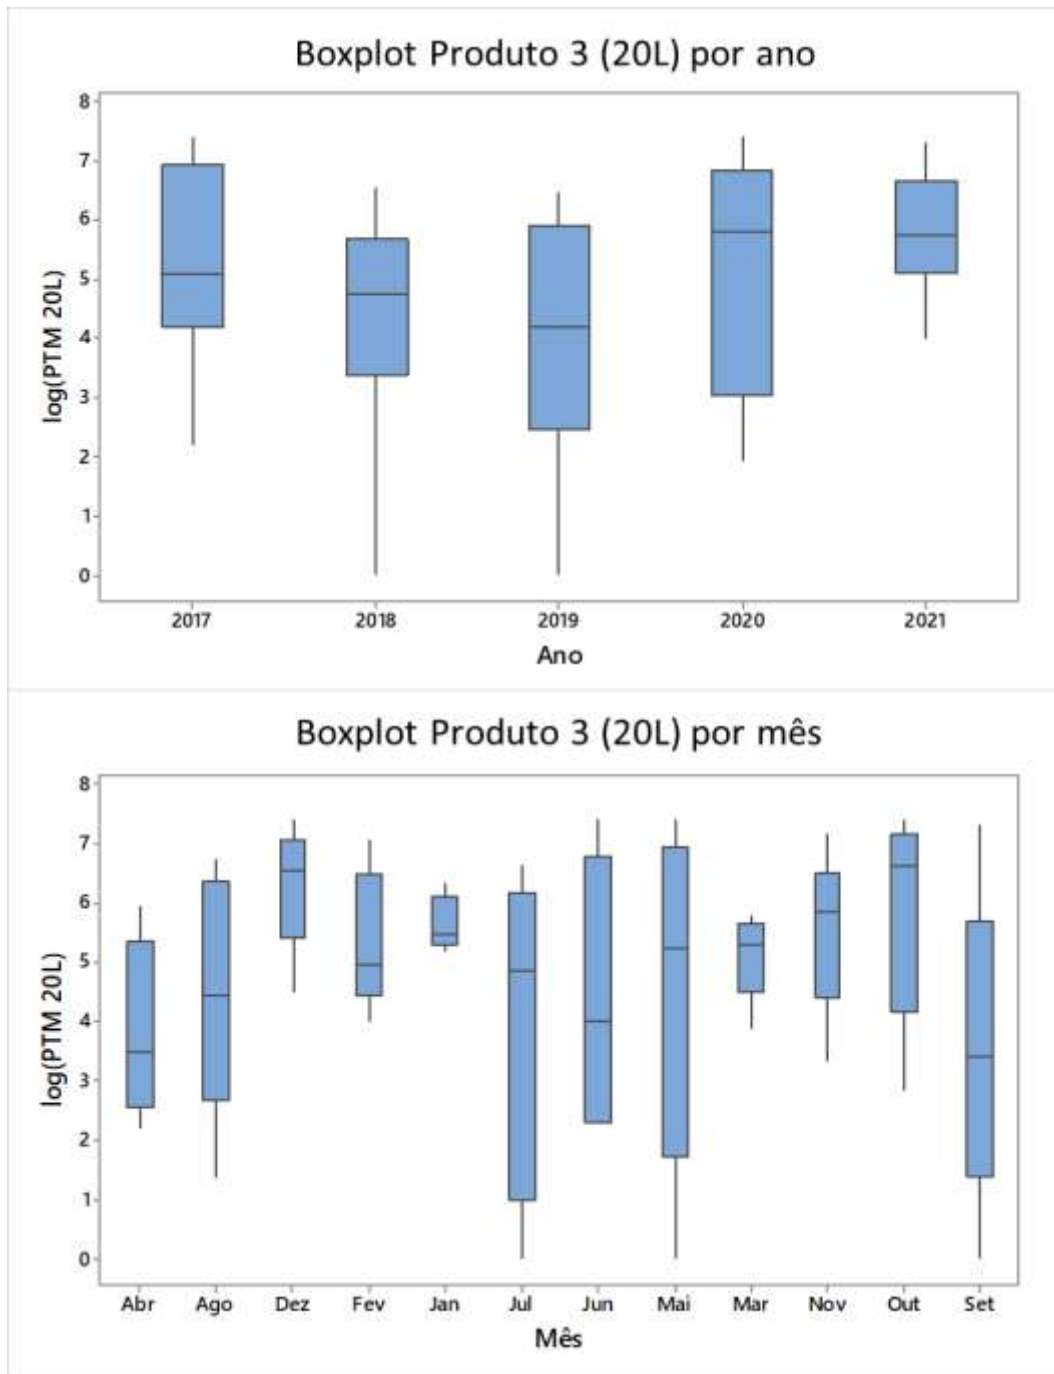
2017	Jul	128	4,85203	1	0	1	0
2017	Ago	84	4,43082	116	4,75359	96	4,56435
2017	Set	60	4,09434	21	3,04452	124	4,82028
2017	Out	1630	7,39634	4	1,38629	25	3,21888
2017	Nov	1262	7,14045	248	5,51343	326	5,7869
2017	Dez	556	6,32077	48	3,8712	120	4,78749
2018	Jan	240	5,48064	1	0	180	5,19296
2018	Fev	55	4,00733	140	4,94164	1	0
2018	Mar	257	5,54908	8	2,07944	60	4,09434
2018	Abr	33	3,49651	280	5,63479	96	4,56435
2018	Mai	1	0	1	0	1	0
2018	Jun	480	6,17379	224	5,41165	192	5,2575
2018	Jul	302	5,71043	20	2,99573	1	0
2018	Ago	53	3,97029	108	4,68213	228	5,42935
2018	Set	1	0	1	0	1	0
2018	Out	242	5,48894	460	6,13123	144	4,96981
2018	Nov	28	3,3322	282	5,64191	293	5,68017
2018	Dez	679	6,52062	12	2,48491	348	5,8522
2019	Jan	220	5,39363	12	2,48491	36	3,58352
2019	Fev	373	5,92158	20	2,99573	1	0
2019	Mar	48	3,8712	257	5,54908	276	5,6204
2019	Abr	376	5,92959	40	3,68888	1	0
2019	Mai	625	6,43775	220	5,39363	1	0
2019	Jun	10	2,30259	12	2,48491	1	0
2019	Jul	1	0	80	4,38203	1	0
2019	Ago	4	1,38629	35	3,55535	116	4,75359
2019	Set	30	3,4012	160	5,07517	240	5,48064
2019	Out	17	2,83321	16	2,77259	24	3,17805
2019	Nov	337	5,82008	100	4,60517	1	0
2019	Dez	90	4,49981	120	4,78749	48	3,8712
2020	Jan	370	5,9135	13	2,56495	1	0
2020	Fev	143	4,96284	252	5,52943	120	4,78749
2020	Mar	317	5,7589	46	3,82864	1	0
2020	Abr	18	2,89037	126	4,83628	1	0
2020	Mai	32	3,46574	160	5,07517	480	6,17379
2020	Jun	1590	7,37149	3	1,09861	255	5,54126
2020	Jul	7	1,94591	361	5,88888	1	0
2020	Ago	816	6,70441	83	4,41884	29	3,3673
2020	Set	16	2,77259	41	3,71357	1	0
2020	Out	974	6,88141	74	4,30407	144	4,96981
2020	Nov	350	5,85793	514	6,24222	1	0
2020	Dez	1638	7,40123	246	5,50533	168	5,12396
2021	Jan	181	5,1985	26	3,2581	125	4,82831
2021	Fev	1149	7,04665	3	1,09861	145	4,97673
2021	Mar	162	5,0876	25	3,21888	363	5,8944
2021	Abr	118	4,77068	8	2,07944	1	0
2021	Mai	187	5,23111	216	5,37528	468	6,14847
2021	Jun	55	4,00733	432	6,06843	29	3,3673

2021	Jul	758	6,63068	46	3,82864	770	6,64639
2021	Ago	398	5,98645	68	4,21951	24	3,17805
2021	Set	1454	7,28207	68	4,21951	1	0
2021	Out	742	6,60935	1	0	1	0
2021	Nov	237	5,46806	4	1,38629	1	0
2021	Dez	793	6,67582	1	0	1	0

Fonte: Elaborado pelo autor.

Após a transformação de dados foi realizado o *boxplot* para cada uma das apresentações produto 10, na Figura 17 tem-se os *boxplots* do produto 3 (20L) por mês e por ano e observa-se não existe diferença entre os anos e os anos de 2019 e 2020 apresentam uma maior variabilidade, já na análise por mês pode-se observar uma grande variabilidade entre os meses, dando destaque para os meses de maio, julho e setembro que possuem uma grande variabilidade dentro do mês.

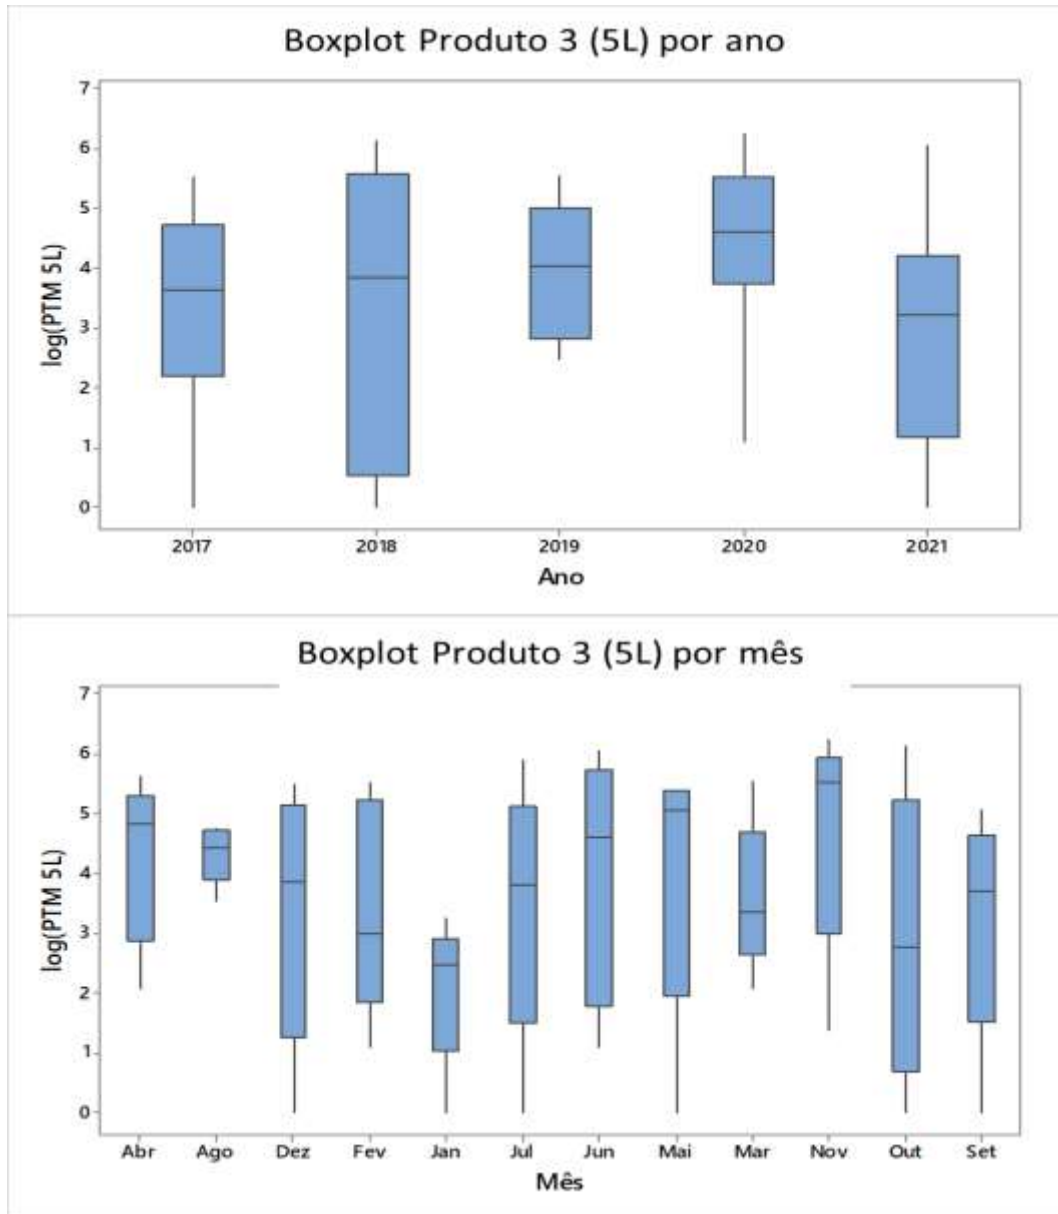
Figura 17 – Análise da dispersão e valores dos conjuntos de dados (*Boxplot* Produto 3 (20L)).



Fonte: Elaborado pelo autor.

A Figura 18 apresenta os *boxplots* do produto 3 (5L) por mês e por ano e observa-se não existe diferença entre os anos e os anos de 2018 e 2021 apresentam uma maior variabilidade, já na análise por mês pode-se observar que o mês de agosto possui pequena variabilidade, ou seja, demanda mais homogênea nesse mês.

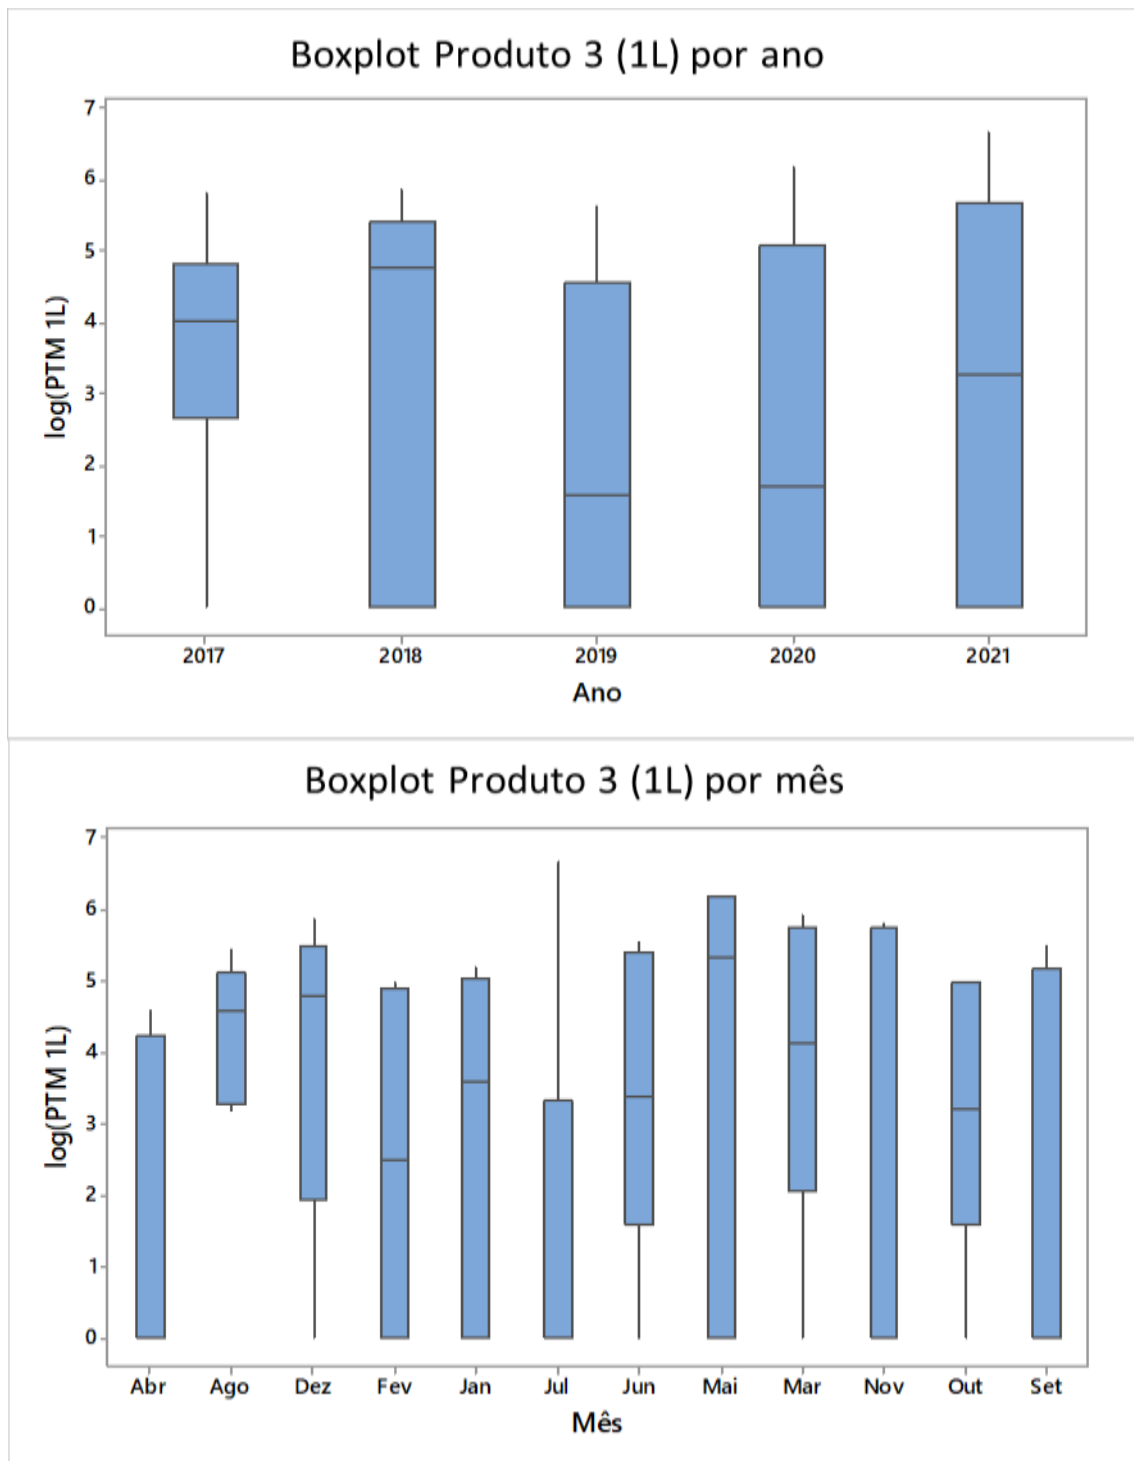
Figura 18 – Análise da dispersão e valores dos conjuntos de dados (*Boxplot* Produto 3 (5L)).



Fonte: Elaborado pelo autor.

A Figura 19 apresenta os *boxplots* do produto 3 (1L) por mês e por ano e observa-se não existe diferença entre os anos e o ano de 2017 apresenta maior homogeneidade na demanda, já na análise por mês pode-se observar que o mês de agosto possui pequena variabilidade, ou seja, demanda mais homogênea nesse mês.

Figura 19 – Análise da dispersão e valores dos conjuntos de dados (*Boxplot* Produto 3 (3L)).



Fonte: Elaborado pelo autor.

A Tabela 7 apresenta os resultados das análises descritivas dos dados do produto 10 para cada apresentação sendo por ano e por mês, apresentando os seguintes resultados:

- Para a apresentação de 20L, nas análises ano a ano tem-se destaque para o ano de 2021 que possui uma média muito superior aos demais, e no mês a mês observa-se o mês de dezembro como o de maior média.
- Para a apresentação de 5L analisando ano a ano, observa-se o ano de 2020 como o ano de maior relevância quando se analisa a média anual de demanda comparado com os demais anos, voltando as análises agora para mês a mês pode-se observar que o mês que possui a maior média é o mês de novembro e na sequência os meses de abril e agosto, os demais meses possuem valores mais baixos.
- Para apresentação 1L analisando por ano os meses que apresentam as maiores médias são 2017 e 2018, possuindo uma diferença pequena entre eles, agora quando se observa mês a mês o destaque vai para o mês de agosto com a média de demanda muito superior à dos demais meses.

Tabela 7 – Estatística descritivas do Produto 3 para todas as apresentações (média e desvio-padrão para cada ano e cada mês).

Variável	Ano	N	Média	Desvio Padrão	Mínimo	Mediana	Máximo
Log (Produto 3 (20L))	2017	12	5,217	1,793	2,197	5,083	7,396
	2018	12	4,144	2,201	0	4,744	6,521
	2019	12	3,983	2,052	0	4,186	6,438
	2020	12	5,161	1,925	1,946	5,808	7,401
	2021	12	5,833	1,021	4,007	5,727	7,282

Variável	Mês	N	Média	Desvio Padrão	Mínimo	Mediana	Máximo
Log (Produto 3 (20L))	Abr	5	3,857	1,496	2,197	3,497	5,930
	Ago	5	4,496	2,065	1,386	4,431	6,704
	Dez	5	6,284	1,077	4,500	6,521	7,401
	Fev	5	5,364	1,159	4,007	4,963	7,047
	Jan	5	5,660	0,449	5,198	5,481	6,312
	Jul	5	3,830	2,770	0,000	4,850	6,630
	Jun	5	4,430	2,290	2,300	4,010	7,370
	Mai	5	4,510	2,920	0,000	5,230	7,400
	Ma	5	5,110	0,738	3,871	5,283	5,759
	Nov	5	5,524	1,380	3,332	5,820	7,140
	Ouc	5	5,842	1,821	2,833	6,609	7,396
	Set	5	3,510	2,620	0,000	3,400	7,280

Variável	Ano	N	Média	Desvio Padrão	Mínimo	Mediana	Máximo
Log (Produto 3 (5L))	2017	12	3,337	1,619	0,000	3,619	5,513
	2018	12	3,334	2,392	0,000	3,839	6,131
	2019	12	3,981	1,129	2,485	4,035	5,549
	2020	12	4,417	1,472	1,099	4,628	6,242
	2021	12	2,896	1,995	0,000	3,238	6,068

Variável	Mês	N	Média	Desvio Padrão	Mínimo	Mediana	Máximo
Log (Produto 3 (5L))	Abr	5	4,242	1,397	2,079	4,836	5,639
	Ago	5	4,326	0,481	3,555	4,419	4,754
	Dez	5	3,330	2,177	0,000	3,871	5,505
	Fev	5	3,426	1,807	1,099	2,996	5,529
	Jan	5	2,077	1,236	0,000	2,485	3,258
	Jul	5	3,419	2,183	0,000	3,829	5,889
	Jun	5	3,934	2,081	1,099	4,605	6,068
	Mai	5	3,950	2,290	0,000	5,080	5,390
	Ma	5	3,609	1,261	2,079	3,367	5,549
	Nov	5	4,678	1,931	1,386	5,513	6,242
	Ouc	5	2,920	2,400	0,000	2,770	6,130
Set	5	3,211	1,942	0,000	3,714	5,075	

Variável	Ano	N	Média	Desvio Padrão	Mínimo	Mediana	Máximo
Log (Produto 3 (1L))	2017	12	3,513	1,890	0,000	3,999	5,787
	2018	12	3,420	2,565	0,000	4,767	5,852
	2019	12	2,207	2,406	0,000	1,589	5,620
	2020	12	2,497	2,684	0,000	1,684	6,174
	2021	12	2,920	2,762	0,000	3,273	6,646

Variável	Mês	N	Média	Desvio Padrão	Mínimo	Mediana	Máximo
Log (Produto 3 (1L))	Abr	5	1,690	2,320	0,000	0,000	4,560
	Ago	5	4,259	0,958	3,178	4,564	5,429
	Dez	5	3,930	2,310	0,000	4,790	5,850
	Fev	5	2,450	2,440	0,000	2,480	4,980
	Jan	5	2,720	2,550	0,000	3,580	5,190
	Jul	5	1,330	2,970	0,000	0,000	6,650
	Jun	5	3,469	2,215	0,000	3,367	5,541
	Mai	5	3,530	3,240	0,000	5,320	6,170
	Ma	5	3,950	2,360	0,000	4,130	5,890
	Nov	5	2,290	3,140	0,000	0,000	5,790
	Ouc	5	3,267	2,030	0,000	3,219	4,970
Set	5	2,060	2,830	0,000	0,000	5,480	

Fonte: Elaborado pelo autor.

#### 4.5 Análise estatística dos dados


A análise estatística dos dados foi considerada usando duas classes de modelos estatísticos para series temporais: modelos estatísticos de médias móveis e modelos ARIMA. A seguir apresentam-se os resultados da análise estatística para os dados dos produtos 9, 10, PTM 20L, PTM 5L e PTM 1L usando os modelos de médias móveis e ARIMA.

##### 4.5.1 Produto 6

Na Figura 20 tem-se o modelo ajustado de médias móveis (médias mensais dos últimos 3 meses). Na Figura 21 apresentam-se os gráficos de resíduos do modelo ajustado indicando que as suposições necessárias para o uso do modelo (normalidade e variância constante dos resíduos) são verificadas (uso do *software* Minitab®).

No Tabela 8, seguem os resultados (estimativas dos parâmetros) do modelo ARIMA (2,1,3) ajustado (uso do *software* Minitab®). Na Figura 22 estão os gráficos de resíduos do modelo ajustado indicando que as suposições necessárias para o uso do modelo (normalidade e variância constante dos resíduos) são verificadas (uso do *software* Minitab®). Na Tabela 9, apresentam-se os resultados de previsão obtidos pelo modelo ARIMA (2,1,3) ajustado para cada mês. Na Figura 23 está o gráfico do modelo ARIMA (2,1,3) ajustado. A Figura 24 mostra o gráfico das autocorrelações parciais indicando o bom ajuste do modelo ARIMA (2,1,3).

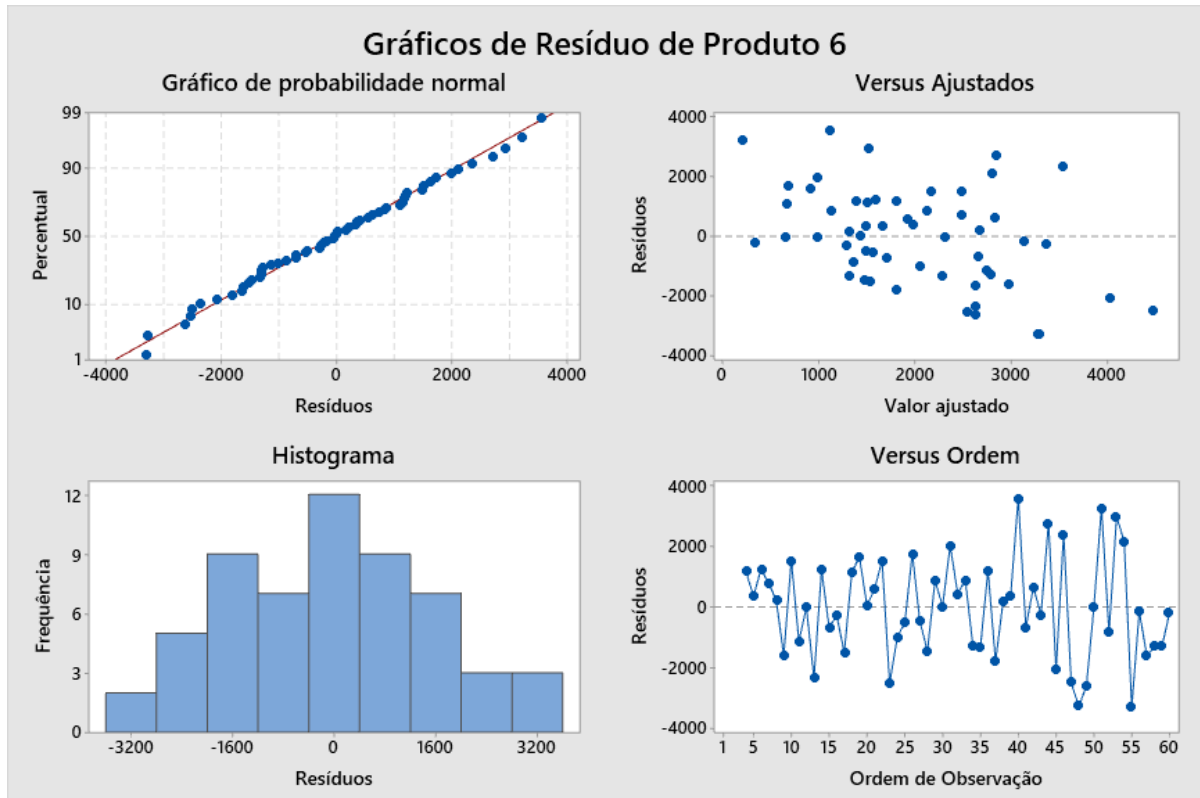
Figura 20 - Modelo de médias móveis ajustado (produto 6).



Fonte: Elaborado pelo autor.



Figura 21 - Gráficos de resíduos do modelo de médias móveis ajustado (produto 6)



Fonte: Elaborado pelo autor.

Tabela 8 – Estimativas dos parâmetros do modelo ARIMA (2,1,3) ajustado (produto 6)

<i>Type</i>	<i>Coef</i>	<i>SE Coef</i>	<i>T</i>	<i>P</i>
AR 1	-0,265	0,599	-0,44	0,66
AR 2	0,221	0,666	0,33	0,742
MA 1	0,621	0,615	1,01	0,317
MA 2	0,346	0,723	0,48	0,634
MA 3	0,004	0,649	0,01	0,995
Constant	-5,3	12,4	-0,43	0,669

*Differencing: 1 regular difference*

*Number of observations: Original series 60, after differencing 59*

*Residuals: SS = 127698221 (backforecasts excluded)*

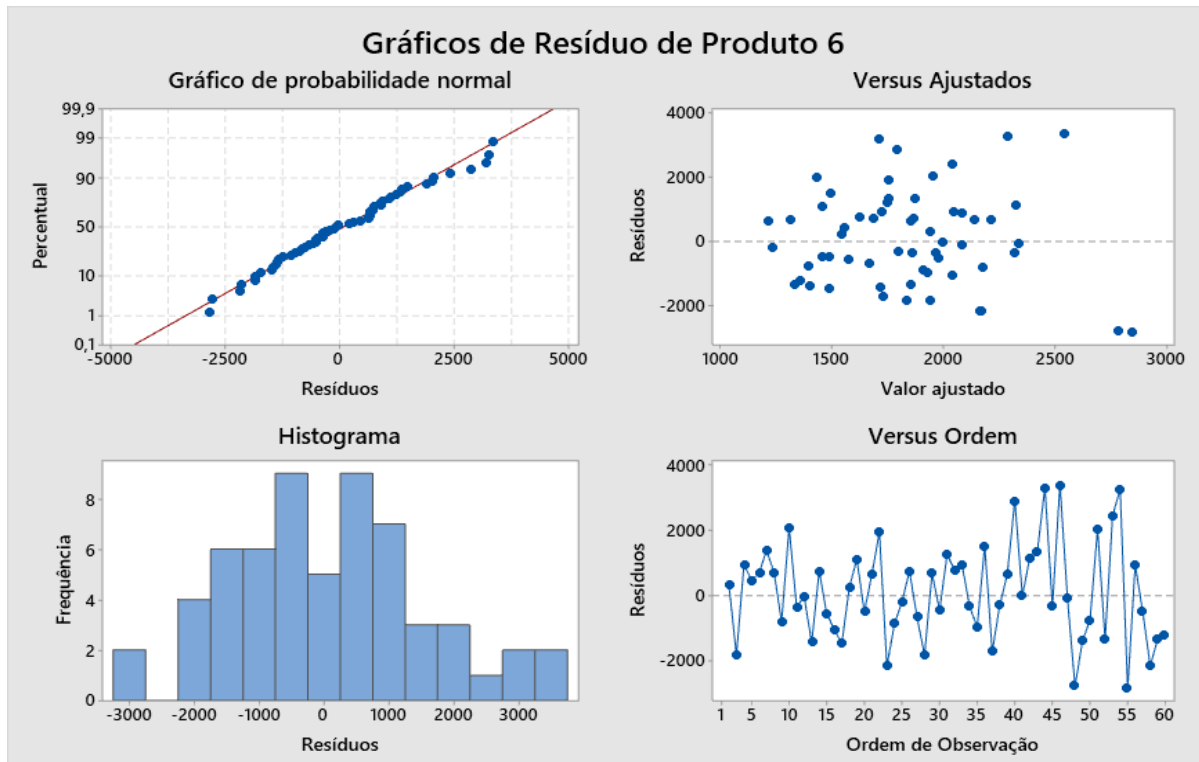
**MS = 2409400                      DF = 53**

*Modified Box-Pierce (Ljung-Box) Chi-Square statistic*

<i>Lag</i>	12	24	36	48
<i>Chi-Square</i>	15,73	34,4	53,77	62,04
<i>DF</i>	6	18	30	42
<i>P-Value</i>	0,015	0,011	0,005	0,024

Fonte: Elaborado pelo autor.

Figura 22 - Gráficos de resíduos do modelo ARIMA(2,1,3) (produto 6)



Fonte: Elaborado pelo autor


Tabela 9 - Resultados de previsão (FITS) obtidos pelo modelo ARIMA (2,1,3) ajustado

Row	Obs.	FITS	Meses
1	2153	*	1
2	2250	1939,963	2
3	105	1942,438	3
4	2650	1722,002	4
5	2000	1554,9785	5
6	2802	2138,75	6
7	3228	1871,208	7
8	2893	2213,104	8
9	1357	2176,349	9
10	4001	1952,803	10
11	1604	1964,985	11
12	2280	2336,397	12
13	266	1718,104	13
14	2584	1866,101	14
15	1007	1576,737	15
16	988	2042,44	16
17	1	1488,537	17
18	1767	1543,619	18
19	2546	1456,004	19
20	1463	1975,974	20

21	2489	1857,161	21
22	3667	1753,448	22
23	1	2171,373	23
24	1026	1910,25	24
25	1026	1231,933	25
26	2413	1689,412	26
27	988	1665,713	27
28	1	1837,694	28
29	1976	1314,598	29
30	988	1456,849	30
30	988	1456,849	30
31	2983	1750,167	31
32	2388	1624,982	32
33	2983	2082,331	33
34	1501	1860,56	34
35	950	1928,297	35
36	2983	1491,762	36
37	1	1731,274	37
38	1482	1797,057	38
39	1843	1214,14	39
40	4674	1794,385	40
41	1976	1994,015	41
42	3458	2322,977	42
43	3094	1754,337	43
44	5567	2287,873	44
45	1972	2322,092	45
46	5916	2542,79	46
47	1972	2085,545	47
48	1	2787,375	48
49	1	1403,227	49
50	629	1395,502	50
51	3451	1429,573	51
52	493	1852,171	52
53	4471	2042,13	53
54	4930	1712,545	54
55	1	2848,647	55
56	2958	2048,499	56
57	986	1488,432	57
58	1	2164,801	58
59	1	1335,101	59
60	119	1357,041	60

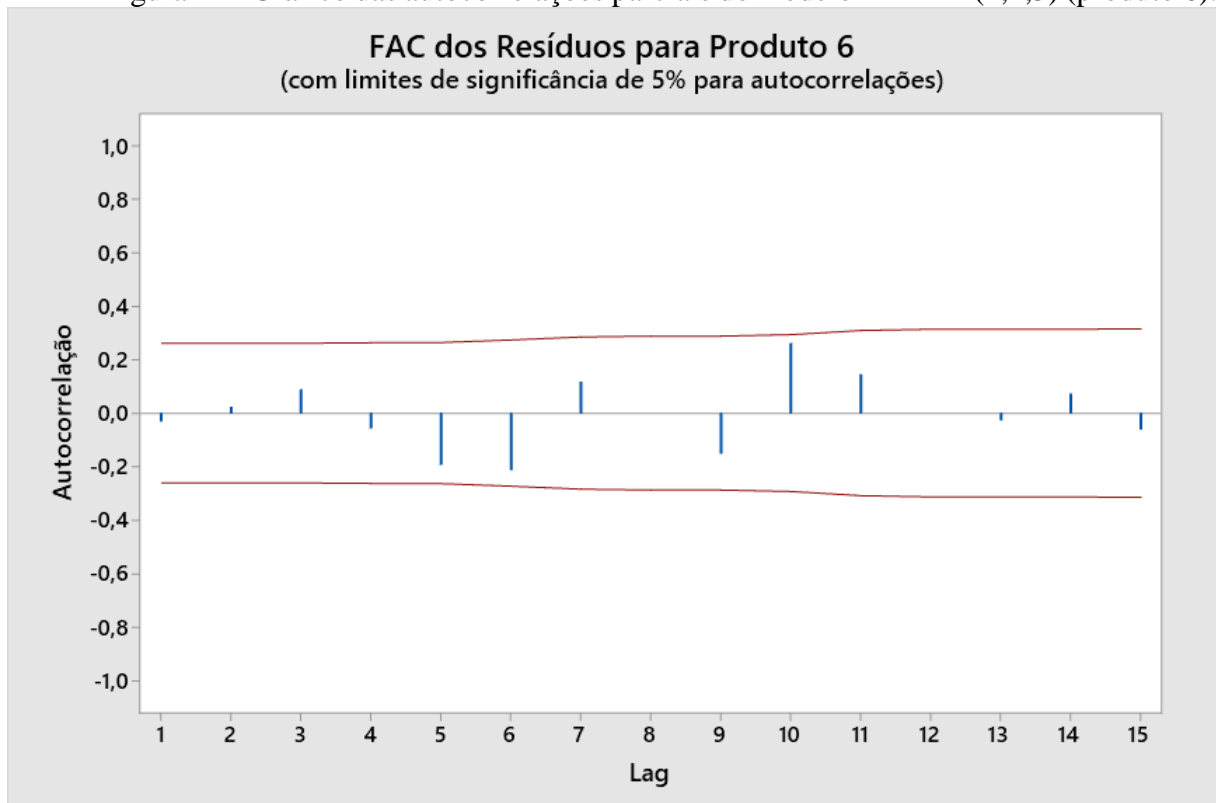
Fonte: Elaborado pelo autor.

Figura 23 - Gráfico dos valores preditos (FITS) do modelo ARIMA(2,1,3) ajustado.



Fonte: Elaborado pelo autor.

Figura 24 - Gráfico das autocorrelações parciais do modelo ARIMA (2,1,3) (produto 6).



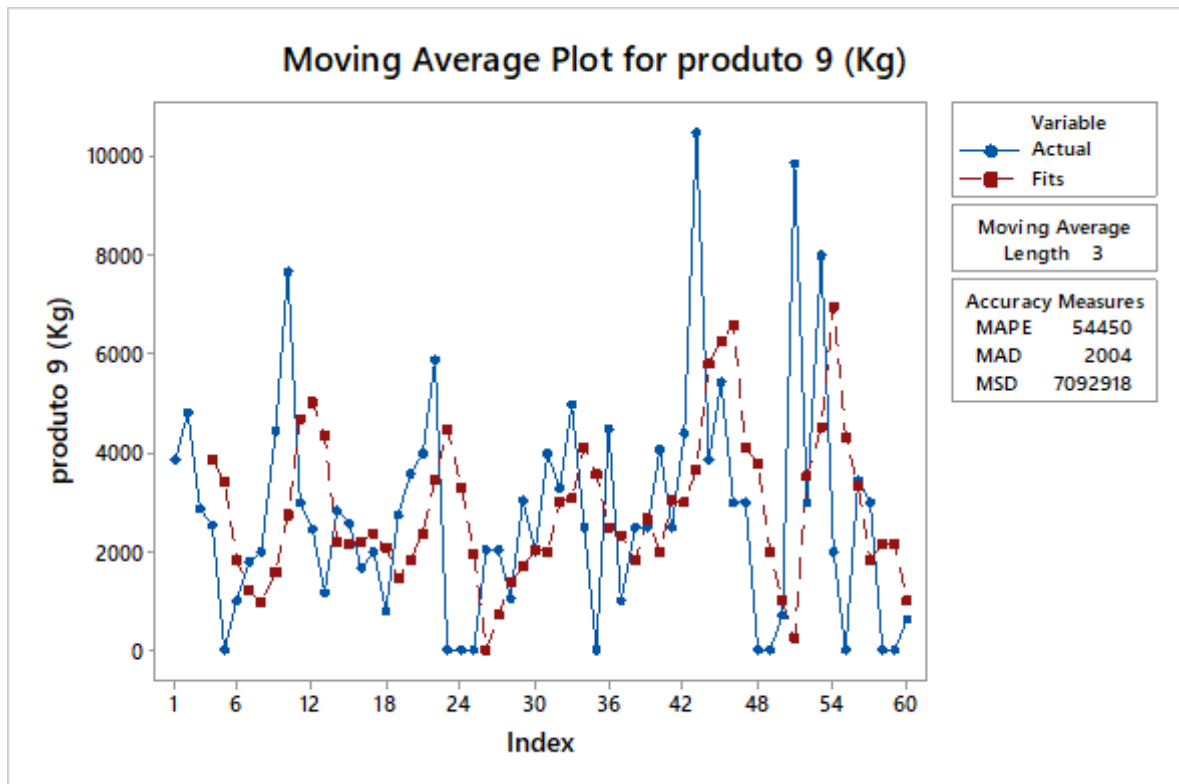
Fonte: Elaborado pelo autor.

#### 4.5.2 Produto 9

Na Figura 25 tem-se o modelo ajustado de médias móveis (médias mensais dos últimos 3 meses). Na Figura 26 apresentam-se os gráficos de resíduos do modelo ajustado indicando que as suposições necessárias para o uso do modelo (normalidade e variância constante dos resíduos) são verificadas (uso do *software* Minitab®).

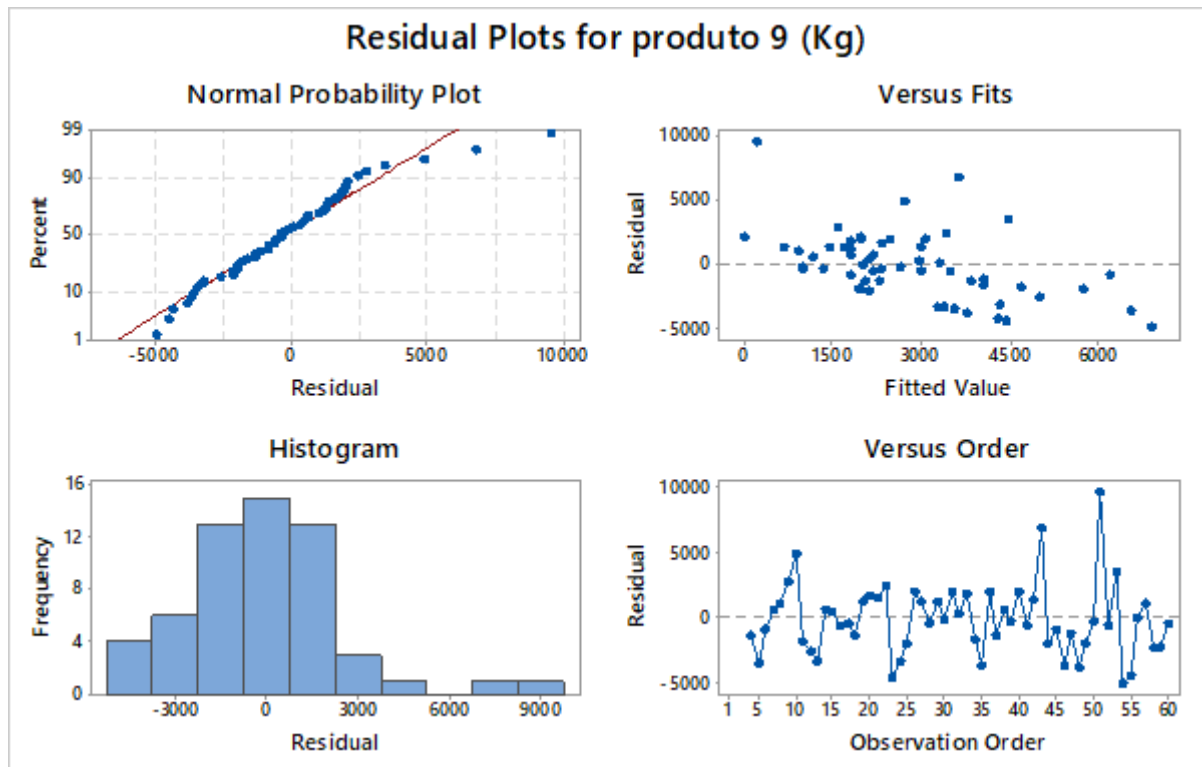
Na Tabela 10, estão os resultados (estimativas dos parâmetros) do modelo ARIMA (2,1,3) ajustado (uso do *software* Minitab®). Na Figura 27 seguem os gráficos de resíduos do modelo ajustado indicando que as suposições necessárias para o uso do modelo (normalidade e variância constante dos resíduos) são verificadas (uso do *software* Minitab®). Na Tabela 11, estão os resultados de previsão obtidos pelo modelo ARIMA (2,1,3) ajustado para cada mês. Na Figura 28 apresenta-se o gráfico do modelo ARIMA (2,1,3) ajustado. A Figura 29 mostra o gráfico das autocorrelações parciais indicando o bom ajuste do modelo ARIMA (2,1,3).

Figura 25 - Modelo de médias móveis ajustado (produto 9)



Fonte: Elaborado pelo autor.

Figura 26 - Gráficos de resíduos do modelo de médias móveis ajustado (produto 9)



Fonte: Elaborado pelo autor.

Tabela 10 – Estimativas dos parâmetros do modelo ARIMA (2,1,3) ajustado (produto 9)

Type	Coef	SE Coef	T	P
AR 1	-0,0923	0,4267	-0,22	0,83
AR 2	0,0714	0,4665	0,15	0,879
MA 1	0,6442	0,4166	1,55	0,128
MA 2	0,1776	0,6028	0,29	0,769
MA 3	0,2655	0,4039	0,66	0,514
Constant	-14,401	9,39	-1,53	0,131

**Differencing: 1 regular difference**

**Number of observations: Original series 60, after differencing 59**

**Residuals: SS = 277528539 (backforecasts excluded)**

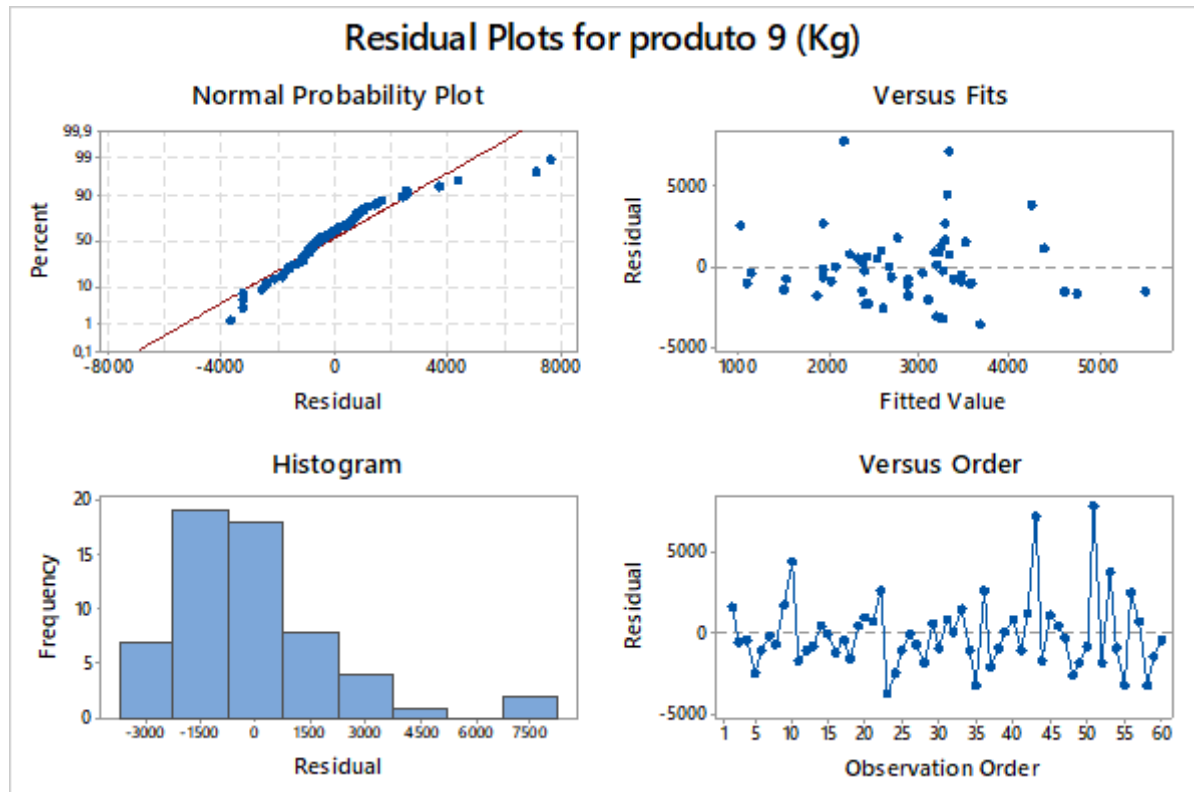
**MS = 5236388                      DF = 53**

**Modified Box-Pierce (Ljung-Box) Chi-Square statistic**

<b>Lag</b>	12	24	36	48
<b>Chi-Square</b>	7,4	15,5	23,2	41,3
<b>DF</b>	6	18	30	42
<b>P-Value</b>	0,282	0,625	0,807	0,503

Fonte: Elaborado pelo autor.

Figura 27 - Gráficos de resíduos do modelo ARIMA(2,1,3) (produto 9)



Fonte: Elaborado pelo autor.

Tabela 11 - Resultados de previsão (FITS) obtidos pelo modelo ARIMA (2,1,3) ajustado

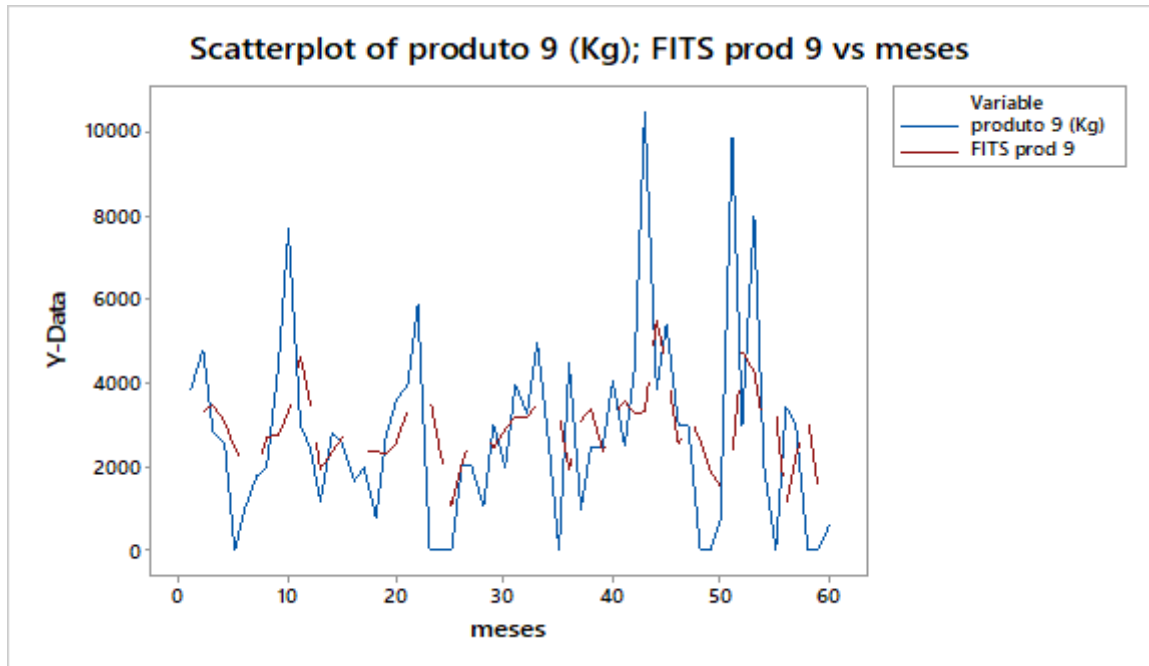
Row	Obs.	FITS	Meses
1	3860	*	1
2	4800	3292,27	2
3	2861	3424, 11	3
4	2539	3043, 12	4
5	1	2450,22	5
6	1003	2031, 04	6
7	1777	1946, 02	7
8	1985	2704, 55	8
9	4408	2773, 15	9
10	7676	3304, 32	10
11	2964	4617, 52	11
12	2432	3472, 75	12
13	1259	1933,72	13
14	2812	2346, 91	14
15	2580	2668,38	15
16	1634	2225, 07	16
17	1976	2328, 51	17
18	778	2373,83	18
19	2717	2331, 99	19
20	3572	3582,96	20

21	3971	3335,31	21
22	5871	3293,49	22
23	1	3673,88	23
24	1	2403,62	24
25	1	1083,13	25
26	2033	2085,36	26
27	2014	2694,79	27
28	1026	3293,49	28
29	3002	2431,61	29
30	1976	2277,42	30
31	3971	3169,45	31
32	3222	3121,53	32
33	4972	3512,35	33
34	2470	3524,26	34
35	1	3242,09	35
36	4465	1932,14	36
37	928	3102,12	37
38	2429	3325,23	38
39	2470	2362,55	39
40	4047	3219,67	40
41	2470	3572,2	41
42	4329	3250,35	42
43	10468	3327,56	43
44	3252	5520,31	44
45	5423	4326,82	45
46	2958	2524,32	46
47	2952	3262,75	47
48	1	2611,79	48
49	1	1220,34	49
50	620	1530,6	50
51	9260	2177,69	51
52	2952	4747,91	52
53	7990	4250,85	53
54	1972	2222	54
55	1	3273,52	55
56	3451	1016,96	56
57	2952	2233,72	57
58	1	3205,43	58
59	1	1513,22	59
60	629	1126,73	60

Fonte: Elaborado pelo autor.




Figura 28 - Gráfico dos valores preditos (FITS) do modelo ARIMA(2,1,3) ajustado.



Fonte: Elaborado pelo autor.

Figura 29 - Gráfico das autocorrelações parciais do modelo ARIMA (2,1,3) (produto 9).



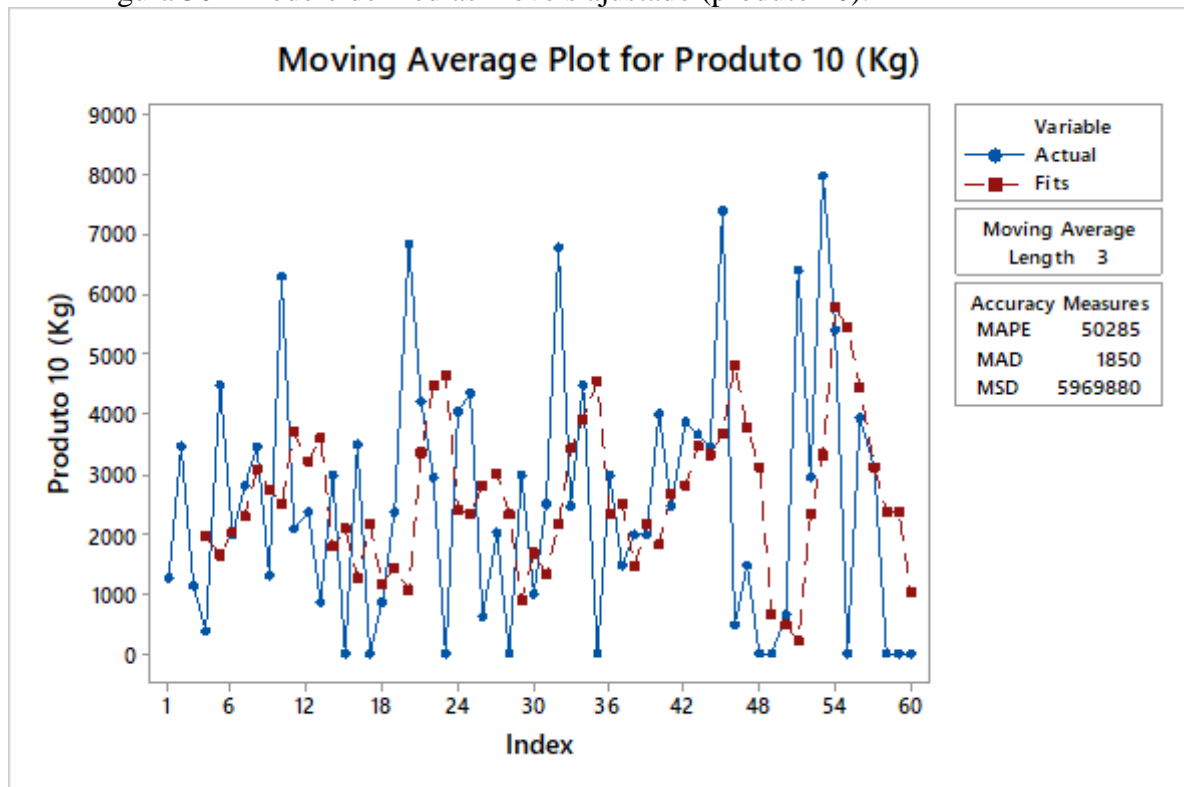
Fonte: Elaborado pelo autor.

### 4.5.3 Produto 10

Na Figura 30 está o modelo ajustado de médias móveis (médias mensais dos últimos 3 meses). Na Figura 31 apresentam-se os gráficos de resíduos do modelo ajustado indicando que as suposições necessárias para o uso do modelo (normalidade e variância constante dos resíduos) são verificadas (uso do *software* Minitab®).

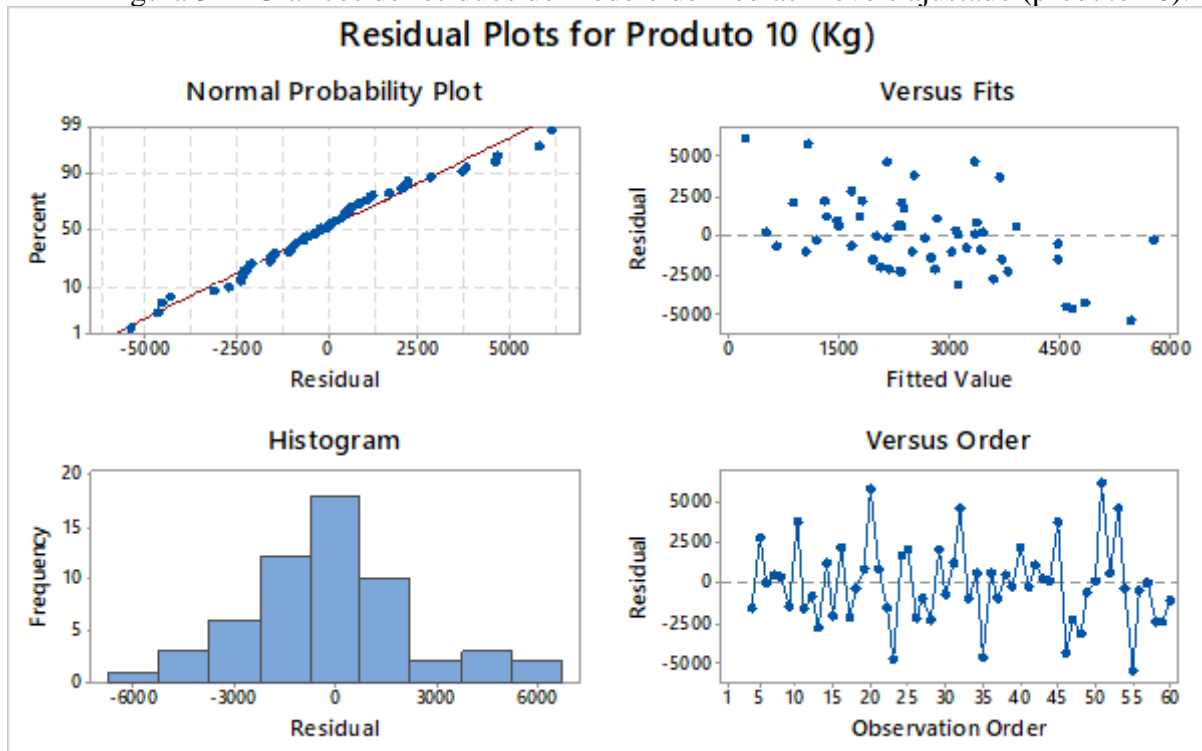
Na Tabela 12, seguem os resultados (estimativas dos parâmetros) do modelo ARIMA (2,1,3) ajustado (uso do *software* Minitab®). Na Figura 32 estão os gráficos de resíduos do modelo ajustado indicando que as suposições necessárias para o uso do modelo (normalidade e variância constante dos resíduos) são verificadas (uso do *software* Minitab®). Na Tabela 13, apresentam-se os resultados de previsão obtidos pelo modelo ARIMA (2,1,3) ajustado para cada mês. Na Figura 33 segue o gráfico do modelo ARIMA (2,1,3) ajustado. A Figura 34 mostra o gráfico das autocorrelações parciais indicando o bom ajuste do modelo ARIMA (2,1,3).

Figura 30 - Modelo de médias móveis ajustado (produto 10).



Fonte: Elaborado pelo autor.

Figura 31 - Gráficos de resíduos do modelo de médias móveis ajustado (produto 10).



Fonte: Elaborado pelo autor.

Tabela 12 - Estimativas dos parâmetros do modelo ARIMA (2,1,3) ajustado (produto 10)

<i>Type</i>	<i>Coef</i>	<i>SE Coef</i>	<i>T</i>	<i>P</i>
AR 1	-0,3168	0,2593	-1,22	0,227
AR 2	0,1039	0,5293	0,2	0,845
MA 1	0,5771	0,2042	2,83	0,007
MA 2	0,3547	0,6863	0,52	0,607
MA 3	0,1564	0,5069	0,31	0,759
Constant	-23	17,27	-1,33	0,188

*Differencing: 1 regular difference*

*Number of observations: Original series 60, after differencing 59*

*Residuals: SS = 246286296 (backforecasts excluded)*

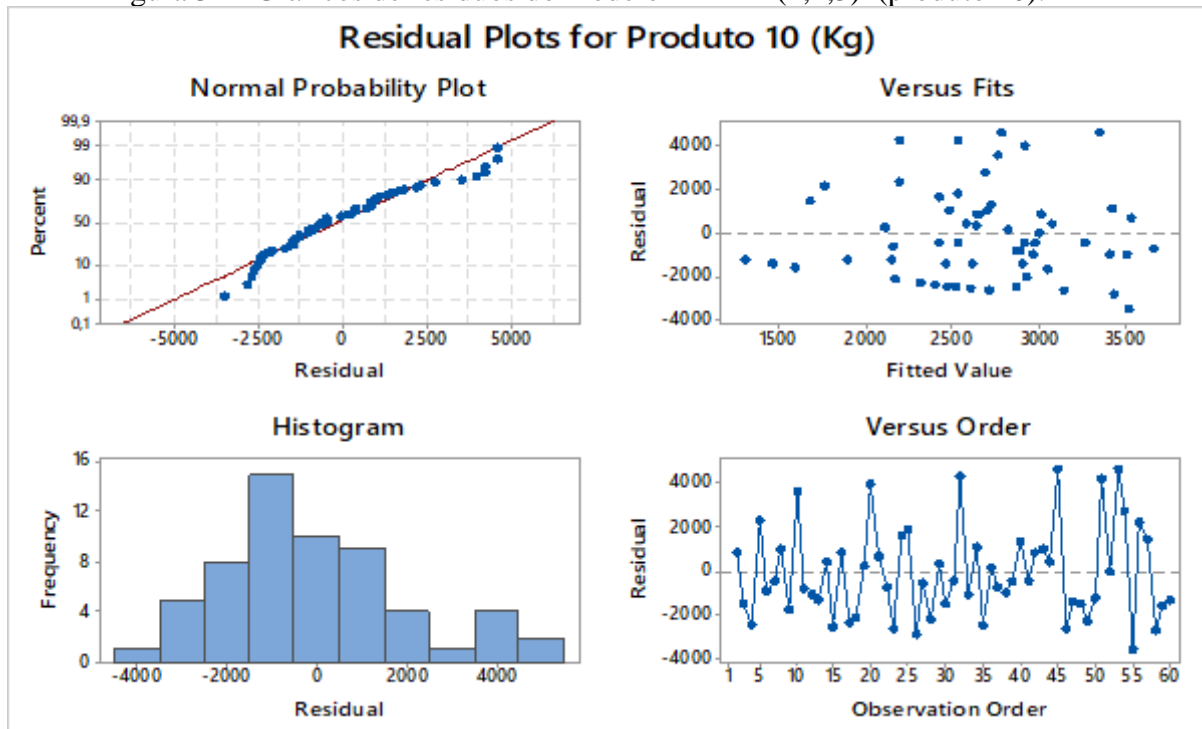
**MS = 4646911                      DF = 53**

*Modified Box-Pierce (Ljung-Box) Chi-Square statistic*

<i>Lag</i>	12	24	36	48
<i>Chi-Square</i>	16	26,3	40,4	60,9
<i>DF</i>	6	18	30	42
<i>P-Value</i>	0,013	0,092	0,097	0,03

Fonte: Elaborado pelo autor.

Figura 32 - Gráficos de resíduos do modelo ARIMA(2,1,3) (produto 10).



Fonte: Elaborado pelo autor.

Tabela 13 - Resultados de previsão (FITS) obtidos pelo modelo ARIMA (2,1,3) ajustado.

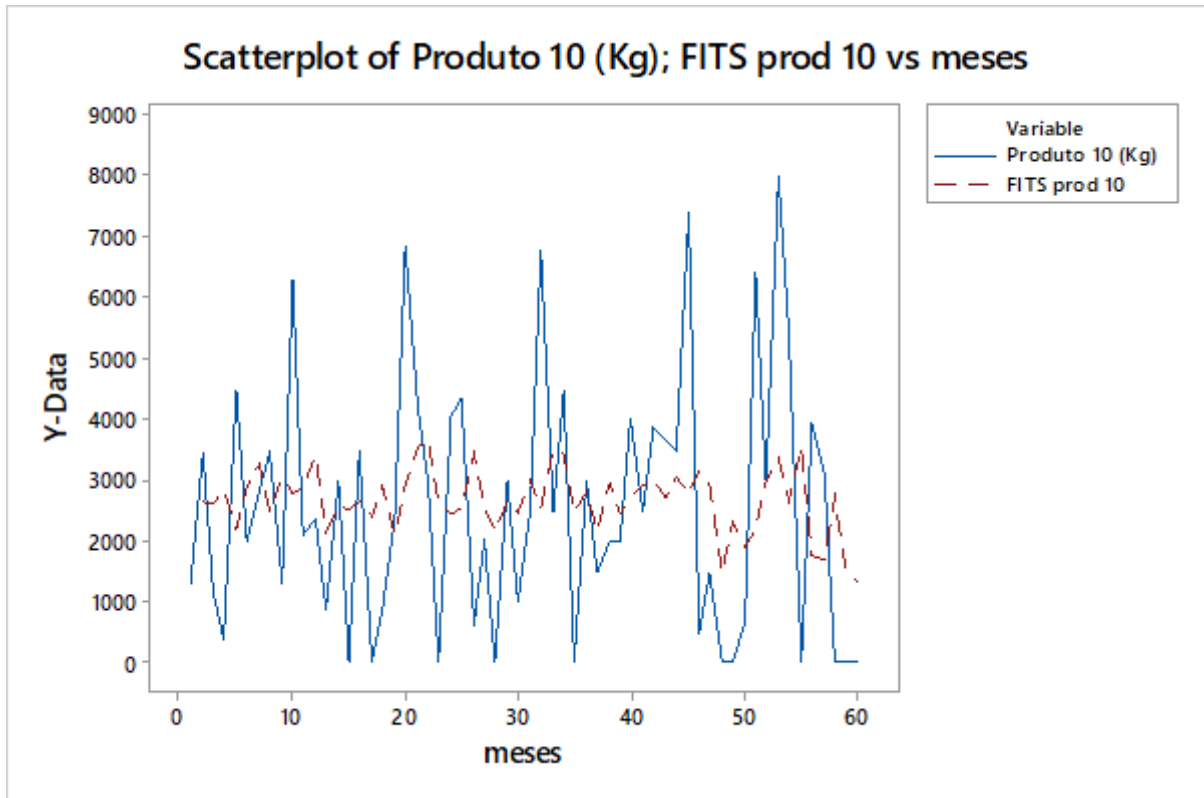
Row	Obs.	FITS	Meses
1	1280	*	1
2	3450	2646,01	2
3	1150	2616,89	3
4	391	2863,98	4
5	4494	2191,31	5
6	2000	2869,81	6
7	2800	3265,49	7
8	3452	2481,44	8
9	1307	3046,55	9
10	6327	2763,84	10
11	2090	2899,44	11
12	2375	3406,36	12
13	855	2146,53	13
14	3002	2581,01	14
15	1	2517,26	15
16	3515	2656,79	16
17	1	2398,22	17
18	855	2929,12	18
19	2356	2109,43	19
20	6878	2914,49	20
21	4218	3527,69	21
22	2945	3664,80	22

23	1	2599,62	23
24	4066	2425,58	24
25	4370	2536,74	25
26	608	3439,57	26
27	2014	2535,89	27
28	19	2173,50	28
29	2983	2645,57	29
30	988	2464,71	30
31	2489	2974,60	31
32	6778	2534,42	32
33	2470	3506,15	33
34	4484	3426,29	34
35	1	2468,68	35
36	2983	2818,67	36
37	1482	2164,42	37
38	1995	2965,91	38
39	1976	2430,21	39
40	4028	2725,59	40
41	2470	2914,17	41
42	3876	3019,26	42
43	3684	2705,05	43
44	3453	3068,51	44
45	7395	2780,09	45
46	493	3146,13	46
47	1479	2900,51	47
48	1	1466,16	48
49	1	2313,48	49
50	643	1901,05	50
51	6409	2192,07	51
52	2958	3000,02	52
53	7990	3352,75	53
54	5423	2693,19	54
55	1	3522,40	55
56	3944	1767,92	56
57	3138	1674,57	57
58	1	2714,32	58
59	1	1594,69	59
60	1	1305,37	60

---

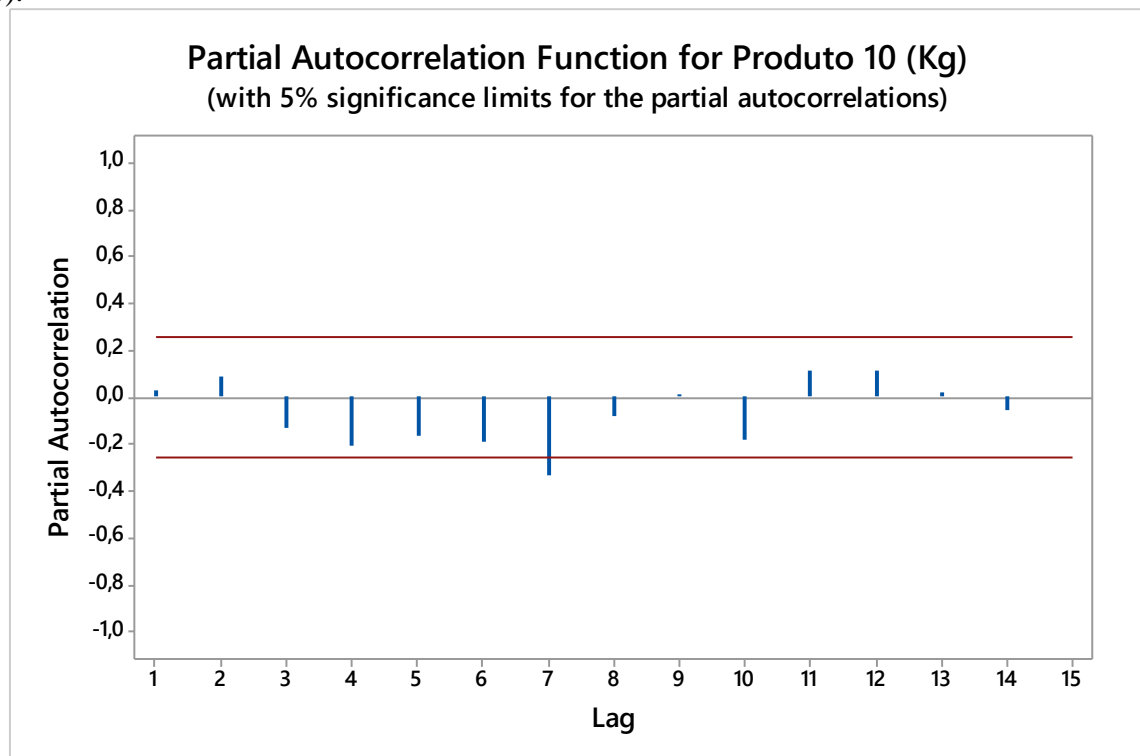
Fonte: Elaborado pelo autor.

Figura 33 - Gráfico dos valores preditos (FITS) do modelo ARIMA(2,1,3) ajustado.



Fonte: Elaborado pelo autor.

Figura 34 - Gráfico das autocorrelações parciais do modelo ARIMA (2,1,3) (produto 10).




Fonte: Elaborado pelo autor.

#### 4.5.4 Produto 3 (20L) na escala logarítmica

Na Figura 35 apresenta-se o modelo ajustado de médias móveis (médias mensais dos últimos 3 meses). Na Figura 36 estão os gráficos de resíduos do modelo ajustado indicando que as suposições necessárias para o uso do modelo (normalidade e variância constante dos resíduos) são verificadas (uso do *software* Minitab®).


Na Tabela 14, seguem os resultados (estimativas dos parâmetros) do modelo ARIMA (2,1,3) ajustado (uso do *software* Minitab®). Na Figura 37 apresentam-se os gráficos de resíduos do modelo ajustado indicando que as suposições necessárias para o uso do modelo (normalidade e variância constante dos resíduos) são verificadas (uso do *software* Minitab®). Na Tabela 15, estão os resultados de previsão obtidos pelo modelo ARIMA (2,1,3) ajustado para cada mês. Na Figura 38 segue o gráfico do modelo ARIMA (2,1,3) ajustado. A Figura 39 mostra o gráfico das autocorrelações parciais indicando o bom ajuste do modelo ARIMA (2,1,3).

Figura 35 - Modelo de médias móveis ajustado (log(PTM 20 L))



Fonte: Elaborado pelo autor.

Figura 36 - Gráficos de resíduos do modelo de médias móveis ajustado (log(PTM 20 L))



Fonte: Elaborado pelo autor.

Tabela 14 - Estimativas dos parâmetros do modelo ARIMA (2,1,3) ajustado (log(PTM 20 L))

Type	Coef	SE Coef	T	P
AR 1	-0,7948	0,6358	-1,25	0,217
AR 2	-0,1452	0,6046	-0,24	0,811
MA 1	0,1188	0,6087	0,2	0,846
MA 2	0,4647	0,339	1,37	0,176
MA 3	0,3506	0,5233	0,67	0,506
Constant	0,03997	0,03309	1,21	0,232

*Differencing: 1 regular difference*

*Number of observations: Original series 60, after differencing 59*

*Residuals: SS = 199,095 (backforecasts excluded)*

**MS = 3,757**

**DF = 53**

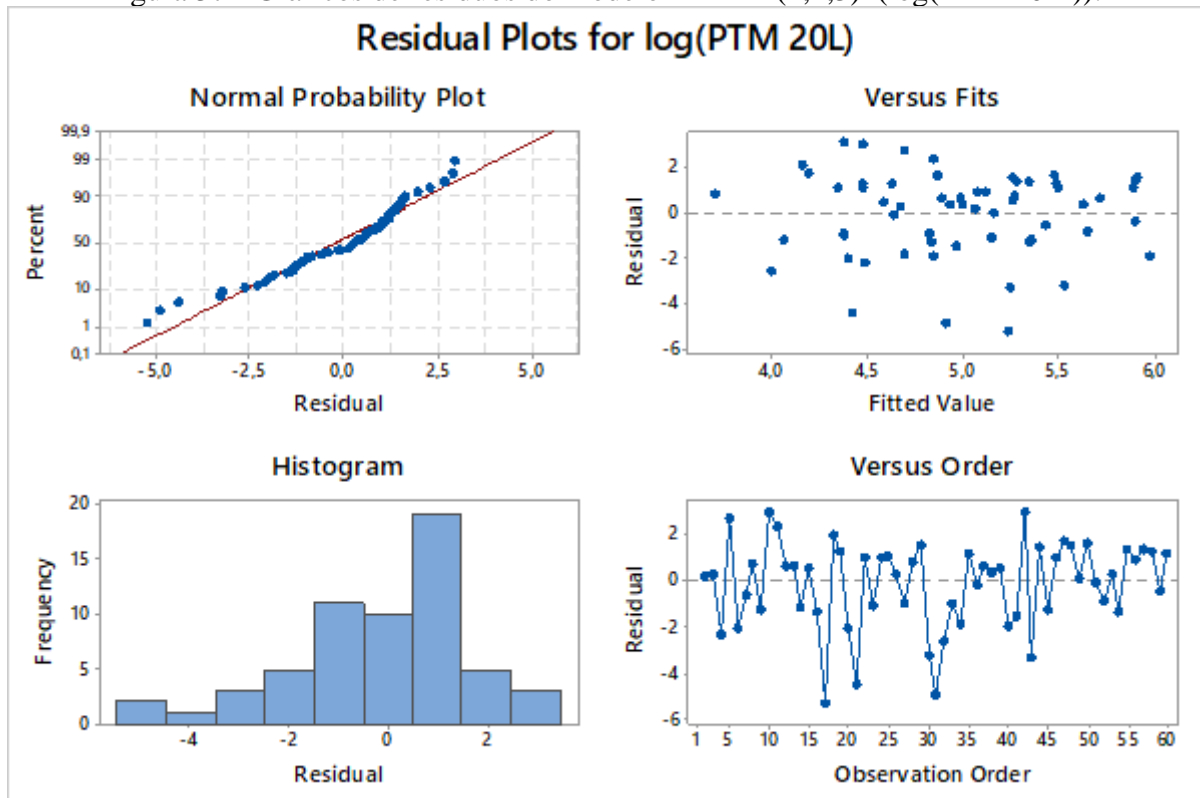
*Modified Box-Pierce (Ljung-Box) Chi-Square statistic*

<i>Lag</i>	12	24	36	48
<i>Chi-Square</i>	7,7	17,3	23,5	32,3
<i>DF</i>	6	18	30	42
<i>P-Value</i>	0,262	0,504	0,796	0,861

Fonte: Elaborado pelo autor.



Figura 37 - Gráficos de resíduos do modelo ARIMA(2,1,3) (log(PTM 20 L)).



Fonte: Elaborado pelo autor.


Tabela 15 - Resultados de previsão (FITS) obtidos pelo modelo ARIMA (2,1,3) ajustado.

Row	LOG	Meses	FITS
1	6,31173	1	*
2	4,8828	2	4,67467
3	5,2832	3	5,00440
4	2,19722	4	4,48880
5	7,39634	5	4,70139
6	2,30259	6	4,39922
7	4,85203	7	5,43626
8	4,43082	8	3,70411
9	4,09434	9	5,35569
10	7,39634	10	4,47979
11	7,14045	11	4,84579
12	6,32077	12	5,71878
13	5,48064	13	4,88903
14	4,00733	14	5,15286
15	5,54908	15	4,99030
16	3,49651	16	4,83614
17	0	17	5,24504
18	6,17379	18	4,16648
19	5,71043	19	4,48317
20	3,97029	20	5,98265
21	0	21	4,42552

22	5,48894	22	4,47863
23	3,3322	23	4,38481
24	6,52062	24	5,49649
25	5,39363	25	4,35290
26	5,92158	26	5,63596
27	3,8712	27	4,82894
28	5,92959	28	5,08031
29	6,43775	29	4,87530
30	2,30259	30	5,53056
31	0	31	4,91490
32	1,38629	32	4,00635
33	3,4012	33	4,38554
34	2,83321	34	4,69603
35	5,82008	35	4,62931
36	4,49981	36	4,63792
37	5,9135	37	5,27161
38	4,96284	38	4,59204
39	5,7589	39	5,25925
40	2,89037	40	4,84749
41	3,46574	41	4,96489
42	7,37149	42	4,37720
43	1,94591	43	5,25088
44	6,70441	44	5,25766
45	2,77259	45	4,06432
46	6,88141	46	5,88647
47	5,85793	47	4,20143
48	7,40123	48	5,90865
49	5,1985	49	5,06732
50	7,04665	50	5,47521
51	5,0876	51	5,16664
52	4,77068	52	5,64943
53	5,23111	53	4,93710
54	4,00733	54	5,35230
55	6,63068	55	5,28427
56	5,98645	56	5,12535
57	7,28207	57	5,90118
58	6,60935	58	5,34964
59	5,46806	59	5,90270
60	6,67582	60	5,49487


Fonte: Elaborado pelo autor

Figura 38 - Gráfico dos valores preditos (FITS) do modelo ARIMA(2,1,3) ajustado.



Fonte: Elaborado pelo autor

Figura 39 - Gráfico das autocorrelações parciais do modelo ARIMA (2,1,3) (log(PTM 20 L)).




Fonte: Elaborado pelo autor.

#### 4.5.5 Produto 3 (5L) na escala logarítmica

Na Figura 40 tem-se o modelo ajustado de médias móveis (médias mensais dos últimos 3 meses). Na Figura 41 apresentam-se os gráficos de resíduos do modelo ajustado indicando que as suposições necessárias para o uso do modelo (normalidade e variância constante dos resíduos) são verificadas (uso do *software* Minitab®).

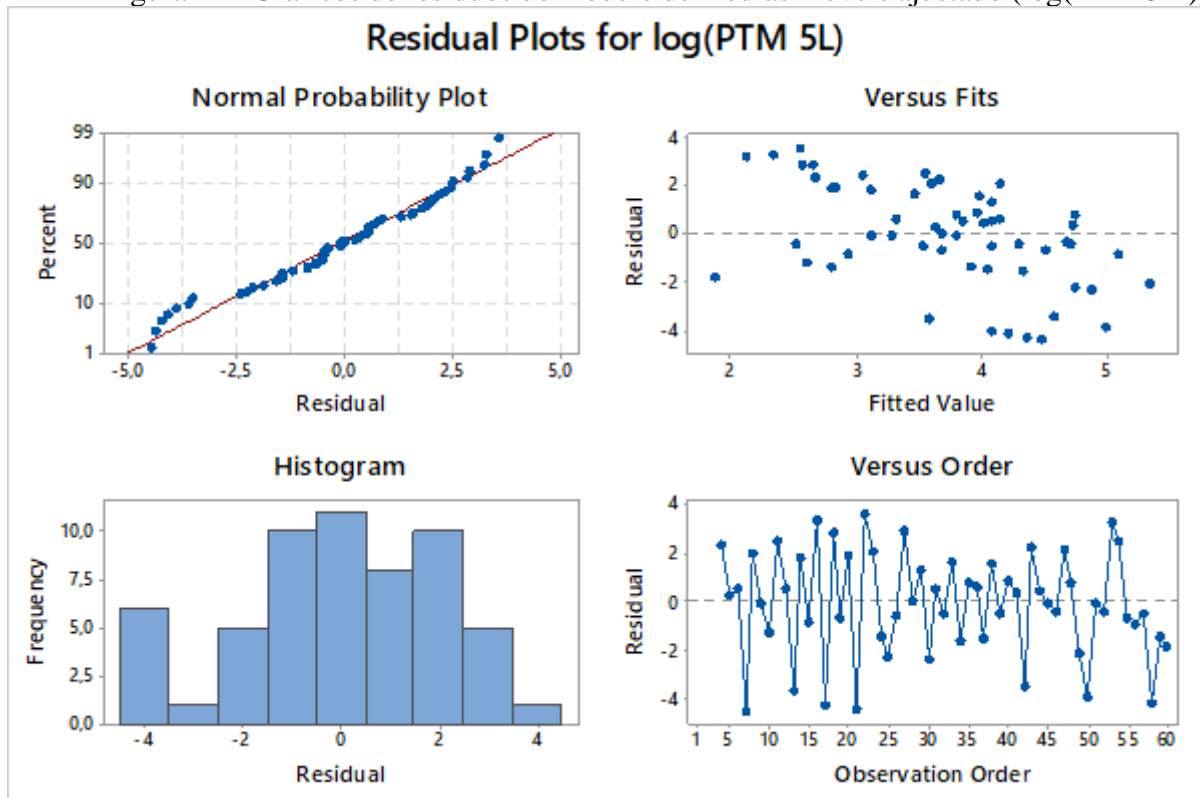
Na Tabela 16, seguem os resultados (estimativas dos parâmetros) do modelo ARIMA (2,1,3) ajustado (uso do *software* Minitab®). Na Figura 42 apresentam-se os gráficos de resíduos do modelo ajustado indicando que as suposições necessárias para o uso do modelo (normalidade e variância constante dos resíduos) são verificadas (uso do *software* Minitab®). Na Tabela 17, estão os resultados de previsão obtidos pelo modelo ARIMA (2,1,3) ajustado para cada mês. Na Figura 43 segue o gráfico do modelo ARIMA (2,1,3) ajustado. A Figura 44 mostra o gráfico das autocorrelações parciais indicando o bom ajuste do modelo ARIMA (2,1,3).

Figura 40 - Modelo de médias móveis ajustado (log(PTM 5L)).



Fonte: Elaborado pelo autor

Figura 41 - Gráficos de resíduos do modelo de médias móveis ajustado (log(PTM 5 L)).



Fonte: Elaborado pelo autor

Tabela 16 - Estimativas dos parâmetros do modelo ARIMA (2,1,3) ajustado (log(PTM 5 L)).

Type	Coef	SE Coef	T	P
AR 1	-0,5012	1,5308	-0,33	0,745
AR 2	0,1828	1,2161	0,15	0,881
MA 1	0,6125	1,5618	0,39	0,696
MA 2	0,4964	0,7784	0,64	0,526
MA 3	-0,1328	1,0792	-0,12	0,903
Constant	0,00243	0,01357	0,18	0,858

**Differencing: 1 regular difference**

**Number of observations: Original series 60, after differencing 59**

**Residuals: SS = 184,086 (backforecasts excluded)**

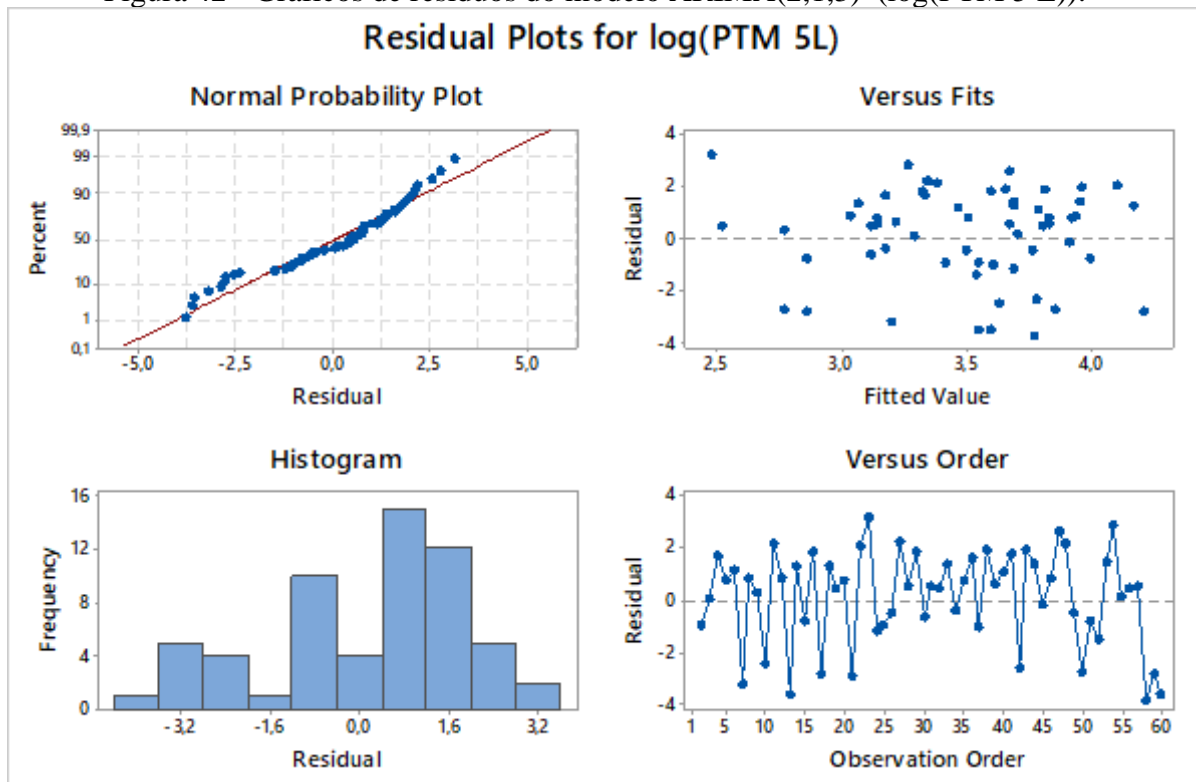
**MS = 3,473      DF = 53**

**Modified Box-Pierce (Ljung-Box) Chi-Square statistic**

Lag	12	24	36	48
Chi-Square	7,3	13,0	21,6	32,2
DF	6	18	30	42
P-Value	0,297	0,794	0,867	0,861

Fonte: Elaborado pelo autor

Figura 42 - Gráficos de resíduos do modelo ARIMA(2,1,3) (log(PTM 5 L)).



Fonte: Elaborado pelo autor


Tabela 17 - Resultados de previsão (FITS) obtidos pelo modelo ARIMA (2,1,3) ajustado.

<b>Row</b>	<b>Log</b>	<b>Meses</b>	<b>FIT</b>
1	2,07944	1	*
2	2,56495	2	3,54740
3	3,3673	3	3,29173
4	4,96981	4	3,33346
5	3,89182	5	3,14553
6	4,60517	6	3,46807
7	0	7	3,20324
8	4,75359	8	3,93754
9	3,04452	9	2,77295
10	1,38629	10	3,77589
11	5,51343	11	3,34455
12	3,8712	12	3,03806
13	0	13	3,54699
14	4,94164	14	3,68933
15	2,07944	15	2,86401
16	5,63479	16	3,80783
17	0	17	2,76872
18	5,41165	18	4,16131
19	2,99573	19	2,52282
20	4,68213	20	3,92042

21	0	21	2,86233
22	6,13123	22	4,09526
23	5,64191	23	2,47976
24	2,48491	24	3,68291
25	2,48491	25	3,41442
26	2,99573	26	3,49402
27	5,54908	27	3,34976
28	3,68888	28	3,14203
29	5,39363	29	3,59751
30	2,48491	30	3,12190
31	4,38203	31	3,82794
32	3,55535	32	3,11714
33	5,07517	33	3,69089
34	2,77259	34	3,17286
35	4,60517	35	3,82305
36	4,78749	36	3,17158
37	2,56495	37	3,60239
38	5,52943	38	3,65172
39	3,82864	39	3,21916
40	4,83628	40	3,78226
41	5,07517	41	3,32384
42	1,09861	42	3,62702
43	5,88888	43	3,95694
44	4,41884	44	3,06780
45	3,71357	45	3,91153
46	4,30407	46	3,50774
47	6,24222	47	3,67146
48	5,50533	48	3,38498
49	3,2581	49	3,76216
50	1,09861	50	3,84951
51	3,21888	51	3,98921
52	2,07944	52	3,53442
53	5,37528	53	3,94901
54	6,06843	54	3,26398
55	3,82864	55	3,70702
56	4,21951	56	3,80298
57	4,21951	57	3,67334
58	0	58	3,76822
59	1,38629	59	4,20949
60	0	60	3,59495


Fonte: Elaborado pelo autor

Figura 43 - Gráfico dos valores preditos (FITS) do modelo ARIMA(2,1,3) ajustado.



Fonte: Elaborado pelo autor.

Figura 44 - Gráfico das autocorrelações parciais do modelo ARIMA (2,1,3) (log(PTM 5 L)).



Fonte: Elaborado pelo autor.




#### 4.5.6 Produto 3 (1L) na escala logarítmica

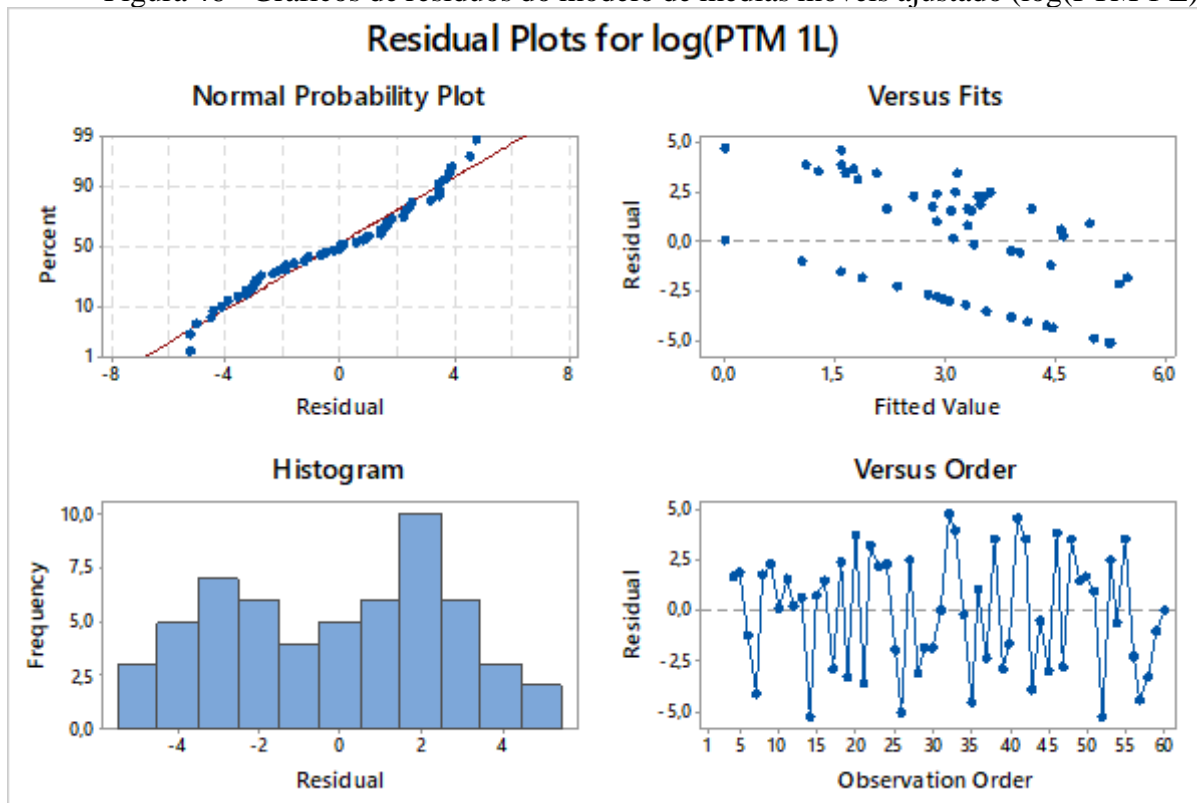
Na Figura 45 está o modelo ajustado de médias móveis (médias mensais dos últimos 3 meses). Na Figura 46 apresentam-se os gráficos de resíduos do modelo ajustado indicando que as suposições necessárias para o uso do modelo (normalidade e variância constante dos resíduos) são verificadas (uso do *software* Minitab®).

Na Tabela 18, seguem os resultados (estimativas dos parâmetros) do modelo ARIMA (2,1,3) ajustado (uso do *software* Minitab®). Na Figura 47 estão os gráficos de resíduos do modelo ajustado indicando que as suposições necessárias para o uso do modelo (normalidade e variância constante dos resíduos) são verificadas (uso do *software* Minitab®). Na Tabela 19, apresentam-se os resultados de previsão obtidos pelo modelo ARIMA (2,1,3) ajustado para cada mês. Na Figura 48 está o gráfico do modelo ARIMA (2,1,3) ajustado. A Figura 49 mostra o gráfico das autocorrelações parciais indicando o bom ajuste do modelo ARIMA (2,1,3).

Figura 45 - Modelo de médias móveis ajustado (log(PTM 1L)).



Fonte: Elaborado pelo autor.

Figura 46 - Gráficos de resíduos do modelo de médias móveis ajustado ( $\log(\text{PTM 1 L})$ ).

Fonte: Elaborado pelo autor.

Tabela 18 - Estimativas dos parâmetros do modelo ARIMA (2,1,3) ajustado ( $\log(\text{PTM 1 L})$ ).

Type	Coef	SE Coef	T	P
AR 1	-0,8341	0,1026	-8,13	0
AR 2	-0,7864	0,1029	-7,64	0,000
MA 1	0,1421	0,0974	1,46	0,150
MA 2	-0,1978	0,0824	-2,40	0,020
MA 3	0,9650	0,0938	10,29	0,000
Constant	-0,04356	0,04451	-0,98	0,332

*Differencing: 1 regular difference*

*Number of observations: Original series 60, after differencing 59*

*Residuals: SS = 305,483 (backforecasts excluded)*

**MS = 5,764**

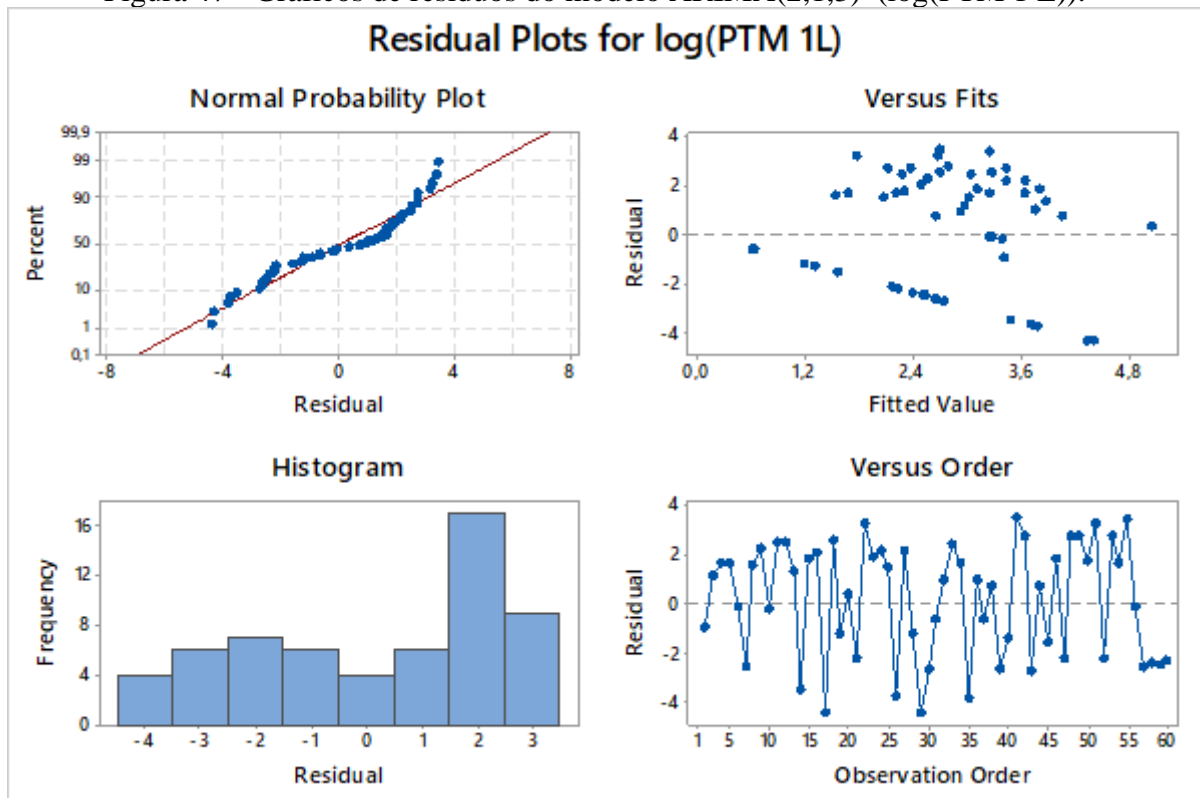
**DF = 53**

*Modified Box-Pierce (Ljung-Box) Chi-Square statistic*

<i>Lag</i>	12	24	36	48
<i>Chi-Square</i>	6,0	10,5	29,9	36,6
<i>DF</i>	6	18	30	42
<i>P-Value</i>	0,428	0,915	0,470	0,705

Fonte: Elaborado pelo autor.

Figura 47 - Gráficos de resíduos do modelo ARIMA(2,1,3) (log(PTM 1 L)).



Fonte: Elaborado pelo autor.

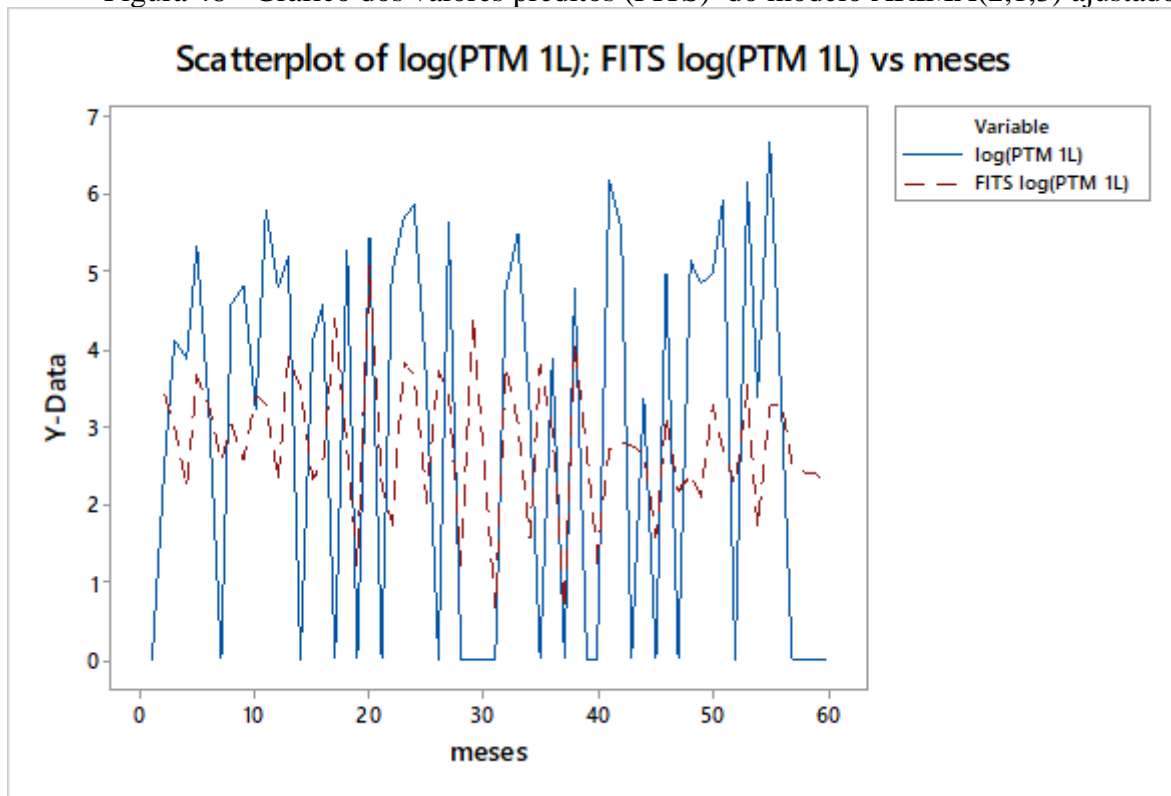
Tabela 19 - Resultados de previsão (FITS) obtidos pelo modelo ARIMA (2,1,3) ajustado.

Row	LOG	Meses	FITS
1	0,00000	1	*
2	2,48491	2	3,42091
3	4,12713	3	2,98741
4	3,87120	4	2,22582
5	5,31812	5	3,64454
6	3,17805	6	3,25686
7	0,00000	7	2,53611
8	4,56435	8	3,02000
9	4,82028	9	2,56793
10	3,21888	10	3,40651
11	5,78690	11	3,29172
12	4,78749	12	2,29565
13	5,19296	13	3,87858
14	0,00000	14	3,49555
15	4,09434	15	2,32104
16	4,56435	16	2,50782
17	0,00000	17	4,34060
18	5,25750	18	2,70623
19	0,00000	19	1,21256
20	5,42935	20	5,07262

21	0,00000	21	2,23937
22	4,96981	22	1,77405
23	5,68017	23	3,80948
24	5,85220	24	3,66306
25	3,58352	25	2,08167
26	0,00000	26	3,71146
27	5,62040	27	3,44152
28	0,00000	28	1,21404
29	0,00000	29	4,40934
30	0,00000	30	2,66022
31	0,00000	31	0,63365
32	4,75359	32	3,77516
33	5,48064	33	3,04779
34	3,17805	34	1,55164
35	0,00000	35	3,78932
36	3,87120	36	2,93052
37	0,00000	37	0,64528
38	4,78749	38	4,07536
39	0,00000	39	2,65857
40	0,00000	40	1,32591
41	6,17379	41	2,69673
42	5,54126	42	2,78988
43	0,00000	43	2,74644
44	3,36730	44	2,65499
45	0,00000	45	1,57335
46	4,96981	46	3,13165
47	0,00000	47	2,16934
48	5,12396	48	2,38342
49	4,82831	49	2,12263
50	4,97673	50	3,25281
51	5,89440	51	2,68761
52	0,00000	52	2,24317
53	6,14847	53	3,44076
54	3,36730	54	1,68908
55	6,64639	55	3,26998
56	3,17805	56	3,29433
57	0,00000	57	2,51363
58	0,00000	58	2,41079
59	0,00000	59	2,41323
60	0,00000	60	2,24801


Fonte: Elaborado pelo autor.

Figura 48 - Gráfico dos valores preditos (FITS) do modelo ARIMA(2,1,3) ajustado.



Fonte: Elaborado pelo autor.

Figura 49 - Gráfico das autocorrelações parciais do modelo ARIMA (2,1,3) (log(PTM 1 L)).



Fonte: Elaborado pelo autor.

#### 4.6 Discussão dos resultados obtidos

Apesar dos dados apresentarem uma grande variabilidade (alguns meses com milhares de unidades e alguns meses com 1 unidade), os modelos de séries temporais de médias móveis e ARIMA conseguiram apresentar tendências das vendas mensais dos diferentes produtos. Isso foi observado usando modelos ARIMA (2,1,3) com os resultados apresentados nas Tabelas 9, 11, 3, 15, 17 e 19, pois pode-se enxergar a tendência muito parecido entre o real e o previsto quando se traça uma comparação entre eles.

Pode-se observar que os modelos se comportam muito bem ao longo do tempo, quando comparados o previsto com o realizado. Porém, quando surge um pico ou um vale de demanda, apresentam uma diferença muito grande. Tendo isso em vista, faz-se necessário uma análise crítica nesses períodos de baixa e alta, observando o que ocorreu para que esses valores oscilassem tanto, inclusive da tendência apresentada.

Infelizmente o *gap* entre o real e o previsto, não pode ser tratado, pois é uma narrativa do modelo. Pode-se utilizar a tendência como fonte de dados. Nos períodos que apresentem tendências baixas realizar algumas promoções de *marketing* para atingir e elevar essa tendência, ou utilizar esse período para se preparar para os períodos de alta e conseguir atender aos clientes, aumentando assim a parceria e satisfação deles.

Em um próximo estudo a metodologia poderia ser usada para dados agrupados (por exemplo, vendas trimestrais) e series temporais mais longas, possivelmente com pelo menos 10 anos e considerando diferentes covariáveis, como cotação do dólar, índice de desemprego, salário-mínimo, e outros fatores econômicos que podem estar correlacionados com as series temporais para cada produto, ou até uma previsão realizada por família de produto, já que os produtos 6, 9 e 10 são da mesma família e possuem uma sequência de demandas altas.

Pode-se apresentar uma comparação com o trabalho realizado por Fattah et al (2018) que utilizou o modelo ARIMA (1,0,1) para prever demanda do produto em longos períodos, enquanto no presente estudo o modelo utilizado foi o ARIMA (2,1,3), com isso pode-se avaliar duas vertentes, a primeira é que o modelo ARIMA traz resultados muito bons quando se trata de prever demanda em longos períodos e a segunda é que para cada produto, de acordo com sua demanda, deve-se diferenciar a apresentação do modelo ARIMA.

Também pode-se comparar com a pesquisa de Zhu et al (2021) que desenvolveram um estudo de previsão de demanda na indústria farmacêutica, apontando que o trabalho desenvolvido pode ser utilizado por outras empresas, realizando as adaptações. Igualmente o sugerem um passo a passo para sua implantação.

Para a escolha do modelo adotado utilizou-se a aderência ao real obtido pela empresa, já o trabalho de Yin et al (2019) comparou modelos, porém com base em desempenho e erros de previsão, o que incentiva a estudos futuros realizando a comparação do desempenho e dos erros de previsão.

#### **4.7 Validação dos Resultados**

De posse dos resultados, agendou-se uma reunião com a liderança da empresa para apresentá-los e buscar validação para a utilização do melhor método. Foram apresentados os modelos e as observações sobre cada um sendo recomendada a utilização do método mais aderente ao realizado, e colocado em fase de teste, ou seja, a empresa no início de 2023 começou a utilizar o modelo para seus planejamentos e estratégias, e o resultado tem sido muito positivo para o planejamento e compras, podendo ter mais assertividade no planejamento e mais tempo de negociação em compras. Outro ponto abordado na reunião foi a replicação do procedimento descrito no presente estudo para os demais produtos da empresa.

## 5. CONCLUSÃO

O objetivo do estudo foi apresentar o modelo de séries temporais com o menor erro e pouca disparidade quando comparado ao real obtido em uma indústria farmoquímica. De acordo com a revisão bibliográfica realizada na base Scopus foi observada a utilização de previsão de demanda por meio series temporais e de acordo com as análises realizadas verificou-se a disseminação do assunto havendo destaque para os anos de 2019 e 2020 possuindo destaque nos continentes Asiático, Europeu e América do Sul. Também se observou a grande importância da previsão de demanda no meio empresarial, em que diversos trabalhos foram aplicados. Também pode-se observar a grande maioria dos trabalhos em inglês. Os artigos evidenciam fatores positivos à utilização da previsão de demanda por meio de series temporais, sugerindo a aplicação destes em estudos correlatos.

Encorajado pela revisão da literatura, quatro produtos foram selecionados como objeto de estudo para previsão de demanda, trazendo uma visão para empresa dos principais produtos quando se relaciona Faturamento e Produção. Esse estudo foi de grande valia, pois apresenta um passo a passo para que se gere previsões de demanda por meio de series temporais, ou seja, um método estruturado para se seguir caso exista a necessidade de utilizar esse meio para prever demanda e oportunizando um legado para que a empresa utilize como procedimento para as previsões dos demais produtos ou adicione ainda mais dados nessas previsões para torná-las mais assertivas.

O ano de 2020 apresenta-se com maior demanda para os produtos 6, 9 e 10, agora quando se análise por mês se tem o mês agosto como o de maior demanda para o produto 10, o mês de setembro como o de maior demanda para o produto 9 e o mês de outubro como o de maior demanda para o produto 6, ou seja eles apresentam uma sequência de demandas altas. Essa sequência de demandas altas refere-se a eles serem de uma mesma família e portanto para uma sugestão futura, realizar as previsões por família de produtos.

Já para o produto 3 e suas apresentações, os dados estão bem pulverizados ao longo do período, com cada apresentação apresentando anos e meses diferentes entre si.

Os modelos foram adotados pelos diretores da empresa e colocados em fase de teste para validar os resultados e utilizar para ajustar o modelo utilizado, além replicar para os outros produtos de acordo com o passo a passo proposto.

Tendo em vista os resultados obtidos e utilizando a comparação com o real os modelos selecionados para os produtos 6, 9 e 10 foi ARIMA, já para o produto 3 por mais que médias



móveis apresentasse uma boa distribuição optou-se pelo ARIMA, pois foi mais assertivo quando se olha para todo o período.

Como limitação para esse estudo e sugestão para estudos futuros seria utilizar outros métodos de previsão de demanda para comparar, adicionar mais dados temporais e/ou utilizar aprendizado de máquina para prever demanda desses produtos.

## REFERÊNCIAS

- ABOLGHASEMI, Mahdi; HURLEY, Jason; ESHRAGHAC, Ali; FAHIMNIAB, Behnam. Demand forecasting in the presence of systematic events: Cases in capturing sales promotions. **International Journal of Production Economics**, v. 230, p. 107892, 2020.
- ARMSTRONG, J.Scott; COLLOPY, Fred. Error measures for generalizing about forecasting methods: empirical comparisons. **International Journal Of Forecasting**, v. 8, n. 1, p. 69-80, jun. 1992.
- BANDEIRA, Saymon Galvão; ALCALÁ, Symone Gomes Soares Alcalá; VITA, Roberto Oliveira; BARBOSA, Talles Marcelo Gonçalves de Andrade. Comparison of selection and combination strategies for demand forecasting methods. **Production**, v. 30, 2020.
- BELL, William Robert. An introduction to forecasting with time series models. **Insurance: Mathematics and Economics**, v. 3, n. 4, p. 241-255, 1984.
- BELVEDERE, Valeria; GOODWIN, Paul. The influence of product involvement and emotion on short-term product demand forecasting. **International Journal of Forecasting**, v. 33, n. 3, p. 652-661, 2017.
- BOX, George EP; JENKINS, Gwilym M.; REINSEL, Gregory. C.; LJUNG, Greta M. **Time series analysis, forecasting and control**. Englewood Cliffs. 1994.
- BRINKHOFF, James; ROBSON, Andrew J. Macadamia Orchard Planting Year and Area Estimation at a National Scale. **Remote Sensing**, v. 12, n. 14, p. 2245, 2020.
- CALSING, Luciana Cristina. **Previsão de demanda combinada a partir de métodos quantitativos e opinião de especialistas**. 2015. 68 p. Dissertação (Mestrado em Engenharia de Produção). Universidade Federal do Rio Grande do Sul, Porto Alegre, 2015.
- CASTRO, Rodrigo Rivera; NAZAROV, Ivan; XIANG, Yuke; MAKSIMOV, Ivan; PLETNEV, Aleksandr; BURNAEV, Evgeny. An industry case of large-scale demand forecasting of hierarchical components. In: **2019 18th IEEE International Conference on Machine Learning and Applications (ICMLA)**. IEEE, 2019. p. 134-139.
- CERVO, Amado Lui; BERVIAN, Pedro Alcino; SILVA, Roberto da. **Metodologia Científica**. 6. ed. São Paulo: Pearson Prentice Hall, 2010. 176 p.
- CONFORTO, Edivandro Carlos; AMARAL, Daniel Capaldo; SILVA, Sergio Luis da. Roteiro para revisão bibliográfica sistemática: aplicação no desenvolvimento de produtos e gerenciamento de projetos. 8o Congresso Brasileiro de Gestão de Desenvolvimento de Produto - CBGDP. **Anais...** p.1-12, Porto Alegre, 2011.

COSTA, Jorge Carlos Santos da; PAGOTTO, Mario Celso; CASAS, Carmen Nila Phang Romero; VARGAS, Marco Antonio; Neto, José Celestino de Barros; BERMUDEZ, Jorge Antonio Zepeda. Avaliação do setor produtivo farmoquímico no Brasil: capacitação tecnológica e produtiva. **RECIIS - Revista Eletrônica de Comunicação, Informação e Inovação em Saúde**, Rio de Janeiro, v. 8, n. 4, p. 443-460, out./dez. 2014.

CORREA, Henrique Luiz; GIANESI, Irineu Gustavo Nogueira; CAON, Mauro. **Planejamento, programação e controle da produção: MRPII/ERP: conceitos, uso e implantação base para SAP, Oracle Applications e outros softwares integrados de gestão**. 5ª edição. São Paulo: Atlas, 2014.

CRUZ, René Santa; CORRÊA, Camila. Intermittent demand forecasting with time series methods and artificial neural networks: A case study. **DYNA: revista de la Facultad de Minas**. Universidad Nacional de Colombia. Medellín, v. 84, n. 203, p. 9-16, 2017.

DAS, Dipankar; CHAKRABARTI, Satyajit. Forecasting non-linear WPI of manufacture of chemicals and chemical products in India: an MLP approach. **International Journal of Advanced Technology and Engineering Exploration**, v. 8, n. 82, p. 1193, 2021.

DELURGIO, Stephen A. **Forecasting principles and applications**. McGraw-Hill/Irwin, 1998.

ELSAMIE, Mohamed Abd; ALI, Tarek; ZHOU, Deyi. Using a dynamic time series model (Arima) for forecasting of Egyptian cotton crop variables. **Journal of Animal and Plant Sciences**, v. 31, n. 3, p. 810-23, 2021.

ELSAYED, Elsayed; BOUCHER, Thomas. **Analysis and Control of Production Systems**. Califórnia: Prentice-Hall, 1985. 320 p.

FATTAH, Jamal; EZZINE, Latifa; AMAN, Zineb; MOUSSAMI, Haj El; LACHHAB, Abdeslam. Forecasting of demand using ARIMA model. **International Journal of Engineering Business Management**, v. 10, p. 1847979018808673, 2018.

GIL, Antônio Carlos. **Como elaborar projetos de pesquisa**. 5. Ed. São Paulo: Atlas, 2010.

GOOVAERTS, Pierre. **Geostatistics for natural resources evaluation**. Oxford University Press on Demand, 1997.

HO, Siu Lau; XIE, Min. The use of ARIMA models for reliability forecasting and analysis. **Computers & industrial engineering**, v. 35, n. 1-2, p. 213-216, 1998.

HOLT, Charles C. Forecasting seasonals and trends by exponentially weighted moving averages. **International journal of forecasting**, v. 20, n. 1, p. 5-10, 2004.

HYNDMAN, Rob; KOEHLER, Anne; ORD, Keith; SNYDER, Ralph. **Forecasting with exponential smoothing: the state space approach**. Berlin: Springer Berlin Heidelberg, 2008. 362 p.

IQVA. **Growth perspectives for the pharma market**, IQVA, 2020. Disponível em: <<https://www.iqvia.com/blogs/2019/10/growth-perspectives-for-the-pharma-market>>. Acesso em 20, agosto, 2021.

JAIN, Chaman L.; MALEHORN, Jack. **Benchmarking: Forecasting Practices: A Guide to Improving Forecasting Performance**. Institute of Business Forec, 2006.

JUNQUEIRA, Diego. Coronavírus expõe fragilidade das farmacêuticas, que receberam menor investimento da década sob Bolsonaro. **Repórter Brasil**, 2020a. Disponível em: <<https://reporterbrasil.org.br/2020/04/coronavirusexpoe-fragilidade-das-farmaceuticas-que-receberam-menor-investimento-da-decada-sob-bolsonaro/>>. Acesso, v. 17, n. 07, 2020.

KAČMÁRY, Peter; MALINDŽÁK, Dušan; SPIŠÁK, Ján. The design of forecasting system used for prediction of electro-motion spare parts demands as an improving tool for an enterprise management. **Management Systems in Production Engineering**, 2019.

KAHN, Kenneth B. An Exploratory Investigation of New Product Forecasting Practices. **The Journal of Product Innovation Management: An international publication of the product development & management association**, v. 19, n. 2, p. 133-143, 2002.

KAHN, K. Benchmarking Sales Forecasting Performance Measures. **The Journal of Business Forecasting**. Winter, p. 19-23, 1998.

KIM, Jaedong. Text Mining-based Approach for Forecasting Spare Parts Demand of KX Tanks. In: **2018 IEEE International Conference on Industrial Engineering and Engineering Management (IEEM)**. IEEE, 2018. p. 1652-1656.

KOTLER, Philip; **Marketing Management: Analysis, Planning, Implementation and Control**. New Jersey: Prentice-Hall, 1991.

LAGE JUNIOR, De Murís. **Planejamento e Controle da Produção: teoria e prática**. Rio de Janeiro: LTC, 2019.

LAKATOS, Eva Maria.; MARCONI, Marina de Andrade. **Fundamentos de metodologia científica**. 7. ed. São Paulo: Atlas, 2010.

LEE, Hau. H. Ultimate Enterprise Value Creation Using Demand-Based Management,” working paper no. **Stanford Global Supply Chain Management Forum**, Stanford, California, September 2001.

LEE, Hanjun; KIM, Jaedong. A Predictive Model for Forecasting Spare Parts Demand in Military Logistics. In: **2018 IEEE International Conference on Industrial Engineering and Engineering Management (IEEM)**. IEEE, 2018. p. 1106-1110.

MARTIN, Amanda Caroline; HENNING, Elisa; WALTER, Olga Maria Formigoni Carvalho; KONRATH, Andrea Cristina. Análise de séries temporais para previsão da evolução do número de automóveis no Município de Joinville. **Revista ESPACIOS**| Vol. 37 (Nº 06) Año 2016, 2016.

MARTINS, Diogo Barreto; STRAMBI, Orlando. Previsão sobre uma estrela: previsão ou pensamento positivo? **Journal of Air Transport Management**, v. 91, p. 101992, 2021.

MARTINS, Petrônio Garcia; LAUGENI, Fernando Piero. **Administração da Produção**. 3. ed. São Paulo: Saraiva, 2015.

MELO, Daniela de Castro; ALCÂNTARA, Rosane Lúcia Chicarelli. Proposição de um modelo para a gestão da demanda: um estudo entre os elos atacadista e fornecedores de produtos de mercearia básica. **Gestão & Produção**, v. 19, p. 759-777, 2012.

MONTGOMERY, Douglas C.; JENNINGS, Cheryl L.; KULAHCI, Murat. **Introduction to time series analysis and forecasting**. John Wiley & Sons, 2008.

MOON, Mark A.; MENTZER, John T.; SMITH, Carlo D. Conducting a sales forecasting audit. **International Journal of Forecasting**, v. 19, n. 1, p. 5-25, 2003.

MORESI, Eduardo Amadeu Dutra. **Metodologia da pesquisa**. 2003. Programa de Pós-graduação Stricto Sensu em Gestão do Conhecimento e Tecnologia da Informação, Universidade Católica de Brasília, Brasília, 2003.

MORETTIN, Pedro Alberto e TOLOI, Célia Maria de, **Previsão de séries temporais**. 2 ed., São Paulo, Atual, 1987.

OLIVEIRA, Eduardo Santos de; DOURADO, José Diamantino de Almeida; MELLO, José André Villas Boas. 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.

PARANHOS, Julia; PERIN, Fernanda Steiner; MIRANDA, Caroline; FALCÃO, Daniela; VEZ, Mariana. Desenvolvimento da indústria farmoquímica no Brasil e na Argentina: diagnóstico, desafios e oportunidades. **Blucher Engineering Proceedings**, [S.L.], v. 8, p. 2031-2047, maio 2021. Editora Blucher. <http://dx.doi.org/10.5151/v-enei-759>.

PELLEGRINI, Fernando R.; FOGLIATTO, Flávio S. Passos para implantação de sistemas de previsão de demanda: técnicas e estudo de caso. **Production**, v. 11, n. 1, p. 43-64, 2001.

RODRIGUEZ, Adolfo Rene Santa Cruz; CORRÊA, Camila. Previsão de demanda intermitente com métodos de série de tempo e redes neurais artificiais: Estudo de caso. **DYNA: revista de la Facultad de Minas**, Medellín, v. 84, n. 203, p. 9-16, 16 set. 2017.

SALAS-FIERRO, Tomas Eloy; MARTINEZ, Jania Astrid Saucedo; AGUILAR, Roman Rodriguez; HARO, Jose Manuel Vela. Demand prediction using a soft-computing approach: a case study of automotive industry. **Applied Sciences**, v. 10, n. 3, p. 829, 2020.

SILVA, Bráulio Wilker. **Gestão de estoques: planejamento, execução e controle** – 2.ed. João Monlevade: BWS Consultoria, 2019.

SANTOS, Daniel Marques dos. ANÁLISE DO FLUXO DE EXAMES EM UM HOSPITAL POR SÉRIES TEMPORAIS. **INOVAE-Journal of Engineering, Architecture and Technology Innovation (ISSN 2357-7797)**, v. 3, n. 2, p. 1-18, 2015.

SOUZA, Rafael; TRIERWEILLER, Andréa; WEISE, Andreas; ROCHA, Rudimar; MONTEIRO, Maria. Previsão da Demanda como suporte para o Planejamento e Controle da Produção na Sigma–Indústria Eletroeletrônica. **Revista Ingepro–Inovação, Gestão e Produção**, Uberaba, v. 3, n. 4, abr. 2010

TANIZAKI, Takashi; HOSHINO, Tomohiro; SHIMMURA, Takeshi; TAKENAKA, Takeshi. Restaurants store management based on demand forecasting. **Procedia CIRP**, v. 88, p. 580-583, 2020.

TRATAR, Liljana Ferbar; MOJŠKERC, Blaž; TOMAN, Aleš. Demand forecasting with four-parameter exponential smoothing. **International Journal of Production Economics**, v. 181, p. 162-173, 2016.

TUBINO, Dalvio Ferrari. **Planejamento e controle da produção: teoria e prática** – 3.ed. Editora Atlas SA, 2017.

TURRIONI, João Batista; MELLO, Carlos Henrique Pereira. **Metodologia de pesquisa em engenharia de produção: estratégias, métodos e técnicas para condução de pesquisas quantitativas e qualitativas**. Itajubá: Unifei, 2012.

VARGAS, CA González; CORTÉS, M. Elizondo. Automobile spare-parts forecasting: A comparative study of time series methods. **International Journal of Automotive and Mechanical Engineering**, v. 14, p. 3898-3912, 2017.

VEIGA, Claudimar Pereira da; VEIGA, Cássia Rita Pereira da; TORTATO, Ubiratã. Demand forecasting strategies: Understanding the most important concepts. **Revista ESPACIOS| Vol. 37 (Nº 05) Año 2016**, 2016.

WANG, Xun; PETROPOULOS, Fotios. To select or to combine? The inventory performance of model and expert forecasts. **International Journal Of Production Research**, [S.L.], v. 54, n. 17, p. 5271-5282, 28 mar. 2016. Informa UK Limited.  
<http://dx.doi.org/10.1080/00207543.2016.1167983>.

YIN, Jiaming; RAO, Weixiong; YUAN, Mingxuan; ZENG, Jia; ZHAO, Kai; ZHANG, Chenxi; LI, Jiangfeng; ZHAO, Quinpei. Experimental study of multivariate time series forecasting models. In: **Proceedings of the 28th ACM International Conference on Information and Knowledge Management**. 2019. p. 2833-2839.

ZHANG, Guoqiang Peter. Time series forecasting using a hybrid ARIMA and neural network model. **Neurocomputing**, [S.L.], v. 50, p. 159-175, jan. 2003. Elsevier BV.  
[http://dx.doi.org/10.1016/s0925-2312\(01\)00702-0](http://dx.doi.org/10.1016/s0925-2312(01)00702-0).

ZHU, Xiaodan; NINH, Anh; ZHAO, Hui; LIU, Zhenming. Demand forecasting with supply-chain information and machine learning: Evidence in the pharmaceutical industry. **Production and Operations Management**, v. 30, n. 9, p. 3231-3252, 2021.