

CENTRO UNIVERSITÁRIO FEI  
JANDERSON LOPES SILVA

**IMPACTO DO USO DE TÉCNICAS DE APRENDIZADO DE MÁQUINA, *BIG DATA* E VARIÁVEIS CAUSAIS NA GESTÃO DE DEMANDA**

São Bernardo do Campo

2022

JANDERSON LOPES SILVA

**IMPACTO DO USO DE TÉCNICAS DE APRENDIZADO DE MÁQUINA, *BIG DATA* E VARIÁVEIS CAUSAIS NA GESTÃO DE DEMANDA**

Dissertação de Mestrado apresentada ao Centro  
Universitário FEI para obtenção do título de  
Mestre em Engenharia Mecânica com ênfase  
em Produção.

Orientado pelo Prof. Dr. Mauro Sampaio

São Bernardo do Campo

2022

Lopes Silva, Janderson .

IMPACTO DO USO DE TÉCNICAS DE APRENDIZADO DE MÁQUINA, BIG DATA E VARIÁVEIS CAUSAIS NA GESTÃO DE DEMANDA / Janderson Lopes Silva. São Bernardo do Campo, 2022.

72 p. : il.

Dissertação - Centro Universitário FEI.

Orientador: Prof. Dr. Mauro Sampaio.

1. aprendizado de máquina. 2. acuracidade de previsão de demanda. 3. cadeia de suprimentos digital. 4. variáveis causais. 5. Big Data. I. Sampaio, Mauro, orient. II. Título.

Elaborada pelo sistema de geração automática de ficha catalográfica da FEI com os dados fornecidos pelo(a) autor(a).



**Aluno:** Janderson Lopes Silva

**Matrícula:** 220110-1

**Título do Trabalho:** Impacto do uso de técnicas de aprendizado de máquina, big data e variáveis causais na gestão de demanda.

**Área de Concentração:** Produção

**Orientador:** Prof. Dr. Mauro Sampaio

**Data da realização da defesa:** 30/05/2022

**ORIGINAL ASSINADA**

**Avaliação da Banca Examinadora:**

O trabalho atende aos requisitos necessários para a formação do mestre em engenharia.

São Bernardo do Campo,     /     /     .

**MEMBROS DA BANCA EXAMINADORA**

Prof. Dr. Mauro Sampaio

Ass.: \_\_\_\_\_

Prof. Dr. Marcel Heimar Ribeiro Utiyama

Ass.: \_\_\_\_\_

Prof. Dr. Sérgio Ricardo Lourenço

Ass.: \_\_\_\_\_

A Banca Julgadora acima-assinada atribuiu ao aluno o seguinte resultado:

APROVADO

REPROVADO

**VERSÃO FINAL DA DISSERTAÇÃO**

APROVO A VERSÃO FINAL DA DISSERTAÇÃO EM QUE  
FORAM INCLUÍDAS AS RECOMENDAÇÕES DA BANCA  
EXAMINADORA

Aprovação do Coordenador do Programa de Pós-graduação

\_\_\_\_\_  
Prof. Dr. Rodrigo Magnabosco

Dedico esta dissertação aos meus pais que me incentivaram a estudar, à minha família e aos amigos que me apoiaram e estiveram presentes nos momentos de lutas e de glórias.

## **AGRADECIMENTOS**

Primeiramente a Deus, por guiar meus caminhos e tornar realidade cada sonho em conquista.

Ao Centro Universitário FEI, pela oportunidade em fazer mestrado com uma bolsa de estudos integral.

Ao Prof. Dr. Mauro Sampaio, pelo apoio nessa trajetória, pela orientação, paciência, confiança, parceria e pelo conhecimento de estudos que me proporcionou buscar pela excelência como mestre a seu exemplo.

“O sucesso é a soma de pequenos esforços repetidos dia após dia.” (Robert Collier)

## RESUMO

Este trabalho de dissertação tem como principal objetivo avaliar o efeito da utilização de algoritmos de aprendizado de máquina e *Big Data* na acuracidade de previsão de demanda, além de analisar a influência das variáveis causais internas e externas. Para alcançar esse objetivo, realizou-se uma revisão sistemática da literatura com os principais conceitos de gestão de demanda para avaliar os principais métodos, abordagens e fatores relevantes para construção do modelo de planejamento de demanda. Além disso, estudou-se também os principais algoritmos de aprendizado de máquina e *Big Data*, que pudessem melhorar no desempenho do modelo. Após, elaborou-se um procedimento metodológico de estudo de caso em uma empresa do segmento de agronegócio, com coleta e análise de dados da demanda planejada e realizada, dos últimos cinco anos e, na sequência, realizou-se análises quantitativas para validar as hipóteses e análises qualitativas através de entrevistas com os especialistas da área. Ambas análises foram importantes para elaboração final do modelo. Como resultado, obteve-se que a utilização das técnicas de aprendizado de máquina e *Big Data*, melhorou em 37% a acuracidade de previsão de demanda em relação ao método qualitativo de ajuste de julgamento utilizado pela empresa. Além disso, o modelo proposto em 100% dos casos, utilizou de métodos mais robustos e sofisticados de aprendizado de máquina, do que utilizar métodos tradicionais de séries temporais simples. Outro fator importante é que as variáveis causais internas contribuíram em 100% dos casos da família de fungicidas para melhoria do planejamento de demanda e, em contrapartida, as variáveis causas externas apoiou em 50% dos casos, para melhoria desse modelo. Conclui-se, então, que as principais contribuições deste trabalho de pesquisa foram: avaliar o desempenho da acuracidade de previsão de demanda comparando métodos clássicos de séries temporais, com métodos de aprendizado de máquina; verificar as influências das variáveis causais internas e externas nos modelos de previsão de demanda; utilizar software de planejamento de demanda com modelos mais robustos, de fácil utilização e com um rápido tempo de processamento; e por fim, estruturar uma revisão sistemática da literatura, com as pesquisas mais recentes dos estudiosos da área de gestão de demanda e *Supply Chain 4.0*, com intuito de utilizar as melhores pesquisas praticadas no mercado.

Palavras-chave: aprendizado de máquina; acuracidade de previsão de demanda; cadeia de suprimentos digital; variáveis causais; *Big Data*.

## ABSTRACT

The main objective of this dissertation is to evaluate the effect of using machine learning algorithms and Big Data on the accuracy of demand forecasting, in addition to analyzing the influence of internal and external causal variables. To achieve this objective, a systematic review of the literature was carried out with the main concepts of demand chain management to evaluate the main methods, approaches and relevant factors for the construction of the demand planning model. In addition, the main machine learning algorithms and Big Data were also studied, which could improve the performance of the model. Afterwards, a methodological procedure of a case study was elaborated in a company of the agribusiness segment, with collection and analysis of data of the planned and carried out demand, of the last five years and, subsequently, quantitative analyzes were carried out to validate the hypotheses and qualitative analysis through interviews with experts in the field. Both analyzes were important for the final elaboration of the model. As a result, it was found that the use of machine learning and Big Data techniques improved the accuracy of demand forecasting by 37% in relation to the qualitative method of judgment adjustment used by the company. In addition, the proposed model in 100% of cases used more robust and sophisticated machine learning methods than using traditional simple time series methods. Another important factor is that the internal causal variables contributed in 100% of the cases of the fungicide family to improve demand planning and, on the other hand, the external causes variables supported in 50% of the cases to improve this model. It is concluded, then, that the main contributions of this research work were: to evaluate the performance of demand forecast accuracy comparing classical time series methods with machine learning methods; verify the influences of internal and external causal variables on demand forecasting models; use demand planning software with more robust models, easy to use and with a fast processing time; and finally, to structure a systematic review of the literature, with the most recent research from scholars in the area of demand management and Supply Chain 4.0, in order to use the best research practiced in the market.

Keywords: machine learning; demand forecast accuracy; digital supply chain; causal variables; Big data.

## **LISTA DE SIGLAS**

SKU – Stock Keeping Unit

WMAPE - Weighted Mean Absolute Percentage Error

MAPE – Mean Absolute Percentage Error

ML – Machine Learning

QRF - Quantil Random Forecast

GBM - Gradient Boosting Machine

SVM – Support Vector Machine

RMSE - Root Mean Squared Error

ANN - Rede Neural Artificial

SVR – Support Vector Regression

BP - Rede Neural de Retropropagação

MNL - Modelo Lógico Multinomial

SAP IBP – SAP Integrated Business Planning

EY – Ernst & Young

IOT – Internet of Things

## LISTA DE FIGURAS

Figura 1 - Mapa VOSviewer: Keyword “Demand Forecasting” .....	18
Figura 2 - Processo de gestão de demanda .....	21
Figura 3 - Fluxo multiescalão de uma cadeia de suprimentos.....	23
Figura 4 - Framework de compartilhamento de pedidos .....	24
Figura 5 - Publicação anual de artigos .....	36
Figura 6 - % Publicação de artigos .....	36
Figura 7 - % Fonte de Artigos .....	37
Figura 8 - Rank das 15 principais fontes de artigos .....	37
Figura 9 - Framework das tecnologias de aprendizado de máquina e Big Data aplicado na gestão de demanda.....	38
Figura 10 - Perfil de Demanda Fungicida 1 .....	43
Figura 11 - Perfil de Demanda Fungicida 2 .....	44
Figura 12 - Perfil de Demanda Fungicida 3 .....	44
Figura 13 - Perfil de Demanda Fungicida 4 .....	45
Figura 14 - Perfil de Demanda Fungicida 5 .....	45
Figura 15 - Perfil de Demanda Fungicida 8 .....	46
Figura 16 - Variáveis Causais Externas.....	47
Figura 17 - Fluxograma com as etapas da modelagem e simulação dos dados.....	48
Figura 18 - Modelagem dos dados históricos de vendas .....	50
Figura 19 - Gráfico com as previsões do al Perfil de Demanda Fungicida 1 algoritmo de Competição com causal .....	54
Figura 20 - Gráfico com a competição entre os modelos .....	55
Figura 21 - Variáveis causais selecionadas para Família Fungicida 1 .....	55
Figura 22 - Comparativo WMAPE de teste da empresa versus melhor modelo proposto .....	57

## LISTA DE TABELAS

Tabela 1 - Principais Keywords.....	19
Tabela 2 - Artigos selecionados para análise de varredura vertical .....	19
Tabela 3 - Segmento de produtos .....	42
Tabela 4 - Característica da Família Fungicida .....	42
Tabela 5 - Comparativo anual das vendas da família de fungicida .....	43
Tabela 6 - Parâmetros da amostra de treino e teste .....	49
Tabela 7 - Modelos utilizados para análise e modelagem dos dados .....	51
Tabela 8 – Tipos de modelos Clássicos versus aprendizado de máquina .....	52
Tabela 9 - Algoritmos modelados sem a influência das variáveis causais externas.....	53
Tabela 10 - Algoritmos modelados com a influência das variáveis causais externas .....	53
Tabela 11 - Análise ponderada da Família Fungicida .....	56
Tabela 12 - Comparativo WMAPE de teste da empresa X melhor modelo proposto.....	56

## SUMÁRIO

<b>1 INTRODUÇÃO</b> .....	<b>14</b>
1.1 FORMULAÇÃO DO PROBLEMA E PERGUNTA DE PESQUISA.....	15
1.2 OBJETIVO.....	15
<b>1.2.1 Objetivo Geral</b> .....	16
<b>1.2.2 Objetivos Específicos</b> .....	16
1.3 RELEVÂNCIA E JUSTIFICATIVA DA PESQUISA.....	16
<b>2 REVISÃO SISTEMÁTICA DA LITERATURA</b> .....	<b>18</b>
2.1 GESTÃO DE DEMANDA.....	20
<b>2.1.1 Tipos de abordagens para previsão de demanda</b> .....	24
<b>2.1.2 Métodos de previsão de demanda</b> .....	25
<b>2.1.3 Métodos para comparação de modelos de previsão de demanda</b> .....	27
<b>2.1.4 Fatores que impactam a previsão de demanda</b> .....	28
<b>2.1.5 Desafios e limitações na gestão de demanda</b> .....	29
<b>2.1.6 Benefícios da gestão de demanda</b> .....	30
2.2 TECNOLOGIAS DO <i>SUPPLY CHAIN 4.0</i> .....	31
<b>2.2.1 Big Data</b> .....	34
<b>2.2.2 Aprendizado de máquina</b> .....	35
2.3 ANÁLISE E DISCUSSÕES DA REVISÃO SISTEMÁTICA DA LITERATURA.....	35
<b>2.3.1 Análise Bibliométrica</b> .....	36
<b>2.3.2 Framework</b> .....	38
<b>3 PROCEDIMENTOS METODOLÓGICOS</b> .....	<b>40</b>
3.1 METODOLOGIA APLICADA NO ESTUDO DE CASO.....	41
<b>3.1.1 Planejamento</b> .....	41
<b>3.1.2 Diagnóstico</b> .....	42
<b>3.1.3 Modelagem e Simulação</b> .....	48
<b>4 ANÁLISE DOS RESULTADOS</b> .....	<b>53</b>
<b>5 DISCUSSÃO DOS RESULTADOS</b> .....	<b>58</b>
<b>6 CONCLUSÃO</b> .....	<b>59</b>
<b>REFERÊNCIAS</b> .....	<b>62</b>
<b>APÊNDICE A - TABELA RESUMO DO PERFIL DE DEMANDA DE CADA FUNGICIDA</b> .....	<b>69</b>
<b>APÊNDICE B - TABELA DE RESULTADOS DE CADA MODELO PROPOSTO</b> ....	<b>71</b>

## 1 INTRODUÇÃO

Com o recente contexto global da pandemia do COVID - 19, as cadeias de suprimentos tiveram que enfrentar vários desafios nos processos gerenciais desde o planejamento de compras até vendas, tais como: entendimento de quais fatores a COVID - 19 impactaria no atendimento da demanda, elaboração de um planejamento de demanda adequado, de modo à evitar o excesso de estoques nos armazéns, revisão da política de estoque e análise dos impactos da pandemia em todos os elos da cadeia de suprimentos desde as fábricas até consumidor final.

De acordo com Fildes et al (2009), a previsão de demanda é um aspecto crucial no processo de planejamento, pois afeta toda a cadeia de suprimentos. A abordagem mais comum para a previsão de demanda nessas empresas envolve o uso de um programa computacional para elaborar previsões iniciais com métodos de séries temporais mais simples para, posteriormente, aplicar a técnica de ajuste por julgamento pelos planejadores de demanda da empresa e, desse modo, levar em conta situações e eventos que são esperados no modelo ao longo do horizonte de planejamento.

A literatura fornece dois argumentos para a adoção da gestão de demanda. Em primeiro lugar, para se obter maior acesso a novos mercados, a aplicação dessa área permite que a empresa alcance real vantagem competitiva, satisfazendo os requisitos estabelecidos pelos clientes. E em segundo lugar, a coordenação da gestão de demanda reduz a variabilidade e eliminam atividades que não agregam valor (VOLLMANN ET AL, 2000).

Ademais, para Croxton et al (2002), o planejamento de demanda em um nível estratégico pode ter dois resultados importantes para responder aos principais questionamentos da empresa ou aumentar a flexibilidade do sistema produtivo da cadeia de suprimentos para atender à demanda ou aperfeiçoar os métodos de previsão de demanda para reduzir os erros de previsão.

O uso de *softwares* computacionais para análise de demanda ainda é limitado e as técnicas de aprendizado de máquina, também conhecida como *Machine Learning* (ML), são pouco utilizadas para estimar a demanda. Além de tudo, há poucas pesquisas práticas que relacionam a previsão de demanda com estudos de variáveis causais, que podem ser aplicados para verificar o impacto que esta variável pode causar nos modelos de planejamento de demanda (FILDES, MA E KOLASSA, 2019).

Além disso, os principais desafios encontrados na literatura relacionados à gestão de demanda são:

- a) obtenção de informação compartilhada na cadeia de suprimentos;
- b) obtenção de histórico de dados confiáveis e precisos;
- c) melhoria da acuracidade de previsão de demanda;
- d) análise dos parâmetros que são sensíveis ao planejamento de demanda;
- e) previsão de demanda com um portfólio de produto com maior variabilidade;
- f) análise dos impactos de variáveis como: volatilidade de preços, promoção e estudos econométricos;
- g) utilização de tecnologias computacionais que sejam capazes de identificar e melhorar a acuracidade de previsão de demanda, utilizando inteligência artificial e aprendizado de máquina.

Os desafios encontrados na literatura na área de gestão de demanda possibilitaram, nesta dissertação, a apresentação de técnicas mais sofisticadas de previsão de demanda utilizando algoritmos de aprendizado de máquina, a utilização do *Big Data* como fonte para análise de variáveis causais externas e internas que podem influenciar no setor de agronegócio, a utilização de *softwares* computacionais de fácil uso e modelagem de dados.

## 1.1 FORMULAÇÃO DO PROBLEMA E PERGUNTA DE PESQUISA

Com base na literatura e entrevistas com especialistas da área, identificou-se como problema de pesquisa, a falta do uso de técnicas de séries temporais sofisticadas, ausência da utilização de técnicas quantitativas, pouca utilização de *software* computacional e análises de variáveis causais que afetam a previsão de demanda.

O presente trabalho visa responder às seguintes perguntas para alcançar o objetivo da pesquisa:

Q1: Qual o impacto na utilização de técnicas de aprendizado de máquina e *Big Data* na previsão de demanda?

Q2: Existem diferenças entre as técnicas tradicionais de séries temporais *versus* técnicas de aprendizado de máquina?

Q3: Qual a influência da utilização de variáveis causais na previsão de demanda?

## 1.2 OBJETIVO

Nas seções a seguir serão descritos o principal objetivo desta dissertação, bem como os objetivos específicos na intenção de esclarecer o que foi pesquisado no decorrer do projeto.

### 1.2.1 Objetivo Geral

Analisar o desempenho da acuracidade de previsão de demanda no ramo da indústria de agronegócio, avaliando os impactos na utilização de técnicas de aprendizado de máquina e *Big Data*, analisando também, a influência das variáveis causais internas e externas, na acuracidade de previsão de demanda.

### 1.2.2 Objetivos Específicos

O presente trabalho tem como objetivos específicos:

- a) determinar os parâmetros computacionais utilizados para modelagem e simulação dos dados;
- b) estabelecer as técnicas de previsão de demanda que serão abordadas na modelagem para competição entre modelos;
- c) definir métricas para avaliar o desempenho da acuracidade de previsão de demanda;
- d) identificar as variáveis causais externas que podem influenciar no modelo.

## 1.3 RELEVÂNCIA E JUSTIFICATIVA DA PESQUISA

As técnicas de séries temporais e uso de métodos estatísticos são as mais exploradas na literatura para aplicação de estudos de caso, pois são técnicas que necessitam dos históricos de banco de dados para gerar bons resultados, além de serem técnicas utilizadas para modelos lineares, que são modelos que utilizam as técnicas de séries temporais mais simples e sem análise de variáveis causais (HUANG e LIU, 2017). Estudos recentes utilizam métodos multivariados que consistem em um conjunto de modelos envolvendo séries temporais, aprendizado de máquina e variáveis não lineares com o intuito de prever uma melhor acuracidade de previsão de demanda.

Ainda, de acordo com Huang e Liu (2017), esse método multivariado é uma técnica que tem despertado interesse nos pesquisadores e profissionais da área, pois combinam fatores importantes a serem considerados em uma previsão de demanda, tais como: preço, promoção, grandes eventos e feriados nacionais.

A previsão de demanda é uma área de pesquisa ativa, que se tornará ainda mais importante no futuro, principalmente com o desenvolvimento de novos algoritmos de previsão e uso de tecnologias como *Big Data* (KOLASSA, 2016).

Além disso, a utilização de variáveis causais na gestão de demanda pode melhorar significativamente a acuracidade de previsão de demanda. Um exemplo disso é o que Gosling

e Ballard (2019) descreveram sobre a região metropolitana de Baltimore-Washington que possibilitou uma maior elasticidade na previsão da demanda ao recorrerem às variáveis socioeconômicas, tais como: distribuição de renda familiar, número de população, tarifa média da passagem aérea e o número de pessoas empregadas.

O estudo desenvolvido por Krishna (2021) também relata a utilização de variáveis causais relacionadas com parâmetros de mobilidade e clima para identificar o aumento de casos de COVID-19 nas principais cidades indianas. O resultado desse estudo ajudou o governo a prever os locais mais propícios ao foco do vírus e criar medidas de isolamento mais restritas para a população. E por fim, segundo Staudt, Gonçalves e Rodriguez (2016), os métodos de previsão combinado são pouco explorados na literatura, o que contribui para o estado da arte, relacionar essas novas técnicas com à gestão de demanda.

O presente trabalho está estruturado em seis capítulos. O capítulo 1 é a introdução na qual destaca a formulação do problema, as questões de pesquisa, os objetivos geral e específicos e a relevância da pesquisa. O capítulo 2 contém a revisão literária, no qual serão apresentados a metodologia utilizada para a busca dos principais artigos, introdução sobre os conceitos chaves de gestão de demanda e tecnologias do *Supply Chain 4.0*, e por fim, uma análise bibliográfica e elaboração de *framework*. O capítulo 3 descreve o procedimento metodológico da dissertação, com foco na abordagem quantitativa. O capítulo 4 resulta nas análises quantitativas do estudo de caso. Por conseguinte, o capítulo 5 apresenta as discussões das análises dos resultados, e, por último, o capítulo 6, a conclusão final da dissertação, bem como pesquisas futuras e limitações de pesquisa.



temporais, análises regressão simples e múltipla, e por fim, “*Supply Chain 4.0*” ou “*Digital Supply Chain*”, que estão relacionados com *Big Data*, aprendizado de máquina, redes neurais e inteligência artificial.

Tabela 1 - Principais Keywords

Tema de Pesquisa	Número de Artigos	
	Scopus	Web of Science
Supply Chain Management	9.438	5.964
Demand Planning OR Demand Forecasting	1.141	920
Demand Chain Management OR Demand Supply Chain	1.117	1.017
Forecast Accuracy	1.374	1.217
Supply Chain 4.0 OR Digital Supply Chain	74	35

Autor, 2021.

Utilizou-se como base de dados nessa etapa e nas seguintes somente *SCOPUS*. Após a procura de cada palavra-chave, realizou-se um filtro com o período de publicação compreendido entre 2016 e 2021, ressaltando nesta dissertação, os trabalhos de pesquisa de estudiosos mais recentes e modernos de gestão de demanda. Depois, filtrou-se o tipo de documento para selecionar somente os artigos. Posteriormente, analisou-se em ordem decrescente os artigos mais citados por outros autores, resultando no total de 304 artigos, conforme Tabela 2.

Após a etapa de busca dos 304 artigos, realizou-se uma análise de varredura horizontal, que consiste na leitura rápida dos títulos, resumos e introdução. Utilizou-se como critério para essa seleção, os artigos mais relevantes ao tema de pesquisa, selecionando um total de 100 artigos, conforme evidenciado na Tabela 2.

Tabela 2 - Artigos selecionados para análise de varredura vertical

KeyWords	Total de artigos base Scopus	Qtde de Artigos Selecionados	Qtde Leitura Completa
Retail Forecast	14	6	5
Strategic Supply Chain Planning	11	4	2
Forecast Accuracy AND Demand Planning	6	7	6
Forecast Accuracy AND Supply Chain	42	11	9
Forecast Accuracy AND Demand Forecasting	59	20	11
Digital Supply Chain AND Demand OR Forecast	10	2	2
Industry 4.0 AND Forecast	38	3	2
Supply Chain 4.0 OR Digital Supply Chain	74	17	15
Artigos já lidos no pré projeto	50	30	18
<b>Total</b>	<b>304</b>	<b>100</b>	<b>70</b>

Autor, 2021

E por último, realizou-se a análise de varredura vertical, que consiste na leitura completa dos artigos, totalizando assim, 70 artigos selecionados para essa revisão sistemática da literatura.

Na próxima seção, serão apresentados os principais estudos encontrados nessa literatura dos autores mais contemporâneos em relação à gestão de demanda e tecnologias de *Supply Chain 4.0*, apresentando os principais conceitos, opiniões e interpretações de cada tema

explorado, quais estudos estão sendo utilizados nos últimos anos, quais as vantagens e os desafios diagnosticados por estes autores.

## 2.1 GESTÃO DE DEMANDA

A gestão de demanda surge na área de conhecimento da gestão da cadeia de suprimentos e de marketing, na qual busca-se uma rápida e adequada integração das necessidades originadas do mercado na direção dos fornecedores, de modo a balancear e alinhar estrategicamente a demanda com a capacidade operacional ao longo da cadeia de suprimentos (MELO e ALCÂNTARA, 2011).

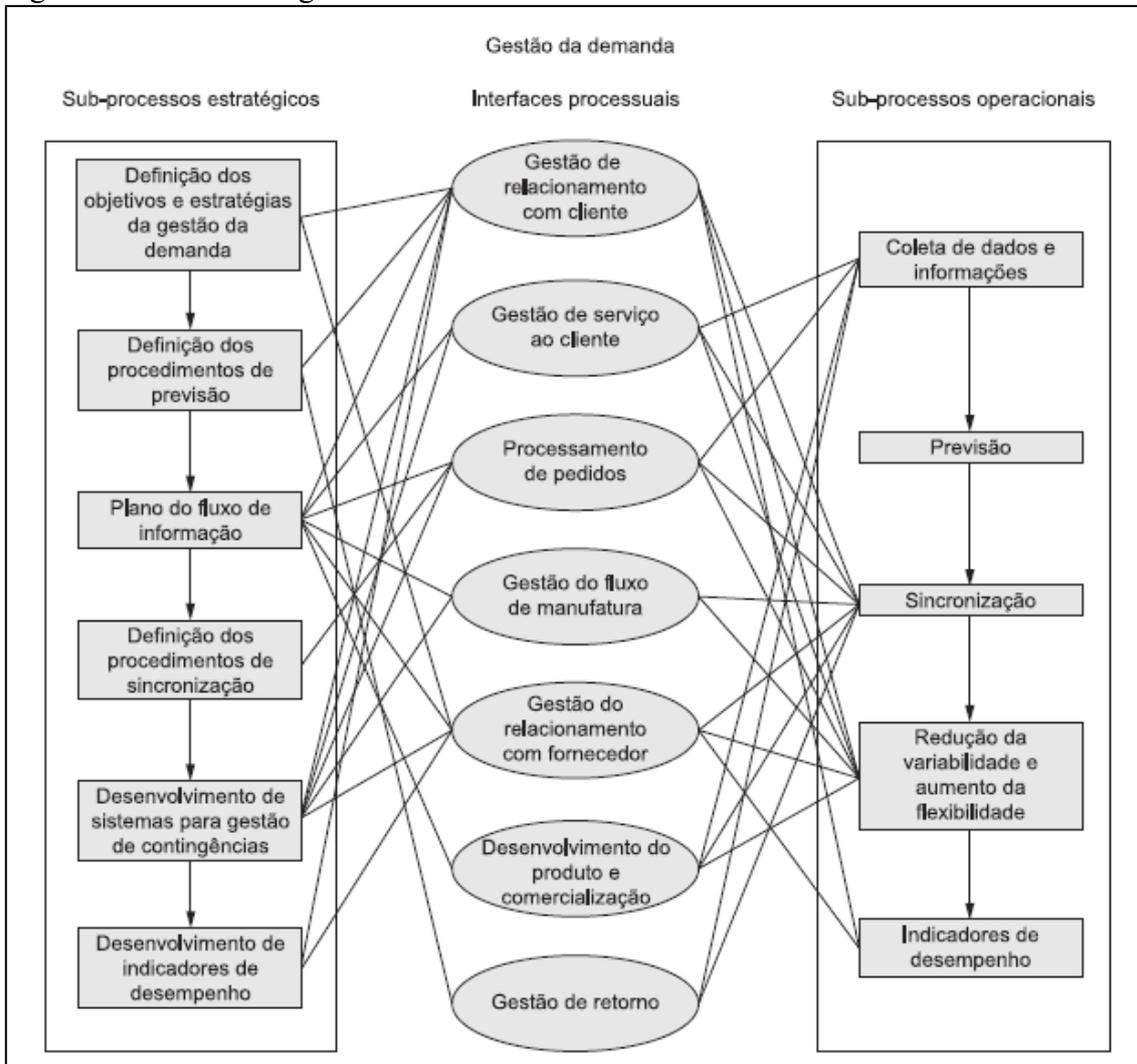
De acordo com Zhang, Dan e Zhou (2019) e Wang, Liu e Zhao (2019), a gestão de demanda se tornou uma fonte de informação vital para organizações, pois desempenha estratégias importantes em toda a cadeia de suprimentos, afetando nos preços, nas estratégias de crescimento do negócio, nos tipos de tomadas de decisão, no gerenciamento da cadeia de suprimentos, no planejamento da distribuição, na programação e controle de produção, no gerenciamento de níveis de estoque e no nível de serviço e eficiência operacional.

Fildes et al (2009) e Julianelli (2004) destacam em seus artigos que a previsão de demanda é um aspecto essencial do processo de planejamento nas empresas, pois desempenha papel de grande importância no planejamento e coordenação dos fluxos de informação e de produtos físicos de uma organização, tendo impactos relevantes nas áreas de marketing, programação e controle da produção, operações logísticas e nas decisões de planejamento da capacidade das instalações.

Para Bergman et al (2017), a previsão de demanda também é crucial para o gerenciamento de estoque, pois se a estimativa da demanda for imprecisa poderá acarretar em produtos sobressalentes, gerando um custo de armazenagem devido ao tempo de inatividade, principalmente se estiver relacionado com demandas intermitentes que criam mais dificuldades para os métodos tradicionais estatísticos em prever a demanda. Desse modo, muitas organizações utilizam *softwares* capazes de otimizar essas restrições com a finalidade de minimizar as incertezas das demandas, e conseqüentemente, possa reduzir seus estoques (BECK; ANZANELLO, 2015).

De acordo com Croxton et al (2002), o processo de gestão de demanda consiste no conjunto de subprocessos operacionais e estratégicos que tem como principal objetivo determinar a previsão de vendas, sincronizando-as com a capacidade produtiva e restrições da empresa e da cadeia, incorporando as estratégias da organização para atender às necessidades dos seus consumidores, conforme evidenciado na Figura 2.

Figura 2 - Processo de gestão de demanda



Fonte: Croxton et al, 2002.

Para Lambert (2007), a gestão de demanda é o processo de gerenciamento da cadeia de suprimentos que equilibra a demanda dos clientes com as capacidades operacionais. Além disso, o processo de gestão de demanda não se limita a previsão de demanda, como também deve ser considerado na sincronização da oferta e demanda, reduzindo a variabilidade e aumentando a flexibilidade.

Segundo Mentzer et al (2001), a gestão de demanda é a criação de um fluxo coordenado entre os membros da cadeia de suprimentos e seus mercados, na qual envolve todos os parceiros, com o objetivo de alcançar um melhor desempenho.

A gestão de demanda é um processo de gerenciamento da cadeia de suprimentos que compreende várias etapas no desenvolvimento de previsões confiáveis, atendendo às expectativas do cliente, no prazo adequado, com a quantidade de produto certa, no lugar certo,

na hora certa e com preço certo, melhorando a lucratividade de um canal ou item de produto específico (BASSON, KILBOURN E WALTERS, 2019).

Dentre as quatro definições sobre gestão de demanda apresentadas acima, o presente trabalho se assemelha mais com as definições propostas por Croxton et al (2002) e Lambert (2007), na qual equilibra a demanda com as capacidades operacionais e restrições da cadeia, sincronizando a oferta e a demanda para atender seus consumidores finais.

A gestão de demanda tem como objetivo entender, influenciar e gerenciar a demanda dos consumidores, alcançando resposta rápida em toda a cadeia de suprimentos, na qual necessita de um time multifuncional composto por integrantes de diversos níveis e setores da organização tais como: marketing, finanças, produção, compras e logística (CROXTON, ET AL 2002).

De acordo com Seaman (2018), há dois termos importantes a serem considerados no planejamento de demanda. O primeiro consiste na previsão de vendas baseada nos históricos de um determinado produto, ou seja, não é referente à falta de estoques, e sim referente às vendas efetivamente realizadas. O segundo refere-se a previsão de demanda que consiste no planejamento de vendas futuras independentemente se houve ruptura de estoque. Entretanto, ambos os conceitos têm o objetivo de atender ou exceder aos objetivos do negócio.

Com o objetivo de reduzir o erro de previsão de demanda e apoiar no processo de tomada de decisões sob a ótica de planejamento estratégico, Dreyer et al (2018), relata cinco passos à serem seguidos, para ter um planejamento de demanda bem alinhado e coordenado, são eles:

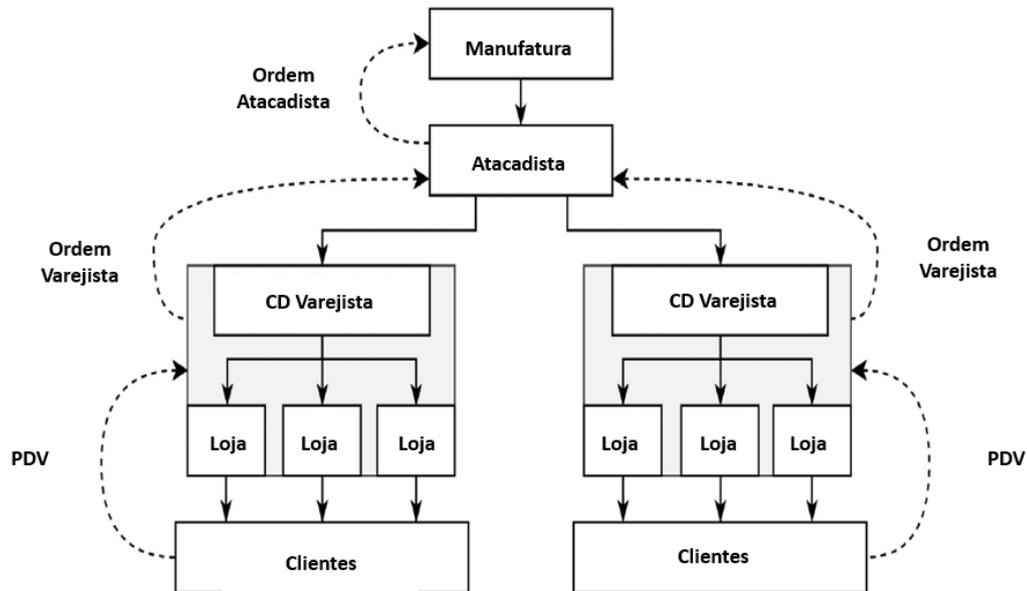
- a) coleta e análise de dados a nível SKU para prever a demanda;
- b) consolidação de um plano de demanda irrestrita;
- c) consideração das restrições e capacidades do negócio;
- d) estabelecimento de um plano de contingência, equilibrando a oferta e demanda;
- e) apresentação do planejamento de demanda e revisão junto com o comitê executivo formado pelas áreas comerciais, *marketing* e *Supply Chain*.

Conforme Van Belle, Guns e Verbeke (2021), o fluxo de informações e atividades na cadeia de suprimentos podem ser *downstream* ou *upstream*. O primeiro ocorre quando o fluxo de atividades dessa organização está mais próximo do consumidor final. Já a cadeia *upstream* ocorre quando o fluxo de atividades da referida organização está mais próximo do fornecedor de matéria-prima.

Em uma cadeia de suprimentos de multiescalão que contém tanto uma cadeia *downstream* quanto *upstream*, o fabricante utiliza as informações de pedidos de um atacadista, que, por sua

vez, utiliza as informações de pedido de um varejista e, este último, utiliza dados de pontos de vendas do consumidor final, conforme Figura 3. Se o planejamento da demanda não for bem elaborado pode haver uma propagação de erros em toda a cadeia de suprimentos, ocasionando o efeito chicote, na qual prejudica a previsão de demanda e gera ineficiências em toda a cadeia de suprimentos (VAN BELLE, GUNS e VERBEKE, 2021).

Figura 3 - Fluxo multiescalão de uma cadeia de suprimentos



Fonte: Van Belle, Guns e Verbeck, 2021.

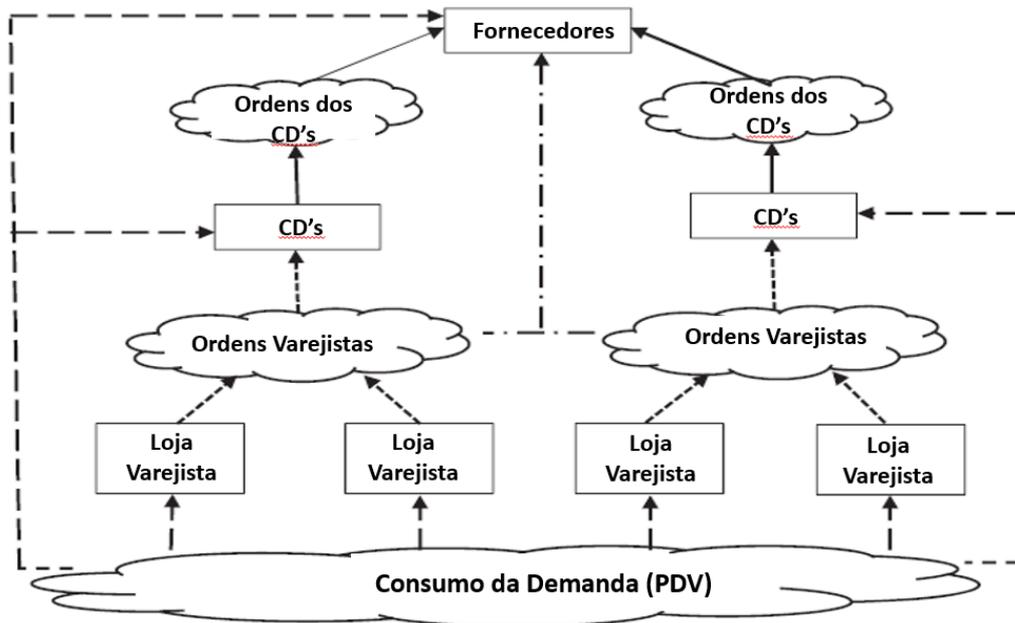
Chiang, Lin e Suresh (2016) definem o efeito chicote como a razão entre a variação da previsão de pedido pela variação da demanda realizada. Ademais, o efeito chicote reduz a lucratividade de toda a cadeia de suprimentos, aumenta o nível de estoque devido às incertezas da demanda e prejudica o nível de atendimento de serviço do cliente.

Ainda, de acordo com Hartzel e Wood (2017) e Hofmann e Rutschmann (2018), o efeito chicote consiste na propagação de erros na medida que é transmitida pelos elos da cadeia de suprimentos. As ineficiências do efeito chicote resultam em: dificuldade no planejamento de produção, datas de entregas perdidas, nível de atendimento ao cliente comprometido, assimetria de informações e custos emergenciais para disponibilizar o produto imediatamente ao cliente.

Narayanan, Sahim e Robinson (2019), relatam que a precisão para o planejamento da demanda dos fornecedores e distribuidores melhora quando se tem informações de dados de ponto de vendas ao invés de dados de histórico de pedidos. Os fornecedores, geralmente, têm uma fonte de dados para prever a demanda dos seus distribuidores, que por sua vez, tem como fonte de dados os varejistas, e estes têm como fonte de dados o consumidor final (PDV). No entanto, se houver o compartilhamento das informações, tanto os fornecedores como

distribuidores também poderão escolher ter acesso ao PDV (conforme evidenciado na Figura 4), reduzindo o efeito chicote entre a cadeia de suprimentos.

Figura 4 - Framework de compartilhamento de pedidos



Fonte: Narayanan, Sahim e Robinson, 2019.

A previsão de demanda é uma entrada de dados muito importante para gerenciamento dos estoques, pois as flutuações de pedidos encarecem o custo das operações da cadeia de suprimentos, induzindo ao *tradeoff* entre o custo de manutenção de estoque e o custo de colocação de pedido. Além disso, as flutuações de pedidos aumentam a variabilidade de demanda dos fornecedores e, conseqüentemente, traz ineficiências para toda a cadeia de suprimentos (WANG e PETROPOULOS, 2016).

O processo de planejamento de demanda deve conter, segundo Cassettari, et al (2017):

- a) uma base de previsão de demanda confiável e precisa;
- b) capacidade analítica dos especialistas da empresa em perceber os sinais de demanda externos como: fatores políticos, econômicos, sociais, ambientais;
- c) capacidade dos especialistas da área em ter uma boa percepção do mercado para ajustarem a demanda, quando necessário;
- d) disponibilidade de metodologias para melhoria contínua na precisão de previsão de demanda.

### 2.1.1 Tipos de abordagens para previsão de demanda

De acordo com Fildes, Ma e Kolassa (2019), existem três abordagens que podem ser

utilizadas para o cálculo da previsão de demanda que são: *Bottom-Up*, *Top-Down* e Combinação Hierárquica. A abordagem *Top-Down* consiste em realizar a previsão de demanda considerando um nível agregado por família de produto, hierarquia de produto, região ou clusterização de produto. Após ter uma previsão consolidada, desagrega-se do nível de detalhe do produto e da localidade, utilizando o percentual de histórico de vendas para fazer o rateio (JULIANELLI, 2004).

Elaborar um planejamento de demanda *Top-Down* reduz a complexidade do modelo e reduz a incerteza quando há grandes flutuações da demanda, devido ao grande número de produtos heterogêneos, com várias lojas de varejo, o que é muito comum em cadeias *downstream* como varejistas e atacadistas (DREYER ET AL, 2018).

A abordagem *Bottom-Up*, segundo Julianelli (2004), consiste em realizar a previsão de demanda do nível de SKU e da localidade de produto e, posteriormente, é agregado a nível de família e/ou regiões, empregado em cadeias *upstreams*, como por exemplo, fornecedores de matéria-prima, que têm um portfólio menor de SKU's.

E por fim, segundo Fildes, Ma e Kolassa (2019), existe um terceiro método chamado de Combinação Hierárquica, no qual constitui num modelo híbrido, responsável, primeiramente, em gerar séries temporais por hierarquias de produto separadas e, posteriormente, em combinar essas hierarquias utilizando algoritmos de transformação linear.

### 2.1.2 Métodos de previsão de demanda

Na literatura, há três tipos de métodos utilizados para prever a demanda, sendo o primeiro, o método qualitativo que envolve “*feeling*”, “*insights*”, opiniões, julgamentos e análise técnica de especialistas em previsão de demanda, na qual utilizam da percepção humana para identificar e corrigir todos os pontos de anomalias que afetam a demanda irrestrita. Este método geralmente é utilizado quando a demanda é sensível à promoção de vendas, como por exemplo, nas campanhas de *Black Friday*.

De acordo com Bergman et al (2017), o método de previsão de análise por julgamento é proposto por opiniões de especialistas e é muito comum na prática quando pouco ou nenhum dado histórico está disponível, quando os modelos de estatística não podem exibir efeitos de eventos especiais, que podem influenciar a demanda futura, ou quando os especialistas têm uma falta de compreensão dos métodos estatísticos.

A técnica de ajuste por julgamento pode ser apresentada por três modos. O primeiro modo baseia-se no ajuste sem contexto, no qual, o especialista utiliza da sua experiência e expertise para ajustar a previsão de demanda, pois não consegue associar com nenhuma

informação contextual. O segundo modo é o ajuste contextual, no qual, o especialista ajusta a previsão de acordo com alguma informação extra que recebe, como por exemplo, campanhas, promoções, eventos esporádicos do time comercial. E por fim, o modo estruturado, que consiste na aplicação de métodos empíricos que ajustam a demanda sem que haja uma imparcialidade, como por exemplo, tratamento de *outliers* (STAUDT, GONÇALVES e RODRIGUEZ, 2016).

O ajuste de julgamento só deve ser realizado quando, há algum evento específico que possa alterar a previsão, no qual, estatisticamente o modelo não considera possíveis *outliers* que afetam a previsão. Ademais, para que seja realizado o ajuste, as informações dos eventos como, descontos e promoções devem ser confiáveis, para que assim, possam melhorar a previsão de demanda. As previsões de análises por julgamento têm um viés tendencioso, nas quais, podem ser otimistas ou pessimistas. (FILDES ET AL, 2009; STAUDT, GONÇALVES e RODRIGUEZ, 2016).

O segundo método é o quantitativo, que é baseado em cálculos e modelos matemáticos, através de dados históricos e variáveis causais. Os mais utilizados são: séries temporais, modelo de regressão, ARIMA, SARIMA, rede neural artificial (ANN), vetor de suporte de regressão (SVR), rede neural de retropropagação (BP), programação genética e modelo lógico multinomial (MNL).

As séries temporais mais utilizadas para previsão de demanda são: média móvel simples, exponencial simples, exponencial dupla, média móvel dupla, sazonalidade aditiva, sazonalidade multiplicativa, *Holt-Winters* aditivo, *Holt-Winters* multiplicativo, ARIMA e SARIMA (PRADITA ET AL, 2020).

De acordo com Ni e Fan (2011), os modelos de previsão por média móvel, suavização exponencial, análise de tendência e regressão linear são modelos de algoritmos simples e de fácil compreensão, entretanto, necessita-se de uma análise massiva de dados e com fatores lineares. São modelos que não atendem às necessidades de um mercado varejista, pois possuem fatores não lineares, como fatores climáticos, elasticidade de preço e estratégia de mercado. Neste caso, para ser mais assertivo, recomenda-se empregar técnicas com o uso de aprendizado de máquina e algoritmos de inteligência artificial, capazes de processar relações não lineares para modelar melhor a demanda específica de cada produto.

Além disso, segundo Van Belle, Guns e Verbeke (2021), os métodos quantitativos de previsão de demanda podem ser divididos em dois subgrupos, métodos extrapolativos e métodos explicativos. Os métodos extrapolativos envolvem modelos de séries temporais que utilizam dados históricos para prever a demanda futura que se utiliza de média móvel, suavização exponencial simples, métodos de *Holt*, método de *Winters*. Já os métodos

explicativos levam em consideração as relações entre a variável prevista com outras variáveis causais e fatores externos, que servem para explicar e/ou melhorar o modelo inicial de previsão de demanda que se utilizam de técnicas como aprendizado de máquina, redes neurais, árvores de decisão e análise de regressão com rede neural.

O terceiro e último método consiste em um modelo híbrido que combina os métodos qualitativos e quantitativos (HOFMANN E RUTSCHMANN, 2018; PRADITA ET AL, 2020).

Uma das abordagens mais comuns para melhorar a acuracidade de previsão de demanda é o uso do modelo híbrido que consiste na utilização de *software* estatístico para cálculo da previsão de demanda associado ao uso da técnica de ajuste por julgamento pelos planejadores de demanda, para levar em consideração circunstâncias excepcionais diagnosticadas ao longo do horizonte de planejamento ou até mesmo corrigir previsões inadequadas (FILDES ET AL, 2009).

### **2.1.3 Métodos para comparação de modelos de previsão de demanda**

De acordo com Seaman (2018), os principais métodos para comparar os modelos de previsão de demanda são:

a) métricas de erro: servem para quantificar acuracidade da previsão de demanda, sendo que a mais comum é o cálculo do erro percentual absoluto médio (MAPE) e erro quadrático médio (RMSE). Há também outras variações do MAPE, como WMAPE, que é um erro percentual absoluto médio ponderado baseado pelo volume ou receitas de vendas.

b) métricas de tendência: mede o viés da previsão de demanda, também conhecido como BIAS, que pode ser tendencioso para baixo, ocasionando ruptura de estoque, ou tendencioso para cima, causando estoque em excesso.

c) métricas de volatilidade: medem o quanto a demanda pode variar de acordo com aplicações de novas previsões, podendo ser analisadas pelo horizonte de planejamento diário, semanal ou mensal.

Murray, Agard e Barajas (2018) descrevem também que o MAPE é uma medida adequada para comparar séries temporais, entretanto, fornece resultados tendenciosos quando a demanda real se aproxima de zero, resultando em valores infinitos que distorcem a precisão do modelo e não dimensiona a contribuição de dados de diferentes magnitudes. Por outro lado, RMSE dimensiona bem a contribuição de dados de diferentes magnitudes, porém, não é um bom método para comparar a precisão de outros modelos de previsão de demanda.

A vantagem em utilizar o MAPE é que permite comparações entre vários modelos de

previsões de demanda, com diferentes séries de dados, porém é necessário ter um grande volume de dados (BASSON, KILBOURN e WALTERS, 2019).

#### **2.1.4 Fatores que impactam a previsão de demanda**

Prever a demanda futura é uma atividade complexa, pois depende de fatores internos (gama de produtos oferecidos, reabastecimento de produtos, ciclo de vida, marketing, vida útil, *lead time* de fornecedores, entrega ao cliente, nível de serviço) e fatores externos (tipo de mercado e características, nível de tempo de serviço e entrega, empresas concorrentes, macroeconomia, desastres naturais, política governamental e regulamentações) para fazer um bom planejamento de demanda (CASSETTARI ET AL, 2017 e PRADITA ET AL 2020).

Belvedere e Goodwin (2017) relatam que os fatores externos, tais como variáveis macroeconômicas, estratégias de marketing e estratégias do varejo, não são levados em consideração pelos especialistas em planejamento de demanda quando fazem as previsões.

Segundo Seaman (2018), os fatores que mais impactam na previsão de demanda são o preço e reabastecimento de estoque, pois preços muito altos direcionarão os clientes ao poder de barganha com a concorrência, fazendo-os migrarem para concorrência, caso o preço seja menor. Em contrapartida, preços muito baixos podem prejudicar os aspectos econômicos e financeiros da organização.

Outro ponto importante, é o fator de elasticidade entre preço e demanda que influencia na tomada de decisão. Para empresas do ramo de varejo são adotadas duas estratégias: A primeira consiste em preços baixos diariamente com leves oscilações e a segunda consiste em preços alto, na qual aplica-se uma política de promoção por um curto intervalo de tempo, para itens de portfólios com preços mais altos, o que interfere diretamente no planejamento da demanda e, conseqüentemente, na gestão de inventário. (SEAMAN, 2018). Ou seja, a variável preço interfere no estoque, receita, lucro, demanda e posicionamento no mercado

Já em relação ao reabastecimento de estoque, Seaman (2018) relata que também é um ponto crítico, pois tem o objetivo de atender a um determinado nível de serviço de forma a evitar excessos de estoques desnecessários. Para chegar nesta análise, é importante observar o equilíbrio entre o custo de manutenção de estoque e o custo de pedido.

Para Ni e Fan (2011), Huang e Liu (2017), no horizonte de planejamento de longo prazo, os fatores de sazonalidade, clima e região são os que mais influenciam na previsão de demanda, e no horizonte de planejamento de curto prazo, os fatores mais influenciáveis são: feriado, promoção e preço.

O clima envolve as características de pressão do ar, temperatura do ar, umidade

relativa, pressão de vapor, direção e velocidade do vento, precipitação; o feriado envolve características de grandes eventos como Páscoa, Natal, Ano Novo, Dia dos Pais, Dia das Mães; a promoção pode estar relacionada a anúncios, propagandas, descontos, cupons presentes; a região pode ser associada a regiões com alto poder econômico, cultura e tradições. A política de preço pode variar conforme a lei de oferta e procura. Por fim, a sazonalidade pode estar associada a baixa e alta temporada de consumo ao longo dos anos ou pelas estações do ano (NI e FAN, 2011).

Segundo Melo e Alcântara (2011), um outro fator estratégico a ser considerado na previsão de demanda a longo prazo, são os 4 P's da estratégia de marketing, relacionados com preço, praça, produto e promoção, que impactam nos tempos de entrega, nos custos da cadeia de suprimentos, na rentabilidade do produto e estoques.

Por último, de acordo com Hofmann e Rutschmann (2018), os fatores que afetam a demanda podem ser divididos em seis categorias, são elas:

- a) produto: em termos de qualidade, preços, concorrência e produtos substitutos;
- b) preferências do consumidor: em relação a moda e tendências de mercado, comportamento de compra, consciência e percepção da marca;
- c) fatores externos: como por exemplo, clima, eventos especiais, feriados, sazonalidade, desenvolvimento local, nível de renda, perspectiva econômica;
- d) fatores de marketing: como promoções, publicidade e propaganda;
- e) fatores da loja: em relação a competição local, atratividade da loja, variedade de produtos e *layout* da loja;
- f) fatores de oferta: em termos de disponibilidade de produto e produtos a vencer.

### **2.1.5 Desafios e limitações na gestão de demanda**

De acordo com Melo e Alcântara (2011), os principais desafios enfrentados na gestão de demanda são: a falta de precisão nas informações, provocando ineficiência no nível de serviço de atendimento a clientes, redução do giro de estoque, falta de alinhamento entre oferta e demanda e alto índice de obsolescência devido à grande diversidade de produtos.

Além disso, segundo Tripathi e Gupta (2019), a gestão de demanda tem problemas como falta de estoque, excesso de estoque, atrasos nos pedidos e baixos níveis de serviço devido à incompatibilidade de oferta e demanda.

Para Fildes et al (2009), a dificuldade em prever um planejamento de demanda adequado está relacionada com algumas variáveis que afetam as análises, tais como: o conjunto de dados históricos, a presença de *outliers*, mudanças de nível e tendência, impacto

do mercado e ambiente econômico, no qual se intensifica pelo grande número de SKU previstos em cada horizonte de planejamento.

Segundo Sagaert et al (2019), a maior parte da previsão de uma cadeia de abastecimento é baseada em métodos extrapolativos, que modelam os padrões de demanda passada, com as potenciais análises de julgamentos dos especialistas da área. Os problemas enfrentados por estes modelos consistem em julgamentos inconsistentes de especialistas e a incapacidade de capturar mudanças na dinâmica do mercado pelas previsões extrapolativas, uma vez que se baseiam apenas em observações históricas anteriores da variável de destino, acrescido de que a decisão de longo prazo pode gerar incertezas de demanda em relação a de curto prazo.

Os principais desafios enfrentados no planejamento de demanda na cadeia de suprimentos é a pressão exercida em atender à demanda de produtos e/ou serviços estipulados pelo cliente, bem como a rápida capacidade de reagir à mudança da demanda, com uma maior velocidade de resposta em termos de volume, entrega e margem econômica (CASSETTARI ET AL, 2017).

Outro fato importante a ser considerado é que as técnicas de previsão de demanda tradicionais se baseiam em prever a demanda através de dados históricos e padrões de tendência, utilizados para modelos lineares, pois não capturam as informações de modelos não lineares. Outros modelos que utilizam técnicas mais robustas como aprendizado de máquina e redes neurais, incorporam modelos não lineares, o que possibilita o uso de outras variáveis de entrada e saída para melhorar o modelo. Entretanto, o problema em utilizar essa técnica é que requer o uso de *softwares* com alto custo de aquisição e alto poder computacional para processar, otimizar e ajustar os parâmetros, além de demorar um tempo para convergir os resultados (KUMAR, SHANKAR E ALJOHANI, 2020).

Segundo Hofmann e Rutschmann (2018), as principais limitações dos modelos de previsão tradicionais dizem respeito à disponibilidade de informação, que geralmente são incompletas e não confiáveis. Uma segunda limitação é a utilização de algoritmos complexos para gerar resultados estatísticos simples devido ao ruído estatístico e variação inexplicada em amostras. Outra limitação ocorre com o processo de tomada de decisão que não está relacionado a um corpo de conhecimento. E por fim, métodos qualitativos requerem certas habilidades estatísticas e domínio de conhecimento de mercado pelos especialistas.

### **2.1.6 Benefícios da gestão de demanda**

Segundo Fildes et al (2009), uma boa acuracidade de previsão de demanda pode trazer benefícios significativos para organização em termos de economias monetárias, maior

competitividade no mercado e melhoria na satisfação do cliente, além de aperfeiçoar o relacionamento com fornecedores e clientes, reduzir o efeito chicote em toda a cadeia de suprimentos, aumentando assim, a satisfação do cliente e o nível de serviço atendido.

De acordo com Huang e Liu (2017) e Dreyer et al (2018), ter um processo de planejamento de demanda bem estruturado reduz as incertezas de oferta e demanda, melhora a disponibilidade de produto, reduz os níveis de estoque, reduz desperdícios e otimizam os processos de operações de toda a cadeia de suprimentos, minimizando custos de transporte, armazenagem e capital de giro.

Uma implementação bem conduzida no planejamento de demanda pode melhorar o nível de serviço prestado ao cliente e gerar benefícios substanciais para os resultados financeiros da empresa como, por exemplo, a redução dos níveis de estoque, melhoria da utilização dos ativos e melhoria na disponibilidade do produto (MELO e ALCÂNTARA, 2011).

Sagaert et al (2019) informam que a inclusão de indicadores macroeconômicos externos pode ser benéfica e eficaz no rastreamento de mudanças no ambiente de negócios, levando a melhores previsões tanto ao nível tático quanto ao nível estratégico.

## 2.2 TECNOLOGIAS DO *SUPPLY CHAIN 4.0*

De acordo com Princes (2020), as cadeias de suprimentos estão se tornando cada vez mais complexas devido aos seguintes motivos:

a) maior expectativa do cliente, pois os consumidores querem produtos que sejam entregues mais rapidamente e desejam ter o poder de escolha de quando e como as mercadorias serão entregues, tendo assim maior visibilidade.

b) maior complexidade da cadeia de suprimentos globalizada, pois as empresas devem gerenciar não só os mercados, como também, as culturas, questões legais e regulatórias.

c) maior tendência de mudança da cadeia de suprimentos com produtos e serviços cada vez mais personalizados com fornecedores especializados.

Consumidores querem cada vez mais conveniência, poder de escolha e controle, porém quando as cadeias de suprimentos se tornarem mais digitais e orientadas por dados, que podem criar serviços que forneçam esses benefícios com mais interconectividade e customização em massa para melhorar a expectativa do cliente (GARAY-RONDERO ET AL, 2019).

A transformação digital é a chave para sobreviver no mundo dos negócios, devido ao ritmo da contínua inovação tecnológica, assim como um tipo de decisão estratégica que ajuda as organizações a obter um melhor atendimento ao cliente, melhores relações com fornecedores,

aumento de vendas e desenvolvimento de negócios e, portanto, aumento da competitividade (AGRAWAL ET AL, 2020).

De acordo com Romanov et al (2020), o desenvolvimento da economia e a transição para a indústria 4.0 criam novos desafios para métodos de inteligência artificial. Esses desafios incluem o processamento de grandes volumes de dados, a análise de vários indicadores dinâmicos, a descoberta de dependências complexas no acúmulo de dados e a previsão do estado dos processos e, mais ainda, esses sistemas inteligentes demonstram um aumento na qualidade e estabilidade de seu funcionamento.

Pesquisadores acadêmicos e industriais sugeriram vários tipos de abordagens para avaliar as possibilidades potenciais de *Supply Chain 4.0*, também conhecido como *Digital Supply Chain* (DSC), mas pouca pesquisa foi realizada sobre como definir esse novo conceito teórico (BÜYÜKÖZKAN e GÖÇER, 2018).

Segundo Calatayud et al (2019), *Supply Chain 4.0* tem como objetivo tornar a cadeia mais ágil e flexível, com a implementação de novas tecnologias digitais e, sendo assim, é possível obter uma melhor percepção das preferências dos clientes, aprimorando seu nível de relacionamento com os clientes, criando, uma maior visibilidade em tempo real sobre suas operações, resultando em maior eficiência operacional e disponibilidade de produto, redução de custos e prazos de entrega.

Para Büyüközkan e Göçer (2018), o *Supply Chain 4.0* se baseia na capacidade de análise massiva de dados, excelente cooperação e comunicação, redes de *hardware* e *software* para suportar e sincronizar a interação entre as organizações, tornando os serviços mais valiosos, acessíveis e com resultados mais ágeis, eficientes e eficazes.

De acordo com Hosseini, Ivanov e Dolgui (2019), o *Supply Chain 4.0* torna uma cadeia cada vez mais resiliente, pois a rede é capaz de suportar, de se adaptar e de se recuperar de interrupções para atender à demanda do cliente e garantir o desempenho através de modelos analíticos e tecnologias inovadoras com foco em agilidade, flexibilidade, visibilidade e colaboração.

De acordo com Büyüközkan e Göçer (2018), o *Supply Chain 4.0* impacta no desenvolvimento de novos produtos através do fornecimento das informações, levando a uma melhor integração com as necessidades dos clientes e permitindo eficiência, tanto na cadeia *upstream* quanto *downstream*.

Segundo Martins, Simon e Campos (2020), as tecnologias habilitadoras da indústria 4.0 possibilitam uma maior integração em toda a cadeia de suprimentos, desde seus fornecedores até o cliente final, com uma maior flexibilidade em suas operações, maior

capacidade de resposta à demanda, confiabilidade dos seus processos e melhor produtividade, fazendo com que as informações gerenciais sejam transmitidas em tempo real e com redução de custos.

Conforme relatado por Zekhnini et al (2020), o recente acesso a dados, modelagem computacionais e avanços tecnológicos na cadeia de suprimentos facilitam o acesso dos gerentes a dados em tempo real que podem ser compartilhados por todo o sistema de abastecimento para tomada de decisão, modificando numerosos sistemas de abastecimento para as necessidades particulares de clientes.

Basson, Kilbourn e Walters (2019) informam que as ferramentas tecnológicas podem apoiar no planejamento de demanda nas seguintes atividades: fornecimento de modelos de séries temporais, integração de sistema de ERP, nas análises de tendências e modelagem da demanda a partir de dados históricos e utilização de aprendizado de máquina, para capturar fatores externos que podem afetar a demanda.

Kumar, Shankar e Aljohani (2020) relatam que as futuras técnicas para detectar a demanda serão utilizadas com tecnologias avançadas de mineração de dados, como o *Big Data*, que será capaz de identificar os padrões da demanda no comportamento do consumidor.

O uso de uma estrutura baseada em *Big Data* fornece uma alta capacidade de modelagem, melhores habilidades de computação e flexibilidade de tornar o modelo de previsão proposto mais contemporâneo. Assim, pode melhorar a precisão da previsão de demanda, otimizando os estoques, melhorando a lucratividade, além de um plano de vendas baseados em dados dos clientes que também podem ser utilizados para prever a demanda de novos produtos (KUMAR, SHANKAR e ALJOHANI, 2020).

O aprendizado de máquina representa uma mudança da avaliação de dados isolados para um padrão mais sofisticado de um sistema de reconhecimento, modelando adequadamente as dependências de tempo dos dados disponíveis. De acordo com a previsão de demanda, uma resposta do cliente é criada por meio de um modelo de sinais de demanda que, por sua vez, é criado por sinais de detecção do mercado. Modelos causais usam padrões reconhecidos e domínio do conhecimento para fazer previsões, pois necessitam analisar, inicialmente o passado para, posteriormente, descobrir padrões futuros (HOFMANN E RUTSCHMANN, 2018).

De acordo com Queiroz (2019), as cadeias de suprimentos tradicionais eventualmente enfrentarão o desafio de se atualizar para cadeias de suprimentos digitais (*Supply Chain 4.0*) oferecendo suporte a novos modelos de produção, modos de transporte, experiências e relacionamentos com o cliente com base nas trocas de informações em tempo real.

Os principais desafios enfrentados para implementar o *Supply Chain 4.0* são: a falta de planejamento e de colaboração, compartilhamento e integração de informações entre os elos da cadeia e imprecisão na previsão de demanda (BÜYÜKÖZKAN E GÖÇER, 2018).

De acordo, Büyükoçkan e Göçer (2018), as principais tecnologias do supply chain 4.0 são: *Big Data*, aprendizado de máquina, internet das coisas (IoT), sistemas ciberfísicos, computação em nuvem, *omnichannel*, manufatura aditiva e tecnologias sensoriais. Entretanto serão apresentados nas próximas seções, somente as tecnologias de *Big Data* e aprendizado de máquina, que são o escopo dessa dissertação.

### 2.2.1 *Big Data*

O *Big Data* é um grande conjunto de dados que contém informações úteis à tomada de decisão aprimorada devido à coleta e análise de grandes conjuntos de dados. Essas informações são dinâmicas, o que possibilita que os resultados variem em tempo real (ASTILL ET AL, 2020).

De acordo com Martins, Simon e Campos (2020), o *Big Data* abrange três principais fluxos na cadeia de suprimentos. Primeiro, melhor monitoramento dos fluxos de materiais, por exemplo, status de produção, monitoramento e qualidade de processo, manuseio de estoque, logística, pesquisa e desenvolvimento, bem como, soluções coletivas em funções de aquisição e distribuição.

Segundo, melhor gerenciamento dos fluxos de informação, por exemplo, gestão de demanda, gestão de fornecedores, gestão de clientes, gestão de riscos, identificação de problemas, suporte a decisões automatizadas e gerenciamento de clientes. Terceiro, melhor controle dos fluxos financeiros, por exemplo, segmentação de clientes, modelagem de demanda, *design* de novo modelo de negócios, preços e sortimento e aspectos financeiros de recursos humanos (MARTINS, SIMON e CAMPOS, 2020).

Hofmann e Rutschmann (2018) relatam cinco técnicas que podem ser utilizadas no *Big Data*:

- a) exploração de dados: consiste em compreender e explorar uma vasta massa de dados, para produzir *insights* que sejam relevantes para o negócio;
- b) análise avançada: aborda questões de análises mais complexas, combinando técnicas de mineração de dados, aprendizado de máquina e métodos estatísticos;
- c) análise e planejamento interativo: consiste em análise de BI (*Business Intelligent*), se concentrando em fazer análises mais acessíveis e relatórios mais gerenciais;
- d) análise incorporada: é um recurso que permite operações com base de dados, para

tomada de decisão por meio de processos mais automatizados e analíticos;

e) análise de fluxo de dados: consiste na programação automática de dados, para filtrar, transformar, detectar dados correlacionados, analisar tendências, dados errôneos e prever modelos.

### 2.2.2 Aprendizado de máquina

Segundo Kaplan e Haenlein (2019), aprendizado de máquina é a capacidade de um sistema interpretar dados externos corretamente para aprender com esses dados e usar esses aprendizados para atingir objetivos específicos e tarefas por meio de adaptação flexível.

De acordo com a Coupa (2021), os principais algoritmos que utilizam técnicas de aprendizado de máquina são:

a) ARIMAX: é um algoritmo semelhante ao Auto ARIMA, com o diferencial de variáveis causais de tendência e sazonalidade para prever a demanda;

b) Support Vector Machine Linear (SVM Linear): é um algoritmo semelhante ao de regressão não linear, que combina múltiplas causais e se encaixa em um modelo de regressão linear dessas variáveis causais combinadas em um espaço de dimensão mais elevada;

c) Quantile Random Forest (QRF): é um algoritmo que constrói um grande número de árvores de decisão em paralelo e posteriormente calcula a média das previsões de todas as árvores. São construídas aproximadamente 500 árvores de decisão;

d) rede neural: este algoritmo é inspirado no funcionamento das redes neurais biológicas dentro do cérebro humano. A unidade básica de uma rede neural é chamada de neurônio ou nó. Um nó recebe entradas de outros nós ou de uma fonte externa e, em seguida, calcula uma saída com uma função de ativação dentro dele. Esta função de ativação é uma função não linear, esses nós estão conectados uns aos outros para formar uma rede neural;

e) *Gradiente Boosting Machine* (GBM): é um algoritmo que também constrói um grande número de árvore de decisão sequencial, e continua melhorando o modelo iterativamente construindo mais árvores. Dessa forma, as árvores de decisão são criadas sequencialmente e, as previsões de todas as árvores são somadas para formar a previsão final.

## 2.3 ANÁLISE E DISCUSSÕES DA REVISÃO SISTEMÁTICA DA LITERATURA

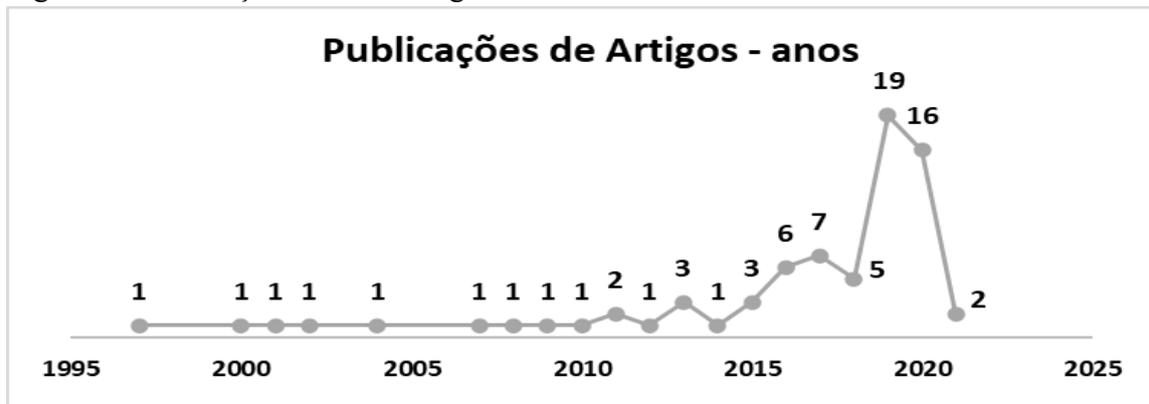
A metodologia de revisão sistemática da literatura contribuiu não só para a revisão da literatura, como também possibilitou uma análise bibliométrica referente a seleção dos artigos, tais como: principais fontes de artigos utilizados, tipos de fontes e ano de publicação, além de elaborar um *framework* conectando o *Big Data* e aprendizado de máquina com a gestão de

demanda.

### 2.3.1 Análise Bibliométrica

A primeira análise em relação à seleção dos artigos pode ser evidenciada na Figura 5, que mostra, a quantidade de artigos que foram publicados, através de uma linha de tempo desde 1995 até 2021, tendo uma maior concentração de artigos publicados nos períodos de 2019 e 2020.

Figura 5 - Publicação anual de artigos



Autor, 2021

A Figura 6 evidencia que dos artigos selecionados para compor essa revisão literária, 79% referem-se a artigos publicados nos últimos cinco anos, permanecendo, assim, em conformidade com a proposta inicial desta pesquisa, sendo que as análises e percepções estão voltadas para a exposição e interpretação dos estudos mais recentemente publicados e que estão disponíveis para implementação em empresas.

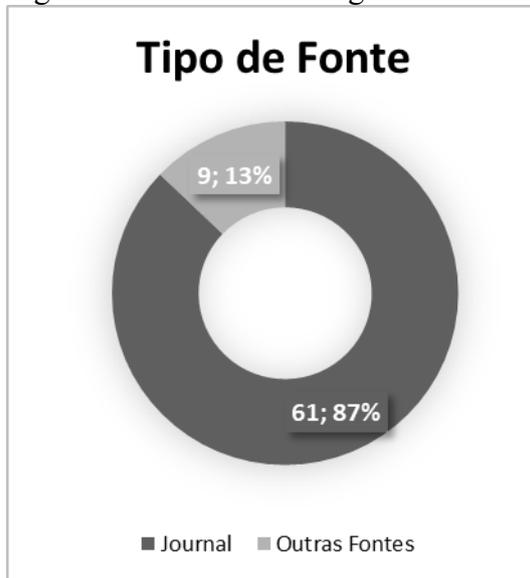
Figura 6 - % Publicação de artigos



Autor, 2021

Conforme apresentado na Figura 7, dos principais artigos selecionados, 87% referem-se aos principais *Journals* de referência na literatura, e 13% estão relacionadas a outras fontes como revistas, anais de congressos, livros e sites.

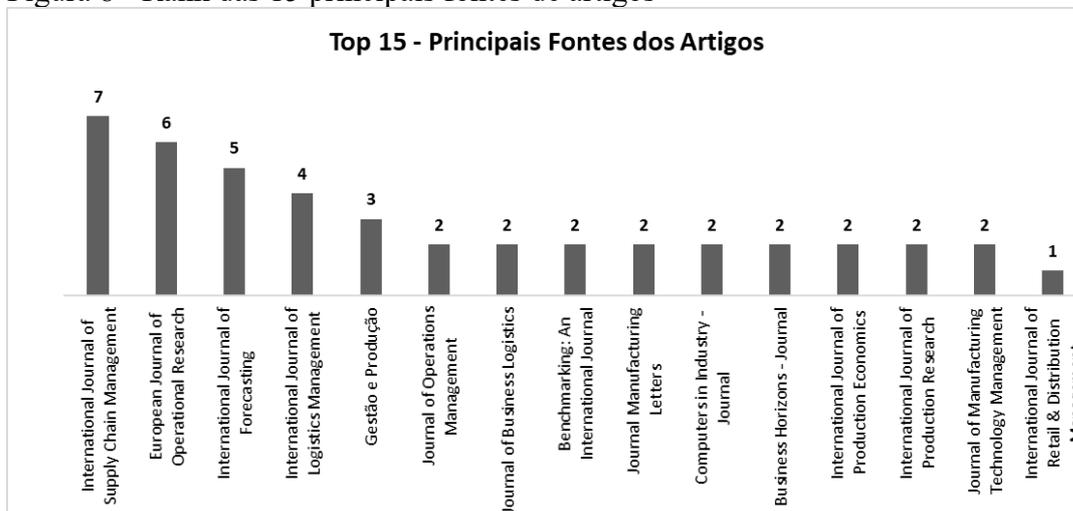
Figura 7 - % Fonte de Artigos



Autor, 2021

E por fim, a Figura 8, evidencia a análise de *rank* das 15 principais fontes de artigos.

Figura 8 - Rank das 15 principais fontes de artigos



Autor, 2021

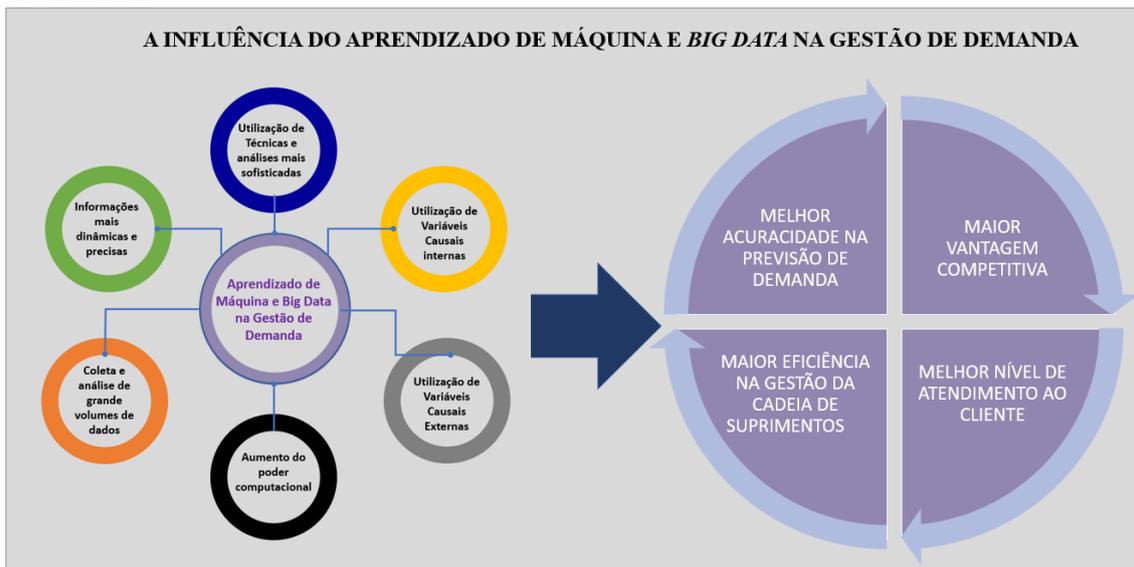
Observa-se que os três principais *Journals* são: *International Journal of Supply Chain Management*, *European Journal of Operational Research* e *International Journal of Forecasting*, que representam 25,7% das fontes de pesquisa. Além disso, nota-se que em quinto lugar aparece a revista brasileira *Gestão e Produção*.

### 2.3.2 Framework

Com base na revisão sistemática de literatura, diagnosticou-se os principais problemas e desafios que as empresas enfrentam na gestão de demanda e como proposto na questão de pesquisa, esta análise visa identificar a influência do aprendizado de máquina e *Big Data* no desempenho da acuracidade do planejamento de demanda.

Pensando nesse contexto, foi elaborado um *framework*, conforme Figura 9, conectando essas duas principais tecnologias do *Supply Chain 4.0* que mais impactam no desempenho do planejamento de demanda, resultando na melhoria da acuracidade da previsão de demanda e eficiência na cadeia de suprimentos, maior vantagem competitiva e melhor nível de atendimento ao cliente.

Figura 9 - *Framework* das tecnologias de aprendizado de máquina e *Big Data* aplicado na gestão de demanda



Autor, 2021

A primeira tecnologia explorada é o *Big Data*, que permite coletar e analisar grandes volumes de dados, com informações dinâmicas e precisas, que variam ao longo do tempo real integrado com a computação em nuvem. Além disso, pode-se armazenar dados em local seguro, na qual cria um espaço virtual e global para permitir uma rede compartilhada de recursos e capacidades de manufatura por meio da internet, criando mais visibilidade, *insights* e flexibilidade da demanda, confiabilidade e gerenciamento de dados inteligentes que impactam diretamente na acuracidade de demanda. Nesta dissertação utilizou-se como *Big Data* o Data Cubo do Guru, para selecionar as variáveis causais externas que pudessem influenciar nos modelos de previsão de demanda.

A segunda tecnologia explorada do *Supply Chain 4.0*, foi a utilização das técnicas de aprendizado de máquina, pois tem-se um alto poder computacional com uso de algoritmos

avançados para análises de modelos mais robustos. Com essa integração também é possível, utilizar técnicas de previsão de demanda mais sofisticadas e precisas, além de realizar análises estatísticas multivariadas para entender o comportamento das variáveis causais internas e externas no modelo, que também impactam positivamente na acuracidade de demanda. Nesta pesquisa, utilizou-se do *software* Demand Guru, para simular e comparar as técnicas clássicas de série temporal *versus* técnicas de aprendizado de máquina.

Com a aplicação dessas duas tecnologias do *Supply Chain 4.0*, é possível melhorar a acuracidade de previsão de demanda, com menores índices de erro de acurácia, maior vantagem competitiva entre seus concorrentes, uma vez que, terão melhores níveis de estoque, e consequentemente, menores custos logísticos.

Além disso, tem-se uma maior eficiência na gestão da cadeia de suprimentos com maior visibilidade da demanda e parcerias com seus fornecedores, melhorando também o nível de atendimento ao cliente, tendo o produto correto, no momento correto e entregue no tempo certo.

É importante salientar que muitas organizações se limitam ao utilizar tecnologias nas análises de previsão de demanda, devido ao alto custo de investimento do *software* ou pela falta de processamento computacional deixando a modelagem de dados mais simples possível. Entretanto, os algoritmos de aprendizado de máquina, aprendem padrões em dados históricos de demanda e usam esse aprendizado para prever o futuro, tornando os modelos mais robustos e de menor erro de acurácia.

Outro fator importante em uma organização é tornar a cadeia de suprimento cada vez mais eficiente, de modo que seja mais flexível e responsiva, para atender às demandas mais customizadas, e reduzir o efeito chicote entre os elos da cadeia. Com a utilização da técnica de aprendizado de máquina e *Big Data*, é possível melhorar a cadeia de suprimentos, pois juntos aumentam a capacidade de coletar e processar dados corretos nos *softwares*, além disso, tem-se um maior controle e monitoramento das operações e gestão dos estoques, bem como maior visibilidade da demanda.

No próximo capítulo serão explicados os procedimentos metodológicos que foram utilizados nesta dissertação.

### 3 PROCEDIMENTOS METODOLÓGICOS

O estudo em questão é de natureza aplicada, que de acordo com a definição de Ferrari (1982), é uma pesquisa que pode contribuir teoricamente com novos fatos para estudos de pesquisas futuras ou mesmo para a compreensão teórica de certos setores do conhecimento, podendo ser estudado em uma ou mais organizações (públicas, privadas, industriais, prestadoras de serviços, fundações, organizações não governamentais etc.). Nesta dissertação, a pesquisa será aplicada na indústria de agronegócio (como já descrito no capítulo 1), contribuindo para melhorar o desempenho da acuracidade de previsão de demanda da empresa.

Nesta dissertação, emprega-se dois tipos de pesquisa, sendo a primeira de caráter exploratória, que de acordo com Gil (2008), tem a finalidade de desenvolver, esclarecer e modificar conceitos e/ou ideias, utilizados para temas poucos explorados, sendo a primeira etapa para problemas de pesquisa mais ampla. Neste caso, o tema requer exploração dos impactos do aprendizado de máquina aplicados na gestão de demanda.

E a segunda, caracteriza-se como pesquisa descritiva, que segundo Gil (2008), é aquela que caracteriza uma determinada população ou fenômeno, assim como estabelece relacionamento entre variáveis, geralmente com a utilização de coletas de dados e instrumentos estatísticos. Neste caso, a presente pesquisa visa analisar quantitativamente o desempenho da acuracidade de demanda, através de coleta de dados da empresa de agronegócio, avaliando os impactos da utilização de variáveis causais, bem como métodos de aprendizado de máquina em previsões de demanda.

A abordagem de pesquisa é quantitativa, que de acordo com Creswell (2007), se caracteriza quando o pesquisador utiliza de raciocínio de causa e efeito, análise de variáveis específicas, hipóteses de pesquisa, empregando estratégias de investigação como experimentos, levantamento e coleta de dados, que geram dados estatísticos. Neste contexto, a abordagem se caracteriza como quantitativa, devido ao levantamento e coleta de dados, análise, modelagem e simulação de dados, utilizando o *software Demand Guru*, avaliando o desempenho da acuracidade de previsão de demanda.

Por fim, o método de pesquisa adotado é de estudo de caso, que de acordo com Gil (2008), é um estudo empírico que explora fenômenos atuais dentro de um contexto que não está claramente definido ou aquele que descreve situações em um contexto que ainda está sendo investigado ou explica as variáveis causais de um determinado fenômeno em situações complexas. Neste trabalho, busca-se investigar quais as principais variáveis causais que podem

interferir na acuracidade de previsão de demanda e descreve o impacto em utilizar modelos de aprendizado de máquina no planejamento de demanda.

Além disso, o estudo de caso, utiliza-se de análises quantitativas, com aplicação de métodos de séries temporais e algoritmos de aprendizado de máquina para análise dos dados, assim como de análise qualitativa, realizando entrevistas com os principais especialistas e executivos da área para maior entendimento do problema.

### 3.1 METODOLOGIA APLICADA NO ESTUDO DE CASO

Para realizar o estudo de caso, elaborou-se uma metodologia para análise dos dados que consiste em três etapas:

a) planejamento: consiste na parceria com a empresa e definição do escopo do projeto de estudo;

b) diagnóstico: corresponde na etapa de coleta de dados da empresa, tratamento de dados, entendimento e mapeamento de como é realizado a previsão de demanda da empresa, definição das variáveis externas que impactam na unidade de negócio e entrevistas com especialistas da área;

c) modelagem e simulação: compreende na construção da modelagem de dados, comparação das técnicas de previsão de demanda, utilizando técnicas de aprendizado de máquina e variáveis causais, com o uso do *software Demand Guru*.

#### 3.1.1 Planejamento

Na etapa de planejamento, foi estabelecido o escopo do projeto para avaliar o desempenho da acuracidade de demanda. Analisou-se o segmento de produto de fungicida como amostra, na qual constitui em seis famílias, representando o volume total de 43% das vendas (conforme Tabela 3).

Além disso, conforme descrito pelos especialistas da empresa, esse segmento de fungicidas é utilizado principalmente para combater e sanitizar doenças nas plantações como ferrugem e mancha alvo, predominantemente utilizados na região Centro-Oeste do Brasil, na qual se concentra o bioma do cerrado.

Tabela 3 - Segmento de produtos

Segmento de Produto	Volume de Vendas (LTR)	% ABC
Fungicida	92.314.040	43%
Adjuvante	79.260.213	37%
Inseticida	28.394.149	13%
Herbicida	14.201.537	7%
<b>Total</b>	<b>214.169.939</b>	<b>100%</b>

Autor, 2022

Definiu-se também, o período utilizado para coleta de dados, com histórico de vendas a partir de 01/01/2014 até 31/12/2019. E como proposta para previsão de demanda, prever os próximos seis meses no período de 01/07/2019 até 31/12/2019. Esse período foi escolhido pelos especialistas da área, pois não havia o efeito da pandemia no histórico de vendas que pudesse influenciar na análise dos resultados.

### 3.1.2 Diagnóstico

Nessa etapa, diagnosticou-se que o maior problema enfrentado pela empresa consistia em dois fatores, na falta de conhecimento técnico dos especialistas da área em utilizar métodos de análises quantitativas, como também, na falta de comparação de diferentes técnicas no modelo de negócio, com intuito de comprovar qual o melhor desempenho entre os métodos quantitativos em relação aos métodos qualitativos praticados pela empresa.

Após essa etapa de diagnóstico do principal problema enfrentado pela empresa, coletou-se os dados de históricos de vendas e previsões de demanda realizadas, no período de 01/01/2014 até 31/12/2019, para o segmento de produto de fungicidas.

Depois, identificou as principais características de cada família de produto, tais como: média de vendas mensais, desvio padrão, variabilidade da demanda, sazonalidade, ciclo de vida do produto e vida útil, conforme mostra a Tabela 4.

Tabela 4 - Característica da Família Fungicida

Família	N° de SKU	Vendas Mensais	Desvio Padrão	Variabilidade	Demanda	Sazonalidade	Ciclo de Vida	Vida Útil
Fungicida 1	2	313.252	365.331	Alta	Alta	Sim	Maduro	Médio
Fungicida 2	2	496.422	497.226	Alta	Alta	Sim	Maduro	Médio
Fungicida 3	2	85.532	73.889	Alta	Baixa	Não	Início de Declínio	Médio
Fungicida 4	3	234.520	233.276	Alta	Média	Sim	Declínio	Médio
Fungicida 5	1	100.294	71.034	Alta	Média	Sim	Início de Declínio	Médio
Fungicida 8	1	40.284	53.096	Alta	Baixa	Sim	Maduro	Médio
<b>Total</b>	<b>11</b>	<b>1.270.303</b>						

Autor, 2022.

Pode-se verificar que há uma alta variabilidade entre as seis famílias de produtos, com médias de vendas graduando desde 40 mil litros até 500 mil litros, com períodos de sazonalidade em quase todas as famílias de produtos.

A Tabela 5 apresenta o histórico anual de vendas dos últimos cinco anos de cada SKU do segmento da família de fungicida. Identifica-se um crescimento no decorrer dos anos, principalmente em 2016 e 2017, em que houve um crescimento de 67% e 66%,

respectivamente, em relação ao ano anterior. Observa-se também, que as famílias de fungicida 2, 4 e 8, inicia-se suas vendas em 2016, enquanto, o fungicida 5, começa em 2017.

Tabela 5 - Comparativo anual das vendas da família de fungicida

Família	2014	2015	2016	2017	2018	2019	% 2015/2014	% 2016/2015	% 2017/2016	% 2018/2017	% 2019/2018
Fungicida 1	2.431.021	3.648.549	2.709.275	3.494.964	4.154.336	5.633.047	50%	-26%	29%	19%	36%
Fungicida 2	-	-	2.785.700	4.907.302	5.869.765	6.888.185	0%	0%	76%	20%	17%
Fungicida 3	827.614	1.011.265	1.186.893	722.458	936.472	1.303.093	22%	17%	-39%	30%	39%
Fungicida 4	-	-	856.155	2.898.627	3.062.800	4.246.904	0%	0%	239%	6%	39%
Fungicida 5	-	-	-	573.060	921.751	1.276.385	0%	0%	0%	61%	38%
Fungicida 8	-	-	225.740	295.100	547.428	704.150	0%	0%	31%	86%	29%
<b>Total Geral</b>	<b>3.258.635</b>	<b>4.659.814</b>	<b>7.763.763</b>	<b>12.891.511</b>	<b>15.492.552</b>	<b>20.051.764</b>	<b>43%</b>	<b>67%</b>	<b>66%</b>	<b>20%</b>	<b>29%</b>

Autor, 2022

As Figuras de 10 até 15 evidenciam graficamente o perfil de demanda de cada família de produtos.

Observa-se que a família 1, possui um baixo volume de vendas no 1º e 2º trimestre de cada ano, com uma sazonalidade com tendência de crescimento no 3º trimestre deste período e queda no volume de vendas a partir do 4º trimestre de cada ano, conforme Figura 10.

Figura 10 - Perfil de Demanda Fungicida 1



Autor, 2022.

A família 2 começou a vender no mercado de agronegócio a partir do 3º trimestre de 2016, tem um baixo volume de vendas no 1º e 2º trimestre de cada ano, sazonalidade com tendência de crescimento no 3º trimestre e queda no volume de vendas a partir do 4º trimestre de cada ano, conforme Figura 11.

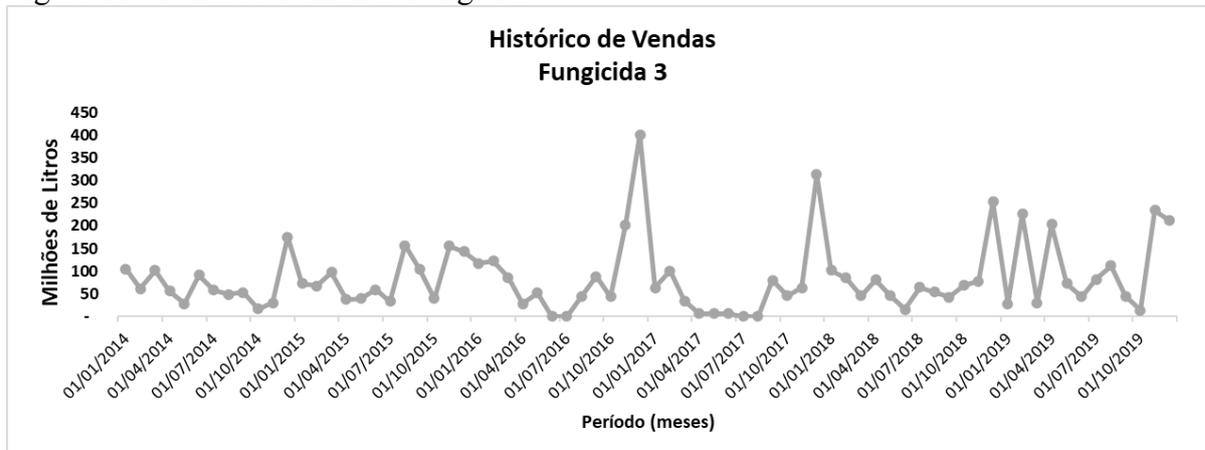
Figura 11 - Perfil de Demanda Fungicida 2



Autor, 2022.

A família 3, apresenta irregularidade nas vendas no decorrer de cada trimestre em todos os anos, exceto em 2019 que há uma tendência de crescimento, também de foram irregulares entre os meses do ano, o que evidencia alta variabilidade nas vendas, conforme mostra a Figura 12.

Figura 12 - Perfil de Demanda Fungicida 3



Autor, 2022.

A família 4, iniciou-se o histórico de vendas a partir do 1º trimestre de 2016, possui a mesma característica da família 1 e 2, com um baixo volume de vendas no 1º e 2º trimestre de cada ano, sazonalidade com tendência de crescimento no 3º trimestre e queda no volume de vendas a partir do 4º trimestre de cada ano, conforme Figura 13.

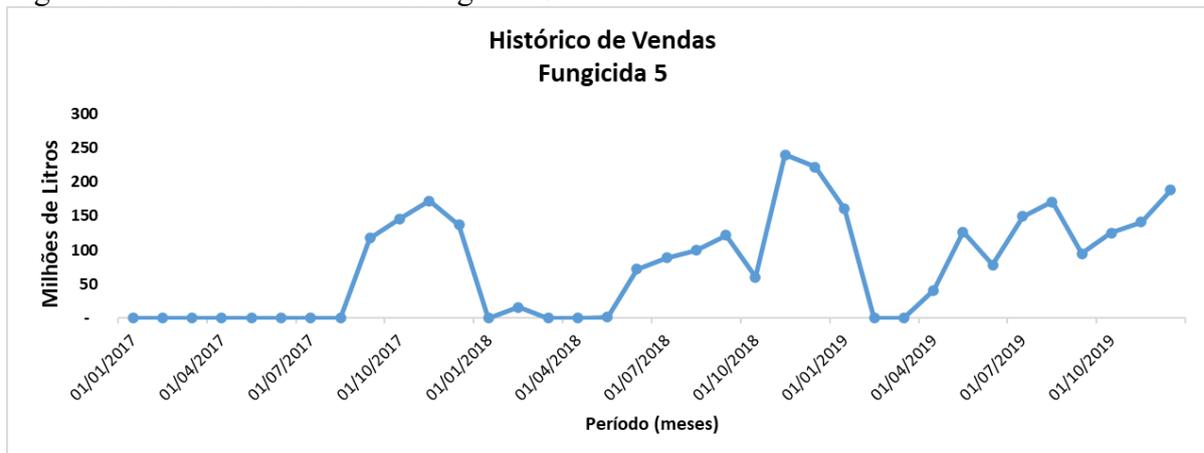
Figura 13 - Perfil de Demanda Fungicida 4



Autor, 2022.

A família 5, obteve-se o histórico de vendas a partir do 2º trimestre de 2017, possui sazonalidade, no 3º e 4º trimestre de 2017 e 2018. A partir do 2º trimestre de 2019, apresenta uma tendência de crescimento linear, conforme mostra na Figura 14.

Figura 14 - Perfil de Demanda Fungicida 5



Autor, 2022.

A família 8, começou o histórico de vendas a partir do 2º trimestre de 2016, possui sazonalidade, porém menos acentuada em relação às famílias 1, 2 e 4. Apresenta também uma tendência de crescimento, no 3º trimestre de cada ano e redução nas vendas a partir do 4º trimestre de cada ano, conforme Figura 15.

Figura 15 - Perfil de Demanda Fungicida 8



Autor, 2022.

Ainda nessa etapa, foram realizadas algumas reuniões semanais para entendimento de como era realizado a previsão de demanda pela empresa, bem como definição das variáveis causais externas que pudessem influenciar na previsão de demanda.

A empresa faz a previsão de demanda através da ferramenta *Salesforce*, que captura os pedidos das ordens de vendas da área de Vendas & Marketing, agregando os produtos no nível de SKU – Família (*Bottom-Up*), porém não realizaram nenhum estudo para determinar esse nível de agregação. Após essa captura de informações, fazem uma análise de julgamento dos dados disponibilizados na plataforma. Essa análise é realizada de forma qualitativa pelos especialistas de demanda e vendas, para verificar possíveis desvios. Os dados dos pedidos de vendas são 70% solicitados pelos distribuidores (lojas físicas) e 30% diretamente pelo consumidor final. A métrica utilizada pela empresa para cálculo da acuracidade de previsão de demanda é WMAPE ponderado pelo volume de vendas realizadas, devido à alta variabilidade e sazonalidade de seus produtos. A previsão de demanda também é realizada para os próximos 36 meses, por se tratar de um planejamento mais estratégico, e à medida que vai se aproximando os meses mais recentes, realiza-se as correções na previsão pela análise de julgamento. O principal risco dessa estratégia está relacionado com o especialista da área em corrigir as previsões de demanda, pois precisa ter um perfil analítico mais apurado e conhecimento específico de mercado.

A Figura 16 apresenta o grau de importância de cada variável externa, entre elas, as de maior importância são o índice de exportação e o PIB de agricultura, que quanto maior for esses índices, maior será o volume de produção na agricultura e, conseqüentemente, aumentará a utilização de fungicidas para o combate de pragas nas lavouras. As demais variáveis externas foram consideradas de média importância. Essa classificação de grau de importância foi determinada por um comitê de especialistas sendo dois especialistas internos da empresa e

dois especialistas externos de mercado.

Figura 16 - Variáveis Causais Externas

Comitê de Especialistas	
Fatores Externos que influenciam a demanda	Grau de Importância
Balanco Comercial	Médio
Índice de Exportação	Alto
Índice de Inflação de Alimentos	Médio
PIB Agricultura	Alto
Índice de Importação	Médio
Precipitação Mato Grosso	Médio

Autor, 2022.

E por último, foram realizadas entrevistas para um *brainstorm* de ideias, com soluções desenvolvidas pelo mercado, comparações de métodos e métricas utilizadas nas empresas, bem como uma visão geral nesse novo contexto de globalização e digitalização da cadeia de suprimentos.

Segundo Augusto Franciosi (2021), diretor de planejamento de demanda na consultoria EY, as empresas estão buscando adotar métodos e *softwares* que sejam capazes de elaborar uma boa previsão de demanda, entre eles o SAP IBP. Além disso, para o entrevistado, o principal desafio está na etapa de teste e parâmetros de cada série temporal. Relata ainda que geralmente, as empresas dos setores industriais e produtivos, praticam um erro de acurácia em torno de 30%. (Informação verbal).<sup>1</sup>

De acordo com Mirella De Martino Ribeiro (2021), especialista de planejamento de demanda no hospital Albert Einstein, relata que atualmente as empresas começaram a observar um valor maior na área de gestão de demanda e que os fóruns estão trazendo nessas reuniões o avanço das tecnologias de informação atuando para melhorar cada vez mais o planejamento de demanda. Além disso, relata também que o SAP IBP é uma ferramenta tecnológica que está ganhando força no mercado, com benefícios relacionados a ganhos com redução de inventário, ganho de tempo com análises mais estratégicas para tomada de decisão dos especialistas de demanda (Informação verbal).

A entrevistada ressalta ainda que há falta de conhecimento das pessoas para fazerem o cálculo da métrica de acuracidade e entenderem como isso se aplica ao planejamento. Além disso, considera um erro de acuracidade de 20 a 25% tolerável, entretanto, a prática no mercado é de aproximadamente de 30 a 40%. (Informação verbal).<sup>2</sup>

<sup>1</sup> Informação verbal concedida por Augusto Franciosi, em 10 de dezembro de 2021 em entrevista.

<sup>2</sup> Informação verbal concedida por Mirella De Martino Ribeiro, em 23 de novembro de 2021 em entrevista.

### 3.1.3 Modelagem e Simulação

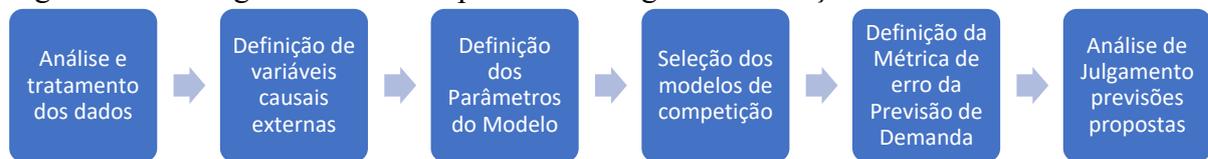
A terceira e última etapa da metodologia aplicada, refere-se a modelagem e simulação referente as informações de dados da demanda.

Para executar a modelagem e simulação dos dados, utilizou-se do *software Demand Guru*, que de acordo com Coupa (2021), é um *software* que conecta as previsões de demanda avançadas, fornecendo as melhores tomadas de decisão para organização, equilibrando a oferta e demanda, tendo a possibilidade de aplicar algoritmos de Aprendizagem de Máquina, para entender o histórico de demanda e replicar esses sinais de forma inteligente.

O *software Demand Guru* foi escolhido por fazer combinações e competições entre algoritmos de aprendizado de máquina, além de utilizar uma biblioteca de cubo de dados, com acesso a mais de duas mil séries de dados históricos de variáveis causais que podem influenciar no modelo, desde variáveis econômicas, índices globais, condições climáticas e índices sociais.

Após a escolha do *software*, elaborou-se um fluxograma com todas as etapas de processamento do modelo, conforme Figura 17.

Figura 17 - Fluxograma com as etapas da modelagem e simulação dos dados



Autor, 2022.

O primeiro passo desse fluxograma, consiste nas entradas dos dados, que devem conter no mínimo as seguintes informações:

- a) data histórica dos dados (diário, semanal, mensal etc.);
- b) quantidade da demanda real (litros, quilogramas, unidades etc.);
- c) nível de agregação do produto (SKU, família, segmento de produto, cluster etc.);
- d) tratamento de *outliers*.

Para o escopo desta dissertação, foi definido o nível de agregação temporal mensal, com a unidade de medida básica da demanda em litros e com nível de agregação de produto Top-Down, agregando a demanda por família de produto e após desagrega-se ao nível de produto. Essa abordagem foi definida, através da análise gráfica do perfil de demanda, bem como cálculo da variabilidade de demanda, na qual foi possível identificar que em todos os casos, o perfil de cada produto era o mesmo perfil da família do produto.

A segunda etapa consiste em habilitar o cubo de dados do Guru, de modo a relacionar as variáveis causais externas que foram definidas na etapa de diagnóstico, para serem

utilizadas na etapa de simulação dos dados.

A terceira etapa corresponde na construção do modelo no *software*, definindo os parâmetros que serão utilizados em cada simulação.

Esses dados históricos são divididos em dois grupos. O primeiro grupo é chamado de amostra de treino, na qual a modelagem de dados é realizada até uma data limite dos dados históricos, para que o *software* possa calcular o modelo matemático e selecionar o algoritmo. Já o segundo grupo é definido como amostra de teste, no qual o *software* aplica o modelo matemático definido no grupo de treino e aplica-se o erro na amostra de teste.

Analisou-se a data mínima e a data máxima, da entrada de dados para cada família de produto. Conforme mostra a Tabela 6, a data limite para amostra de treino ocorreu no período de 01/01/2014 até 30/06/2019, a quantidade de meses para amostra de treino será diferente para cada família de produto, devido à quantidade inicial do histórico de dados ser irregular, tendo algumas famílias começando em 2014 ou 2016 ou 2017. Já o período para amostra de teste ocorreu entre 01/07/2019 e 31/12/2019, com previsão de demanda dos próximos seis meses para todas as famílias.

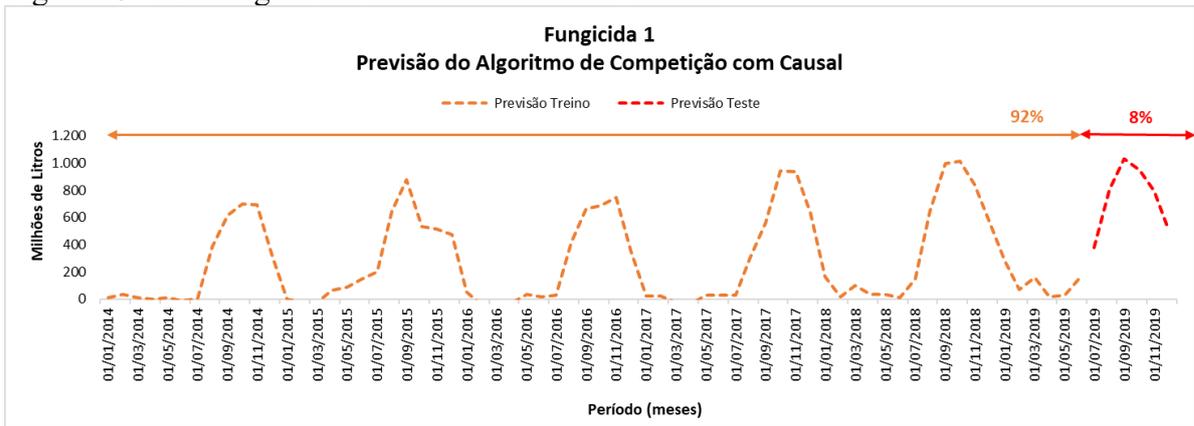
Tabela 6 - Parâmetros da amostra de treino e teste

Família	Data Mínima de Dados	Data limite	Qtde de Meses		Qtde meses Amostra Total	% Amostra de Treino	% Amostra de Teste	Previsão Final
			Amostra de Treino	Amostra de Teste				
Fungicida 1	01/01/2014	30/06/2019	66	6	72	92%	8%	31/12/2019
Fungicida 2	01/07/2016	30/06/2019	36	6	42	86%	14%	31/12/2019
Fungicida 3	01/01/2014	30/06/2019	66	6	72	92%	8%	31/12/2019
Fungicida 4	01/01/2016	30/06/2019	42	6	48	87%	13%	31/12/2019
Fungicida 5	01/09/2017	30/06/2019	21	6	27	78%	22%	31/12/2019
Fungicida 8	01/05/2016	30/06/2019	38	6	44	86%	14%	31/12/2019

Autor, 2022.

Para solucionar essa defasagem de dados históricos irregulares para amostra de treino, utilizou-se como um parâmetro de entrada, o percentual que a amostra de treino deveria ter, para padronizar o período de teste em seis meses para cada família de produto. Como exemplo, tem-se que a família de fungicida 1 e 3, deve obter 92% dos dados históricos para treino e 8% dos dados históricos para teste, para que assim, obtenha padronize o período de teste iniciando em 01/07/2019 até 31/12/2019, contabilizando seis meses de previsão, evidenciado na figura 18. Outro exemplo é o fungicida 2 e 8, na qual o parâmetro de entrada deve ser 86% para período de treino e 14% para o período de teste, para que também obtenha um período de teste compreendido entre 01/07/2019 e 31/12/2019. E assim foi realizado esse cálculo para cada as demais famílias, evidenciado na tabela 6.

Figura 18 - Modelagem dos dados históricos de vendas



Autor, 2022.

Na quarta etapa envolve a escolha dos métodos de previsão de demanda. Definiu-se seis modelos para comparações entre os métodos, que são classificados em método clássicos e métodos de aprendizado de máquina, conforme descrito na Tabela 7.

Tabela 7 - Modelos utilizados para análise e modelagem dos dados

Família	Algoritmo	Melhor Método	Machine Learning?	Causal?	Amostra Treino	Amostra de Teste
Fungicida 1	Empresa	Análise de julgamento	Não	Não	-	-
	Naive	Naive	Não	Não	66	6
	Automático	SVM Linear	Sim	Não	66	6
	Competição	SVM Linear	Sim	Não	66	6
	Combinado	Composto	Sim	Não	66	6
	Competição	GBM	Sim	Sim	66	6
	Combinado	Composto	Sim	Sim	66	6
Fungicida 2	Empresa	Análise de julgamento	Não	Não	-	-
	Naive	Naive	Não	Não	36	6
	Automático	SVM Linear	Sim	Não	36	6
	Competição	SVM Linear	Sim	Não	36	6
	Combinado	Composto	Sim	Não	36	6
	Competição	Arimax	Sim	Sim	36	6
	Combinado	Composto	Sim	Sim	36	6
Fungicida 3	Empresa	Análise de julgamento	Não	Não	-	-
	Naive	Naive	Não	Não	66	6
	Automático	SVM Linear	Sim	Não	66	6
	Competição	GBM	Sim	Não	66	6
	Combinado	Composto	Sim	Não	66	6
	Competição	GBM	Sim	Sim	66	6
	Combinado	Composto	Sim	Sim	66	6
Fungicida 4	Empresa	Análise de julgamento	Não	Não	-	-
	Naive	Naive	Não	Não	42	6
	Automático	SVM Linear	Sim	Não	42	6
	Competição	QRF	Sim	Não	42	6
	Combinado	Composto	Sim	Não	42	6
	Competição	SVM Linear	Sim	Sim	42	6
	Combinado	Composto	Sim	Sim	42	6
Fungicida 5	Empresa	Análise de julgamento	Não	Não	-	-
	Naive	Naive	Não	Não	22	6
	Automático	SVM Linear	Sim	Não	22	6
	Competição	Arimax	Sim	Não	22	6
	Combinado	Composto	Sim	Não	22	6
	Competição	AVNNet	Sim	Sim	22	6
	Combinado	Composto	Sim	Sim	22	6
Fungicida 8	Empresa	Análise de julgamento	Não	Não	-	-
	Naive	Naive	Não	Não	38	6
	Automático	SVM Linear	Sim	Não	38	6
	Competição	Naive	Não	Não	38	6
	Combinado	Composto	Sim	Não	38	6
	Competição	Naive	Não	Sim	38	6
	Combinado	Composto	Sim	Sim	38	6

Autor, 2022.

Os métodos clássicos consistem em algoritmos como: *Naive*, média móvel, exponencial simples, ARIMA e auto ARIMA. Já os métodos de aprendizado de máquina, constituem em algoritmos como: *Support Vector Machine* (SVM) Linear, ARIMAX, *Quantil Random Forecast* (QRF), redes neurais e *Gradient Boosting Machine* (GBM), conforme evidenciado na Tabela 8. A descrição de cada um desses métodos está contida na revisão de literatura na seção 2.2.2.

Tabela 8 – Tipos de modelos Clássicos versus aprendizado de máquina

Algoritmo	Classicos						Machine learning				
	Naive	Media Movel	Suavizamento exponencial	Intermitente	Arima	Auto Arima	SVM Linear	Arimax	QRF	Redes Neurais	GBM
Automatico		√		√			√				
Competicao	√	√		√		√	√	√		√	√
Combinado	√	√		√		√	√	√		√	√

Fonte: Coupa, 2021.

O primeiro modelo utilizado foi o algoritmo de *Naive*, por ser um método de série temporal mais simples utilizado nas previsões de demanda. No segundo modelo utilizou-se o algoritmo automático, que promove a competição entre três algoritmos específicos que são: média móvel, exponencial simples e SVM linear. Após o cálculo de acuracidade o modelo seleciona o algoritmo de menor erro.

No terceiro modelo utilizou-se o algoritmo de competição, que promove a competição de todos os algoritmos, independente se é clássico ou de aprendizado de máquina, e posteriormente seleciona o melhor algoritmo que obtiver o menor erro de acuracidade.

No quarto modelo utilizou-se o algoritmo de abordagem combinada, que permite combinar os algoritmos de melhores resultados, através de uma ponderação de fatores com base no seu desempenho de acurácia.

No quinto modelo, utilizou-se o algoritmo de competição, porém com o acréscimo das variáveis causais externas selecionadas na etapa de planejamento pelos especialistas de demanda, com o intuito de comparar a influência das variáveis causais no desempenho de previsão de demanda.

Finalmente, no sexto modelo, utilizou-se também do algoritmo de abordagem combinada, com o acréscimo das variáveis causais externas, para comparar a influência das variáveis causais no desempenho de previsão de demanda.

Na quinta etapa do fluxograma, define-se qual a melhor métrica de acuracidade de previsão de demanda, que mais se aproxima do modelo de negócio da empresa. Nesta dissertação, a medida de acuracidade utilizada na competição dos modelos, foi o WMAPE ponderado, pelo fato da demanda apresentar sazonalidade e alta variabilidade no histórico de dados, conforme Apêndice A.

E por fim, a sexta etapa do fluxograma, consiste em rodar o modelo e fazer uma análise de julgamento de modo quais qualitativo, para corroborar os resultados das previsões de demanda.

#### 4 ANÁLISE DOS RESULTADOS

Para avaliar os resultados obtidos, após a modelagem e simulação dos dados, os modelos foram analisados em dois grupos. O primeiro grupo consiste em quatro modelos (*Naive*, Automático, Competição e Combinado) e não contém a influência de variáveis causais externas. Já o segundo grupo, consiste em dois modelos (Competição com causal e Combinado com causal) e contém as variáveis causais externas selecionadas para comparar e avaliar o desempenho da acuracidade de previsão de demanda.

A Tabela 9 apresenta os resultados obtidos no primeiro grupo, exemplificado pela família de fungicida 1.

Tabela 9 - Algoritmos modelados sem a influência das variáveis causais externas

Família	Algoritmo	Melhor Método	RMSE Treino	RMSE Teste	% Melhoria RMSE	WMAPE Treino	WMAPE teste	% Melhoria WMAPE
Fungicida 1	Naive	Naive	235.780	822.758	N/A	55,9	39,4	N/A
	Automático	SVM Linear	119.413	369.391	-55%	30,1	21,0	-47%
	Competição	SVM Linear	119.413	369.391	-55%	30,1	21,0	-47%
	Combinado	Composto	105.128	412.031	-50%	26,7	21,1	-46%

Autor, 2022.

Observa-se que ao considerar o RMSE de Treino e WMAPE de Treino, que são os dados históricos utilizados para treinamento e construção do modelo matemático, o melhor resultado entre os quatro modelos foi o algoritmo combinado, que é uma técnica de aprendizado de máquina, que permite a combinação de vários algoritmos, ponderando o resultado pelo desempenho da acurácia. Este método é chamado de Composto e o resultado do WMAPE foi de aproximadamente 26,7%. Já em relação ao RMSE de Teste e WMAPE de teste, que são os dados históricos de aplicação do modelo matemático, o melhor resultado foi o algoritmo de Competição, utilizando o método de SVM Linear, que também é uma técnica que utiliza o aprendizado de máquina, com o resultado do WMAPE de aproximadamente 21,0%.

Além disso, ao comparar o desempenho de acuracidade para amostras de testes, entre o algoritmo mais simples, que é o método de *Naive* e o algoritmo mais robusto, que é o método de Competição, tem-se uma redução de 55% na medida de erro de acurácia de RMSE e uma redução de 47% na medida de erro de acurácia do WMAPE, evidenciando a melhoria ao utilizar as técnicas de aprendizado de máquina.

A Tabela 10 evidencia o segundo grupo de análise que contém as variáveis causais externas, exemplificado pela família de fungicida 1.

Tabela 10 - Algoritmos modelados com a influência das variáveis causais externas

Família	Algoritmo	Melhor Método	RMSE Treino	RMSE Teste	% Melhoria RMSE	WMAPE Treino	WMAPE teste	% Melhoria WMAPE
Fungicida 1	Naive	Naive	235.780	822.758	N/A	55,9	39,4	N/A
	Competição_Causal	GBM	74.118	357.135	-57%	19,5	11,9	-70%
	Combinado_Causal	Composto	86.997	400.845	-51%	22,5	17,2	-56%

Autor, 2022.

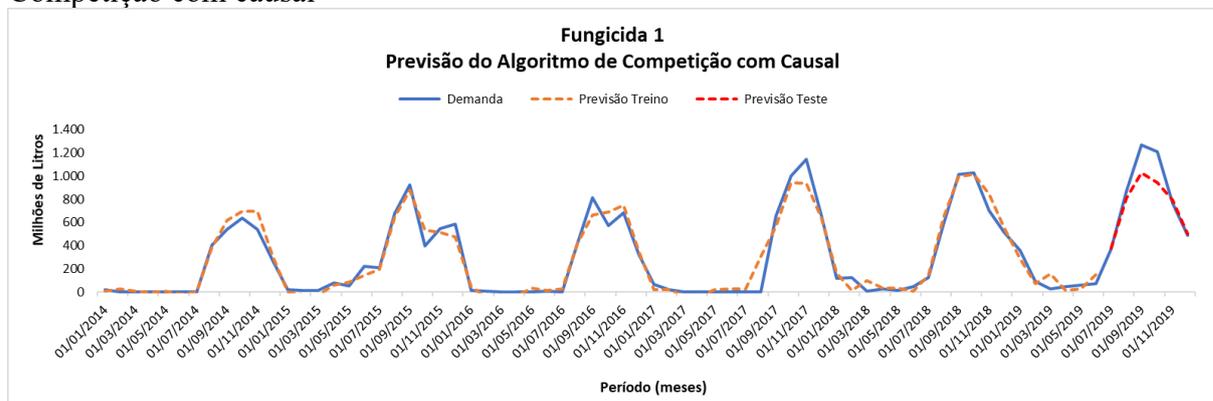
Neste grupo, ambas as métricas de acuracidade de RMSE e WMAPE, tanto para amostras de treino, quanto de teste, obteve-se o melhor resultado utilizando o algoritmo de

competição, através da técnica de GBM com WMAPE de aproximadamente 19,5% para treino e 11,9% para teste.

Ao comparar esses modelos com o método de *Naive* que consiste no algoritmo mais simples, tem-se uma redução na medida do erro de acurácia para RMSE em torno de 57% e WMAPE em torno de 70%, o que evidencia a melhoria do modelo com as variáveis causais externas em conjunto com a técnica de aprendizado de máquina. As demais análises das famílias de fungicidas encontram-se no Apêndice B.

A Figura 19 apresenta os gráficos com a previsão de demanda do melhor modelo selecionado para a família de fungicida 1, utilizando o algoritmo de Competição com Causal, com a técnica de GBM.

Figura 19 - Gráfico com as previsões do al Perfil de Demanda Fungicida 1 algoritmo de Competição com causal

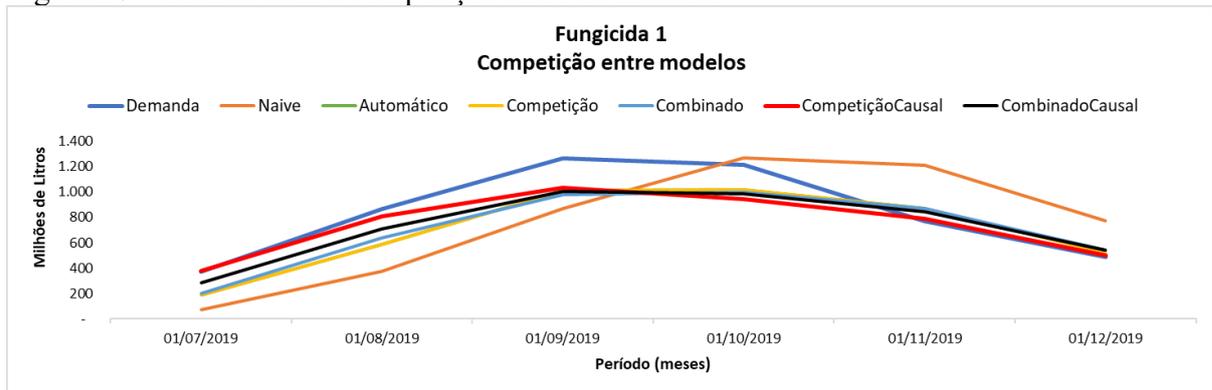


Autor, 2022

Os valores reais de demanda são mostrados na linha azul sólida. Os valores previstos para amostra de treino são mostrados na linha laranja pontilhada. Por fim, os valores previstos para amostra de teste são representados pela linha vermelha pontilhada. Observa-se que, tanto a previsão para amostra de treino, quanto a previsão da amostra de teste, estão bem próximas da demanda real, na qual corrobora um erro de acurácia mais baixo.

A Figura 20 apresenta um gráfico com a competição dos seis modelos comparando com a demanda real, sendo a linha sólida em azul a demanda real; a linha sólida em laranja, algoritmo de *Naive*; a linha sólida em verde, algoritmo Automático; a linha sólida amarela, algoritmo de Competição; a linha sólida em roxo, algoritmo Combinado; a linha sólida em vermelho, algoritmo de Competição com causal, por último, a linha sólida em preto, algoritmo combinado com causal.

Figura 20 - Gráfico com a competição entre os modelos



Autor, 2022.

Observa-se que nos três primeiros meses de previsão o algoritmo de competição com causal (linha sólida vermelha), obteve-se mais próximo da demanda real (linha sólida azul). No quarto mês de previsão houve-se uma previsão de demanda mais pessimista em relação à demanda real, em todos os modelos de aprendizado de máquina. E por fim, nos últimos dois meses de previsão, o algoritmo de competição com causal, apresenta novamente o melhor resultado, o que evidencia graficamente que na competição entre os seis métodos, o algoritmo de competição com causal foi o melhor.

A Figura 21, apresenta as variáveis causais que foram consideradas no modelo de competição com causal para a família de fungicida 1.

Figura 21 - Variáveis causais selecionadas para Família Fungicida 1

Família	Algoritmo	Causal	Tipo de Causal	Grau de Importância	Nível de Importância
Fungicida 1	CompetiçãoCausal	Índice Sazonal_mês_12	Causal interna	100	Alta
		Demanda_mês_1	Causal interna	20	Baixo
		Tendência	Causal interna	13	Baixíssimo
		Índice de Importação Brasil_mês_2	Causal externa	10	Baixíssimo
		Demanda_mês_4	Causal interna	8	Baixíssimo
		Índice de Inflação de Alimentos_mês_7	Causal externa	6	Baixíssimo
		Demanda_mês_2	Causal interna	3	Baixíssimo
		Índice Sazonal_mês_13	Causal interna	1	Baixíssimo

Autor, 2022.

Verifica-se que a maioria das variáveis selecionadas foram causais internas de sazonalidade, nível de demanda e tendência, sendo a de maior importância a variável de sazonalidade. Além disso, das seis variáveis causais externas que foram propostas, apenas duas delas foram utilizadas nessa família de produto, que são as variáveis econômicas de índice de importação e de inflação de alimentos.

A Tabela 11 apresenta os valores de RMSE e WMAPE de treino e teste, ponderado pelo volume médio referente as seis famílias de produto, para obter o RMSE e WMAPE do segmento Fungicida para cada modelo apresentado.

Tabela 11 - Análise ponderada da Família Fungicida

Algoritmo	RMSE Médio		WMAPE Médio		% Família com Melhor Desempenho	% Família com Melhor Desempenho Permitindo 10% de desvio
	Ponderado Treino	Ponderado Teste	Ponderado Treino	Ponderado Teste		
Naive	216.473	700.941	53,9	39,4	0%	0%
Automático	113.018	310.384	31,9	18,5	17%	0%
Competição	105.741	297.100	29,7	16,2	33%	50%
Combinado	100.873	348.829	26,9	18,5	0%	0%
Competição com causal	83.675	247.047	26,8	15,2	33%	33%
Combinado com causal	79.196	293.508	23,5	17,9	17%	17%

Autor, 2022.

De modo geral, o modelo com o melhor desempenho na amostra de treino foi o método combinado com causal com WMAPE de 23,5% e na amostra de teste foi o modelo de competição com causal com WMAPE de 15,2%.

Observa-se também que 100% das famílias de fungicida tiveram o melhor desempenho utilizando as técnicas de aprendizado de máquina, e 50% das famílias de produtos, utilizaram o modelo que contém as variáveis causais externas. A mesma análise se aplica quando se permite um desvio de 10% no erro de acurácia final.

Outro fator importante é que 66% das famílias de produtos utilizou o método de competição entre modelos e, quando aplicado um desvio de 10% no erro de acurácia, esse percentual aumenta para 83%, o que novamente evidencia a melhora que se tem na acuracidade de previsão de demanda, em utilizar técnicas de aprendizado de máquina.

A Tabela 12 mostra a comparação em relação ao desempenho de acuracidade de previsão de demanda, entre a técnica utilizada pela empresa por análise de julgamento e os melhores métodos selecionados para cada família de produto.

Tabela 12 - Comparativo WMAPE de teste da empresa X melhor modelo proposto

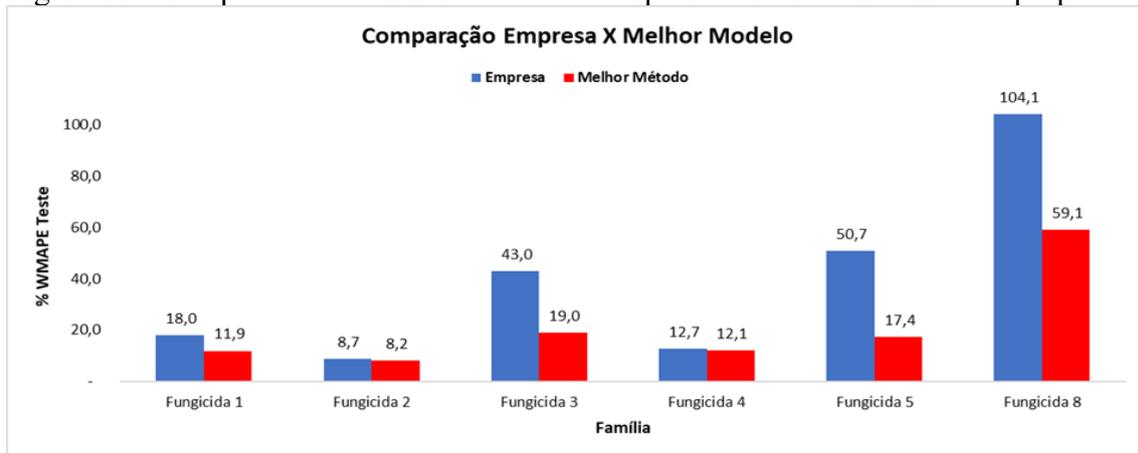
Família	Empresa		FEI		% Melhoria
	Método	WMAPE Médio Ponderado Teste	Melhor Método	WMAPE Médio Ponderado Teste	
Fungicida 1	Análise de Julgamento	18,0	GBM	11,9	-34%
Fungicida 2	Análise de Julgamento	8,7	Arimax	8,2	-6%
Fungicida 3	Análise de Julgamento	43,0	GBM	19,0	-56%
Fungicida 4	Análise de Julgamento	12,7	QRF	12,1	-5%
Fungicida 5	Análise de Julgamento	50,7	Composto	17,4	-66%
Fungicida 8	Análise de Julgamento	104,1	SVM Linear	59,1	-43%
Geral		20,4		12,9	-37%

Autor, 2022.

Observa-se que 100% dos métodos selecionados são técnicas de aprendizado de máquina, com percentual de redução do erro de acurácia variando entre 5% e 66%. Nota-se também que, para o segmento de família de fungicida na análise ponderada, houve uma redução no erro de acurácia de 37%.

Na Figura 22, é apresentado um gráfico de colunas, com o comparativo do WMAPE realizado pela empresa *versus* melhor modelo proposto.

Figura 22 - Comparativo WMAPE de teste da empresa versus melhor modelo proposto



Autor, 2022.

As barras em azul são os valores de WMAPE calculados pela previsão de demanda da empresa e as barras em vermelho são os valores de WMAPE calculados pela previsão de demanda desenvolvida nesta dissertação. Conclui-se que em todos os casos da família de fungicida, obteve-se uma melhoria no desempenho da acuracidade de previsão de demanda, sendo mais significativa nas famílias de fungicidas 1, 3, 5 e 8.

## 5 DISCUSSÃO DOS RESULTADOS

Após as análises dos resultados, é possível identificar a influência que a utilização de técnicas de aprendizado de máquina, interferem no planejamento de demanda. Em 100% dos casos das séries temporais do segmento da família de produto de fungicida, o modelo propôs os melhores métodos utilizando aprendizado de máquina, o que evidencia também que as técnicas de aprendizado de máquina, para aplicação deste estudo de caso, tiveram um comportamento melhor do que as técnicas clássicas de séries temporais e do que os métodos qualitativos praticados pela empresa, resultando assim, num impacto positivo para redução do erro de acurácia.

Em 50% dos casos das séries temporais, a utilização de variáveis causais externas, também influenciou na redução do erro de acurácia, e em 100% dos casos as variáveis causais internas contribuíram para melhoria do modelo, reduzindo o erro de acurácia de cada previsão proposta, ou seja, utilizar variáveis causais internas e/ ou externas, impactam positivamente na previsão de demanda, contudo, no caso das variáveis causas externas é importante explorar e definir de forma adequada, quais os fatores que podem influenciar no planejamento de demanda de cada família e/ou segmento de produto.

De modo geral, os modelos propostos utilizando os algoritmos de aprendizado de máquina e variáveis causais, tiveram um impacto significativo na construção dos modelos, gerando um WMAPE de 12,9 % dos modelos propostos *versus* um WMAPE de 20,4 % calculado pelo método qualitativo, por meio da técnica de ajuste de julgamento da empresa. Resultando assim, em uma melhoria de 37% no planejamento de demanda.

Além disso, outro ponto de discussão importante, é que as empresas aplicam o mesmo método para todas as séries temporais independente do SKU e família de produto. Todavia, observa-se com as análises de resultados, que para cada família de produto foi proposto um método diferente, por se tratar de perfis de demanda distintas com variabilidade diferente, ou seja, é importante selecionar a técnica mais adequada para cada perfil de demanda.

Pode-se perceber também, que o modelo de competição foi o melhor modelo, pois representou 83% das famílias de fungicidas, considerando um desvio de até 10% em relação ao erro de acurácia.

E por fim, o tempo de processamento também é um fator importante de análise, pois para cada família de produto demorou-se aproximadamente 10 minutos para execução dos seis modelos propostos das seis famílias de produto. Ou seja, o *software* executa um modelo mais robusto, contendo variáveis causais internas e externas e, ainda sim, com um rápido tempo de processamento, no qual viabiliza a construção e execução em massa de um portfólio de produto.

## 6 CONCLUSÃO

A gestão de demanda é uma área que está crescendo muito nas organizações, devido ao impacto que traz em toda a cadeia de suprimento, seja em efetivar o planejamento de compra necessária para fabricação de materiais, seja no planejamento de reabastecimento dos estoques, ou até mesmo na entrega final dos produtos e/ ou serviços aos clientes.

Executar um planejamento de demanda de forma adequada, possibilita a redução dos níveis de estoques, redução de custos com armazenagens de estoque desnecessárias, além de possibilitar uma melhor gestão dos inventários, reduzindo os estoques em excessos e em falta, contribuindo assim, para uma cadeia de suprimentos mais eficiente.

O presente trabalho alcançou o objetivo da proposto avaliando os impactos em utilizar técnicas de aprendizado de máquina e a influência das variáveis causais na acuracidade de previsão de demanda, por meio de análises do estudo de caso numa empresa de agronegócio, respondendo as principais questões de pesquisa.

A primeira questão de pesquisa avalia qual o impacto na utilização de técnicas de aprendizado de máquina e *Big Data* na previsão de demanda? A resposta obtida foi que a utilização dos algoritmos de aprendizado de máquina contribuiu para a redução do erro de acurácia, em 100% dos casos das famílias de produtos, o que corrobora com a proposta de que a utilização de técnicas de aprendizado de máquina na previsão de demanda traz um impacto positivo na construção dos modelos, sendo melhores do que as técnicas clássicas de séries temporais.

A segunda questão de pesquisa compara se existe diferença entre as técnicas tradicionais de séries temporais *versus* técnicas de aprendizado de máquina? Para responder a essa pergunta, observou-se que em 100% dos casos de família de fungicida o erro de acurácia da série clássica de *Naive* foi maior do que o erro de acurácia dos modelos utilizando algoritmos de aprendizado de máquina. Um exemplo disso é na análise geral de todas as famílias de produtos, em que se obteve um erro médio ponderado com WMAPE de 39,4% utilizando a técnica de *Naive versus* um WMAPE de 16,2 %, utilizando técnicas de aprendizado de máquina, o que evidencia uma diferença significativa de 58,9% entre a utilização de modelos clássicos de séries temporais *versus* modelos de aprendizado de máquina.

A terceira questão de pesquisa analisa qual a influência da utilização de variáveis causais na previsão de demanda? Para responder a terceira pergunta de pesquisa deste trabalho, analisou-se a influência em utilizar as variáveis causais nos modelos de previsão de demanda. Essa análise foi realizada em dois aspectos. O primeiro aspecto avaliando a influência das variáveis causais internas no modelo, onde em 100% dos casos dos métodos propostos, utilizou-

se de variáveis causais internas, que ajudou na redução do erro de acurácia. Já no segundo aspecto, avaliando a influência de variáveis causais externas no modelo, na qual em apenas 50% dos casos foram utilizadas para ajudar na redução do erro de acurácia.

Com a finalização de todas as etapas de pesquisa, é possível afirmar que as variáveis causais influenciam positivamente na previsão de demanda, todavia, deve-se analisar cuidadosamente quais variáveis são relevantes para serem incorporadas ao modelo.

Outro fator relevante deste trabalho é que em 100% dos casos, os melhores métodos propostos desempenham um erro de acuracidade menor do que o método de análise de julgamento previsto pela empresa, tendo um erro de acurácia geral de 20,4% da empresa *versus* 12,9% dos modelos propostos, resultando numa redução do erro de acurácia de 36,7%.

Além disso, a família de produto que obteve o maior desempenho entre a previsão de demanda calculada pela empresa *versus* modelo proposto foi fungicida 5, com uma redução de 65,7% do erro de acurácia, sendo o WMAPE calculado pela empresa de 50,7% e o WMAPE calculado pelo modelo proposto de 17,4%.

Comparando este método de pesquisa com os artigos encontrados na literatura, verifica-se semelhanças nos artigos explorados em estabelecer competições e combinações entre diferentes modelos para evidenciar as diferenças de técnicas aplicadas, bem como interferência no desempenho na acuracidade de previsão de demanda. No artigo de Pradita et al (2020), utilizou-se de métodos de análise quantitativa ARIMA e SARIMA, combinando com análise qualitativa de ajuste de julgamento para melhorar a previsão de demanda de contêineres refrigerados de 20 e 40 pés na Indonésia, resultando num aumento de previsão de 40%.

Na pesquisa de Ferro et al (2019), também aplicou um método de competição e combinação entre séries temporais utilizando as técnicas de ARIMA e suavização exponencial para verificar se havia mudanças significativas na acuracidade de demanda, em três famílias de produtos de uma empresa do ramo de eletrodomésticos. Como resultado, desta pesquisa, somente uma família de produto obteve-se uma melhoria na acuracidade de previsão de demanda, nas demais, a aplicação única do modelo de suavização exponencial foi melhor.

E por fim, na pesquisa de Werner e Ribeiro (2006), também utilizou métodos comparativos para análise de previsões de demanda, utilizando de regressão linear e ajuste de julgamento, para prever a demanda de uma prestadora de serviços de assistência técnica de computadores. Como resultado obteve-se uma melhoria na acuracidade de previsão de demanda em 7,5%.

As principais vantagens em utilizar variáveis causais e modelos de aprendizado de máquina no planejamento de demanda são:

- a) melhoria na acuracidade de previsões de demanda;
- b) redução dos níveis de estoques de segurança e estoque de ciclo para atendimento da demanda;
- c) redução no custo de inventário devido à redução no volume de produtos armazenados, o que possibilita uma maior vantagem competitiva no mercado;
- d) maior eficiência na gestão da cadeia de suprimentos, reduzindo os efeitos chicotes;
- e) melhor nível de atendimento ao cliente, com entregas mais rápidas, no local certo, com produto correto;
- f) maior análise de dados e análises de sensibilidade que apoiam nas tomadas de decisão estratégica do planejamento de demanda.

Conclui-se, então, que as principais contribuições deste trabalho de pesquisa foram: avaliar o desempenho da acuracidade de previsão de demanda comparando métodos clássicos de séries temporais, com métodos de aprendizado de máquina; verificar as influências das variáveis causais internas e externas nos modelos de previsão de demanda; utilizar *software* de planejamento de demanda com modelos mais robustos, de fácil utilização e com um rápido tempo de processamento; e por fim, estruturar uma revisão sistemática da literatura, com as pesquisas mais recentes dos estudiosos da área de gestão de demanda e *Supply Chain 4.0*, com intuito de utilizar as melhores pesquisas praticadas no mercado.

As principais limitações nesta pesquisa foram: realizar a modelagem e simulação de dados em apenas um *software* de processamento de planejamento de demanda; aplicar o estudo de caso somente em uma empresa do segmento de agronegócio; utilizar a amostra de dados, com produtos com ciclo de vida que já tenha passado pela fase de maturidade no mercado e utilizar somente o histórico do pedido de vendas para previsão de demanda.

Finalmente, para dar continuidade a este estudo sugere-se como pesquisa futura, um estudo de caso em empresas varejistas com o objetivo de localizar *gaps* dentro de planejamento de demanda, que por sua vez, possibilitará a comparação dos resultados da pesquisa com segmento do setor de agroindústria; estabelecer uma relação de estudos entre os modelos de *Bottom-Up* e *Top-Down*, realizando a análise com cluster de produtos; utilizar outro *software* computacional para comparação de modelos como por exemplo, SAP IBP, *Forecast Pro*; acrescentar também como estudos a comparação entre históricos de pedidos de vendas e pontos de vendas; fazer uma análise entre os diferentes níveis de agregação temporal. Propõem-se, dessa maneira, a exemplo da atual pesquisa, buscar os mais recentes estudos dentro da área no Brasil e no mundo.

## REFERÊNCIAS

AGRAWAL, P. ET AL. Analysis of barriers in implementation of digital transformation of supply chain using interpretive structural modelling approach. **Journal of Modeling in Management**, v. 15, n. 1, p. 297-317, 2020. DOI: 10.1108 / JM2-03-2019-0066 Disponível em: <https://www-scopus.ez328.periodicos.capes.gov.br/record/display.uri?eid=2-s2.0-85074714300&origin=resultslist&sort=plf-f&src=s&sid=0d79cce6fcd9cd55410551387787dc24&sot=b&sdt=b&sl=146&s=TITLE-ABS-KEY%28%22Analysis+of+barriers+in+implementation+of+digital+transformation+of+supply+chain+using+interpretive+structural+modelling+approach%22%29&relpos=0&citeCnt=14&searchTerm=>. Acesso em: 10 dez. 2020.

ASTILL, J. ET AL. Smart poultry management: smart sensors, Big Data, and the internet of things. **Computers and Electronics in Agriculture**, 2020. DOI: <https://doi.org/10.1016/j.compag.2020.105291> Disponível em: <https://www.sciencedirect.com/science/article/pii/S0168169918316363>. Acesso em: 29 nov. 2020.

BASSON, L.M; KILBOURN, P.J; WALTERS, J. Forecast accuracy in demand planning: A fast-moving consumer goods case study. **Journal of Transport and Supply Chain Management**, 2019. DOI: 10.4102 / jtscm.v13i0.427. Disponível em: <https://www.scopus.com/record/display.uri?eid=2-s2.0-85078792825&origin=resultslist&sort=plf-f&src=s&st1=&st2=&sid=c509b1f2913c776c161e46722098d7b2&sot=b&sdt=b&sl=95&s=TITLE-ABS-KEY+%28%22Forecast+accuracy+in+demand+planning%3a+A+fast-moving+consumer+goods+case+study%22%29&relpos=0&citeCnt=2&searchTerm=> . Acesso em: 02 mar. 2021.

BECK, T; ANZANELLO, M. Análise da gestão de estoques utilizando simulação de monte Carlo. **Revista Gestão Industrial**. 2015. DOI: 10.3895/gi.v11n4.2967. Disponível em: <https://www.semanticscholar.org/paper/AN%C3%81LISE-DA-GEST%C3%83O-DE-ESTOQUES-UTILIZANDO-SIMULA%C3%87%C3%83O-Beck-Anzanello/6b628069273bea125b1fe74077f260393c064b24> . Acesso em: 29 set. 2019.

BELVEDERE, V.; GOODWIN, P. The influence of product involvement and emotion on short-term product demand forecasting. **International Journal of Forecasting**, v. 33, p. 652-661, 2017. DOI: 10.1016 / j.ijforecast.2017.02.004. Disponível em: <https://www.scopus.com/record/display.uri?eid=2-s2.0-85018472156&origin=resultslist&sort=plf-f&src=s&st1=&st2=&sid=a93fd3a37210e1f9b5dd7e77df0d927d&sot=b&sdt=b&sl=106&s=TITLE-ABS-KEY%28%22The+influence+of+product+involvement+and+emotion+on+short-term+product+demand+forecasting%22%29&relpos=0&citeCnt=3&searchTerm=>. Acesso em: 19 mar. 2021.

BERGMAN, J.J. ET AL. A Bayesian approach to demand forecasting for new equipment programs. **Robotics and Computer-Integrated Manufacturing**, v. 47, p. 17-21, 2017. DOI: 10.1016 / j.rcim.2016.12.010. Disponível em: <https://www.scopus.com/record/display.uri?eid=2-s2.0-85008474390&origin=resultslist&sort=plf-f&src=s&st1=&st2=&sid=de6696a33d736400e7483f9f3bc5a50&sot=b&sdt=b&sl=85&s=TITLE-ABS-KEY%28%22A+Bayesian+approach+to+demand+forecasting+for+new+equipment+programs%22%29&relpos=0&citeCnt=8&searchTerm=> . Acesso em: 19 mar. 2021.

BÜYÜKÖZKAN, G.; GÖÇER. F. Digital Supply Chain: literature review and a proposed framework for future research. **Computers in Industry**, v. 97, p.157–177, 2018. DOI: 10.1016 / j.compind.2018.02.010 Disponível em: <https://www.scopus.com/record/display.uri?eid=2-s2.0-85042861929&origin=resultslist&sort=plf-f&src=s&sid=dce37e6103688ccbb9fc26c6b890dd79&sot=b&sdt=b&sl=57&s=TITLE-ABS-KEY%28%22Digital+Supply+Chain%3a+literature+review+%22%29&relpos=0&citeCnt=163&searchTerm=> . Acesso em: 22 nov. 2020.

CALATAYUD, A. ET AL. The self-thinking supply chain. **Supply Chain Management**, v. 24, n. 1, p. 22-38, 2019. DOI: 10.1108 / SCM-03-2018-0136. Disponível em: <https://www.scopus.com/record/display.uri?eid=2-s2.0-85058852929&origin=resultslist&sort=plf-f&src=s&st1=%22The+self-thinking+supply+chain%22&st2=&sid=2f2d471e491ab32e0455529ddab7842e&sot=b&sdt=b&sl=47&s=TITLE-ABS-KEY%28%22The+self-thinking+supply+chain%22%29&relpos=0&citeCnt=14&searchTerm=> . Acesso em: 10 dez. 2020.

CASSETTARI, L. ET AL. A new stochastic multi source approach to improve the accuracy of the sales forecasts. **Foresight**, v. 19, p. 48-64, 2017. DOI: 10.1108 / FS-07-2016-0036. Disponível em: <https://www.scopus.com/record/display.uri?eid=2-s2.0-85014810343&origin=resultslist&sort=plf-f&src=s&st1=&st2=&sid=1d446b11ea112273d08ae5ff45994789&sot=b&sdt=b&sl=102&s=TITLE-ABS-KEY%28%22A+new+stochastic+multi+source+approach+to+improve+the+accuracy+of+the+sales+forecasts%22%29&relpos=0&citeCnt=4&searchTerm=>. Acesso em: 19 mar. 2021.

CHIANG, C.Y.; LIN, W.T.; SURESH, N.C. An empirically-simulated investigation of the impact of demand forecasting on the bullwhip effect: evidence from U.S. auto industry. **International Journal of Production Economics**, v.177, p. 53-65, 2016. DOI: 10.1016 / j.ijpe.2016.04.015. Disponível em: <https://www-scopus.ez328.periodicos.capes.gov.br/record/display.uri?eid=2-s2.0-84971657607&origin=resultslist&sort=plf-f&src=s&st1=&st2=&sid=c4d0f25617ca521d069d65af215d1e3c&sot=b&sdt=b&sl=114&s=TITLE-ABS-KEY%28%22An+empirically-simulated+investigation+of+the+impact+of+demand+forecasting+on+the+bullwhip+effect%22%29&relpos=0&citeCnt=13&searchTerm=>. Acesso em: 7 mar. 2021.

COLLIER, R. **O sucesso é a soma de pequenos esforços repetidos dia após dia**. Disponível em: [https://www.pensador.com/autor/robert\\_collier/](https://www.pensador.com/autor/robert_collier/). Acesso em: 16 jun. 2021.

COUPA. **Supply Chain Guru**. Coupa, 2021. Disponível em: <https://coupa.com/supply-chain-guru/>. Acesso em: 26 ago. 2021.

CRESWELL, J.W. **Projeto de pesquisa: método qualitativo, quantitativo e misto**. 2. ed. Porto Alegre, Artmed, 2007.

CROXTON, K.L. ET AL. The demand management process. **The International Journal of Logistics Management**, v. 13, p. 51-66, 2002. DOI: 10.1108 / 09574090210806423. Disponível em: <https://www-scopus.ez328.periodicos.capes.gov.br/record/display.uri?eid=2-s2.0-33644590127&origin=resultslist&sort=plf-f&src=s&st1=&st2=&sid=859be230a388ba627ecf519148eb42b0&sot=b&sdt=b&sl=47&s=TITLE-ABS-KEY+%28%22The+Demand+Management+Process%22%29&relpos=8&citeCnt=79&searchTerm=>. Acesso em 28 fev. 2021.

DREYER, H.C. ET AL. Proposals for enhancing tactical planning in grocery retailing with S&OP. **International Journal of Physical Distribution & Logistics Management**, v. 48, p.114-138, 2018. DOI: 10.1108 / IJPDLM-01-2017-0018. Disponível em: <https://www.scopus.com/record/display.uri?eid=2-s2.0-85042687392&origin=resultslist&sort=plf-f&src=s&st1=&st2=&sid=4b37a343933b05134034d618c301d352&sot=b&sdt=b&sl=50&s=TITLE-ABS-KEY+%28%22Proposals+for+enhancing+tactical%22%29&relpos=0&citeCnt=7&searchTerm=>. Acesso em: 02 mar. 2021.

FERRARI, A. T. **Metodologia da pesquisa científica**. São Paulo: McGraw-Hill do Brasil, 1982.

FERRO, W.A. ET AL. Combinações de Métodos Quantitativos na Previsão de Demanda de Vendas de Eletrodomésticos. **Gestão da Produção**, v. 14, nº 5, p. 67 - 88, 2019. DOI:10.15675/gepros.v14i5.2416. Disponível em: [https://www.researchgate.net/publication/336981095\\_Combinacoes\\_de\\_Metodos\\_Quantitativos\\_na\\_Previsao\\_de\\_Demanda\\_de\\_Vendas\\_de\\_Eletrrodomesticos\\_Combinations\\_of\\_Quantitative\\_Methods\\_in\\_the\\_Forecast\\_for\\_Demand\\_for\\_Sales\\_of\\_Home\\_Appliances](https://www.researchgate.net/publication/336981095_Combinacoes_de_Metodos_Quantitativos_na_Previsao_de_Demanda_de_Vendas_de_Eletrrodomesticos_Combinations_of_Quantitative_Methods_in_the_Forecast_for_Demand_for_Sales_of_Home_Appliances). Acesso em: 08 abr. 2022.

FILDES, R.; MA S; KOLASSA, S. Retail forecasting: research and practice. **International Journal of Forecasting**, 2019. DOI: <https://doi.org/10.1016/j.ijforecast.2019.06.004>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S016920701930192X?via%3Dihub>. Acesso em: 20 set. 2020.

FILDES, R. ET AL. **Effective forecasting and judgmental adjustments: an empirical evaluation and strategies for improvement in Supply Chain planning**. **International Journal of Forecasting**, 2009. DOI: <https://doi.org/10.1016/j.ijforecast.2019.06.004>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S016920701930192X?via%3Dihub>. Acesso em: 27 set. 2020.

GARAY-RONDERO, C.L. ET AL. Digital supply chain model in Industry 4.0. **Journal of Manufacturing Technology Management**, v. 31, p. 887-933, 2019. DOI: 10.1108 / JMTM-08-2018-0280. Disponível em: <https://www-scopus.ez328.periodicos.capes.gov.br/record/display.uri?eid=2-s2.0-85077979984&origin=resultslist&sort=plf-f&src=s&sid=14d5277dbfbeat1ed323af970a58b8889&sot=b&sdt=b&sl=59&s=TITLE-ABS-KEY%28%22Digital+supply+chain+model+in+Industry+4.0%22%29&relpos=0&citeCnt=22&searchTerm=>. Acesso em: 4 abr. 2021.

GIL, A, C. **Métodos e técnicas de pesquisa social**. 6. ed. São Paulo: Atlas, 2008. Disponível em: <https://ayanrafael.files.wordpress.com/2011/08/gil-a-c-mc3a9todos-e-tc3a9cnicas-de-pesquisa-social.pdf>. Acesso em: 13 jun. 2021.

GOSLING, G. D; BALLARD, D. Addressing Household Income Distribution in Air Travel Demand Models: Case Study of the Baltimore–Washington Region. **Transportation Research Record**, V. 2673, P. 491-502, 2019. DOI: 10.1177/0361198118823197. Disponível em: <[https://www-scopus.ez328.periodicos.capes.gov.br/record/display.uri?eid=2-s2.0-85060945884&origin=resultslist&sort=plf-f&src=s&sid=1b13e8cb8c4cf31d49e9e5585fa0d63b&sot=b&sdt=b&sl=132&s=TITLE-ABS-KEY%28%22Addressing+Household+Income+Distribution+in+Air+Travel+Demand+Models%3a+Case+Study+of+the+Baltimore%e2%80%93Washington+Region%22%29&relpos=0&citeCnt=1&searchTerm=>](https://www-scopus.ez328.periodicos.capes.gov.br/record/display.uri?eid=2-s2.0-85060945884&origin=resultslist&sort=plf-f&src=s&sid=1b13e8cb8c4cf31d49e9e5585fa0d63b&sot=b&sdt=b&sl=132&s=TITLE-ABS-KEY%28%22Addressing+Household+Income+Distribution+in+Air+Travel+Demand+Models%3a+Case+Study+of+the+Baltimore%e2%80%93Washington+Region%22%29&relpos=0&citeCnt=1&searchTerm=)>. Acesso em: 05 maio 2021.

HARTZEL, K. S.; WOOD, C.A. Factors that affect the improvement of demand forecast accuracy through point-of-sale reporting. **European Journal of Operational Research**, v. 260, p. 171-182, 2017. DOI: 10.1016 / j.ejor.2016.11.047. Disponível em: <https://www-scopus.ez328.periodicos.capes.gov.br/record/display.uri?eid=2-s2.0-85009356015&origin=resultslist&sort=plf-f&src=s&st1=&st2=&sid=397bbf4df6fc1cec1daec6c226963045&sot=b&sdt=b&sl=112&s=TITLE-ABS-KEY%28%22Factors+that+affect+the+improvement+of+demand+forecast+accuracy+through+point-of-sale+reporting%22%29&relpos=0&citeCnt=7&searchTerm=>. Acesso em: 7 mar. 2021.

HOFMANN, E.; RUTSCHMANN, E. Big Data analytics and demand forecasting in supply chains: a conceptual analysis. **International Journal of Logistics Management**, v. 29, p. 739-766, 2018. DOI: 10.1108 / IJLM-04-2017-0088. Disponível em: <https://www.scopus.com/record/display.uri?eid=2-s2.0-85047937964&origin=resultslist&sort=plf-f&src=s&st1=&st2=&sid=595a95c1ae8ec99d87e7a82179447e82&sot=b&sdt=b&sl=98&s=TITLE-ABS-KEY%28%22Big+data+analytics+and+demand+forecasting+in+supply+chains%3a+a+conceptual+analysis%22%29&relpos=0&citeCnt=32&searchTerm=>. Acesso em: 19 mar. 2021.

HOSSEINI, S; IVANOV, D; DOLGUI, A. Review of quantitative methods for supply chain resilience analysis. **Transportation Research Part E: Logistics and Transportation Review**, v. 125, p. 285-307, 2019. DOI: 10.1016 / j.tre.2019.03.001. Disponível em: <https://www-scopus.ez328.periodicos.capes.gov.br/record/display.uri?eid=2-s2.0-85063228583&origin=resultslist&sort=plf-f&src=s&st1=&st2=&sid=e4ca5fcb6c8fea32cd6f734dc84d3e5e&sot=b&sdt=b&sl=84&s=TITLE-ABS-KEY%28%22Review+of+quantitative+methods+for+supply+chain+resilience+analysis%22%29&relpos=0&citeCnt=139&searchTerm=>. Acesso em: 30 mar. 2021.

HUANG, H; LIU, Q. Intelligent retail forecasting system for new clothing products considering stock-out. **Fibres & textiles in eastern Europe**, v. 25, p. 10-16, 2017. DOI: 10.5604 / 12303666.1227876. Disponível em: <https://www-scopus.ez328.periodicos.capes.gov.br/record/display.uri?eid=2-s2.0-85014488562&origin=resultslist&sort=plf-f&src=s&st1=&st2=&sid=aa32bab16e9d88fd812ef22ae79e7fa2&sot=b&sdt=b&sl=103&s=TITLE-ABS-KEY+%28%22Intelligent+Retail+Forecasting+System+for+New+Clothing+Products+Considering+Stock-out%22%29&relpos=0&citeCnt=4&searchTerm=>. Acesso em: 27 fev. 2021.

JULIANELLI, L. **Comparação entre as abordagens Top-Down e Bottom-Up para previsão de vendas**. ILOS. 2004. Disponível em: <https://www.ilos.com.br/web/comparacao-entre-as-abordagens-top-down-e-bottom-up-para-previsao-de-vendas/#:~:text=Na%20abordagem%20Bottom%20Up%2C%20a,de%20produtos%20ou%20por%20regi%C3%B5es..> Acesso em 28 fev. 2021.

KAPLAN, A.; HAENLEIN, M. Siri, Siri in my hand: Who's the fairest in the land? On interpretations,



KEY%28%22Forecast+of+individual+customer%e2%80%99s+demand+from+a+large+and+noisy+dataset%22%29&relpos=0&citeCnt=21&searchTerm=. Acesso em: 7 mar. 2021.

NARAYANAN, A.; SAHIN, F.; ROBINSON, E. P. Demand and order-fulfillment planning: the impact of point-of-sale data, retailer orders and distribution center orders on forecast accuracy. **Journal of Operations Management**, v. 65, p. 468-486, 2019. DOI: 10.1002 / joom.1026. Disponível em: <https://www.scopus.com/record/display.uri?eid=2-s2.0-85064763201&origin=resultslist&sort=plf-f&src=s&st1=&st2=&sid=28ef431ffc84ea829c61c7bceca7a550&sot=b&sdt=b&sl=157&s=TITLE-ABS-KEY%28%22Demand+and+order-fulfillment+planning%3a+The+impact+of+point-of-sale+data%2c+retailer+orders+and+distribution+center+orders+on+forecast+accuracy%22%29&relpos=0&citeCnt=5&searchTerm=>. Acesso em: 4 mar. 2021.

NI, Y; FAN, F. A two-stage dynamic sales forecasting model for the fashion retail. **Expert Systems with Applications**, v. 38, p. 1529-1536, 2011. DOI: 10.1016 / j.eswa.2010.07.065. Disponível em: <https://www.scopus.ez328.periodicos.capes.gov.br/record/display.uri?eid=2-s2.0-78049527759&origin=resultslist&sort=plf-f&src=s&st1=&st2=&sid=ad39f34c9cd73e0cd730588a8a90be0e&sot=b&sdt=b&sl=84&s=TITLE-ABS-KEY+%28%22A+two-stage+dynamic+sales+forecasting+model+for+the+fashion+retail%22%29&relpos=0&citeCnt=31&searchTerm=>. Acesso em: 27 fev. 2021.

PRADITA, S. P. ET AL. Utilizing an intervention forecasting approach to improve reefer container demand forecasting accuracy: a case study in Indonesia. **International Journal of Technology**, v. 11, p. 144-154, 2020. DOI: 10.14716 / ijtech.v11i1.3220. Disponível em: <https://www.scopus.com/record/display.uri?eid=2-s2.0-85079275795&origin=resultslist&sort=plf-f&src=s&st1=&st2=&sid=dd39606de331fea90c5bd89beb7c329b&sot=b&sdt=b&sl=147&s=TITLE-ABS-KEY+%28%22Utilizing+an+Intervention+Forecasting+Approach+to+Improve+Reefer+Container+Demand+Forecasting+Accuracy%3a+A+Case+Study+in+Indonesia%22%29&relpos=0&citeCnt=2&searchTerm=>. Acesso em: 2 mar. 2021.

PRINCES, E. Facing disruptive challenges in supply chain 4.0. **International Journal of Supply Chain Management**, v. 9, p. 52-57, 2020. Disponível em: <https://www-scopus.ez328.periodicos.capes.gov.br/record/display.uri?eid=2-s2.0-85089987667&origin=resultslist&sort=plf-f&src=s&sid=2fe77c7258d0771275227abea5fa1403&sot=b&sdt=b&sl=65&s=TITLE-ABS-KEY%28%22Facing+Disruptive+Challenges+in+Supply+Chain+4.0%22%29&relpos=0&citeCnt=1&searchTerm=>. Acesso em: 4 abr. 2021.

QUEIROZ, M. M. Industry 4.0 and digital supply chain capabilities: A framework for understanding digitalisation challenges and opportunities. **Benchmarking**, 2019. DOI: 10.1108 / BIJ-12-2018-0435. Disponível em: <https://www-scopus.ez328.periodicos.capes.gov.br/record/display.uri?eid=2-s2.0-85077153361&origin=resultslist&sort=plf-f&src=s&sid=c76f782f8ea6e25c60ab2a0b58a56899&sot=b&sdt=b&sl=90&s=TITLE-ABS-KEY%28%22A+framework+for+understanding+digitalisation+challenges+and+opportunities%22%29&relpos=0&citeCnt=20&searchTerm=>. Acesso em: 4 abr. 2021.

ROMANOV, A. ET AL. Discrete and fuzzy models of time séries in the tasks of forecasting and diagnostics. **Axioms**, v. 9, p.49, 2020. DOI: 10.3390 / AXIOMS9020049. Disponível em: <https://www-scopus.ez328.periodicos.capes.gov.br/record/display.uri?eid=2-s2.0-85085703911&origin=resultslist&sort=plf-f&src=s&sid=51cb48a7aa7884bd147edc0d72090e7f&sot=b&sdt=b&sl=101&s=TITLE-ABS-KEY%28%22Discrete+and+Fuzzy+Models+of+Time+Séries+in+the+Tasks+of+Forecasting+and+Diagnostics%22%29&relpos=0&citeCnt=0&searchTerm=>. Acesso em: 31 mar. 2021.

SAGAERT, Y. R. ET AL. Incorporating macroeconomic leading indicators in tactical capacity planning. **International Journal of Production Economics**, v. 209, p. 12-19, 2019. DOI: 10.1016 / j.ijpe.2018.06.016. Disponível em: <https://www.scopus.com/record/display.uri?eid=2-s2.0-85049326644&origin=resultslist&sort=plf-f&src=s&st1=&st2=&sid=f3e2e98504ec14fecc00a2d38cd78bbf&sot=b&sdt=b&sl=93&s=TITLE-ABS-KEY%28%22Incorporating+macroeconomic+leading+indicators+in+tactical+capacity+planning%22%29&relpos=0&citeCnt=5&searchTerm=>. Acesso em: 19 mar. 2021.

SEAMAN, B. Considerations of a retail forecasting practitioner. **International Journal of Forecasting**, v. 34, p.

822-829, 2018. DOI: 10.1016 / j.ijforecast.2018.03.001. Disponível em: <https://www-scopus.ez328.periodicos.capes.gov.br/record/display.uri?eid=2-s2.0-85045548007&origin=resultslist&sort=plf-f&src=s&st1=&st2=&sid=0b0bd8203a17a397cff76ca070108dee&sot=b&sdt=b&sl=69&s=TITLE-ABS-KEY%28%22Considerations+of+a+retail+forecasting+practitioner%22%29&relpos=0&citeCnt=9&searchTerm=>. Acesso em: 27 fev. 2021.

STAUDT, F. H.; GONÇALVES, M. B.; RODRIGUEZ, C. M. T. Procedimento para implantar um modelo de previsão de demanda com incorporação de julgamento de especialistas. **Gestão e Produção**, v. 26, p. 459-475, 2016. DOI: 10.1590 / 0103-6513.054612. Disponível em: <https://www.scopus.com/record/display.uri?eid=2-s2.0-84973577738&origin=resultslist&sort=plf-f&src=s&st1=&st2=&sid=84393e1586e4a8d83bd68a7aaf226522&sot=b&sdt=b&sl=125&s=TITLE-ABS-KEY%28%22Procedimento+para+implantar+um+modelo+de+previs%3%a3o+de+demanda+com+incorpora%3%a7%3%a3o+de+julgamento+de+especialistas%22%29&relpos=0&citeCnt=1&searchTerm=>. Acesso em: 19 mar. 2021.

TRIPATHI, S; GUPTA, M. Transforming towards a smarter supply chain. **International Journal of Logistics Systems and Management**, v. 36, n. 3, p. 319-342, 2019. DOI: 10.1504 / IJLSM.2020.108694. Disponível em <https://www.scopus.com/record/display.uri?eid=2-s2.0-85093866297&origin=resultslist&sort=cp-f&src=s&st1=%22Transforming+towards+a+Smarter+Supply+Chain%22&st2=&sid=2fdd3e2ad277b77db82331edc931dca0&sot=b&sdt=b&sl=60&s=TITLE-ABS-KEY%28%22Transforming+towards+a+Smarter+Supply+Chain%22%29&relpos=0&citeCnt=0&searchTerm=>. Acesso em: 10 dez. 2020.

VAN BELLE, J.; GUNS, T.; VERBEKE, W. Using shared sell-through data to forecast wholesaler demand in multi-echelon supply chains. **European Journal of Operational Research**, v. 288, p. 466-479, 2021. DOI: 10.1016 / j.ejor.2020.05.059. Disponível em: <https://www-scopus.ez328.periodicos.capes.gov.br/record/display.uri?eid=2-s2.0-85086589425&origin=resultslist&sort=plf-f&src=s&st1=&st2=&sid=e05ce2b8e399d2a4ecf149791c342468&sot=b&sdt=b&sl=108&s=TITLE-ABS-KEY%28%22Using+shared+sell-through+data+to+forecast+wholesaler+demand+in+multi-echelon+supply+chains%22%29&relpos=0&citeCnt=0&searchTerm=>. Acesso em: 7 mar. 2021.

VOLLMANN, T. E. ET AL. Teaching supply chain management to business executives. **Production and Operations Management**, v. 9, n. 1, p. 81-90, 2000. DOI: 10.1111 / j.1937-5956.2000.tb00325.x . Disponível em: <https://www-scopus.ez328.periodicos.capes.gov.br/record/display.uri?eid=2-s2.0-0002313384&origin=resultslist&sort=plf-f&src=s&sid=76af2bea9f3a14fef24bb1733324fdd6&sot=b&sdt=b&sl=72&s=TITLE-ABS-KEY%28%22Teaching+supply+chain+management+to+business+executives%22%29&relpos=0&citeCnt=68&searchTerm=>. Acesso em: 29 nov. 2020.

WANG, J.; LIU, Z.; ZHAO, R. On the interaction between asymmetric demand signal and forecast accuracy information. **European Journal of Operational Research**, v. 277, p. 857-874, 2019. DOI: 10.1016 / j.ejor.2019.03.029. Disponível em: <https://www-scopus.ez328.periodicos.capes.gov.br/record/display.uri?eid=2-s2.0-85063860427&origin=resultslist&sort=plf-f&src=s&st1=&st2=&sid=cfc1cb889e8a879527da5ca5e00620ce&sot=b&sdt=b&sl=102&s=TITLE-ABS-KEY%28%22On+the+interaction+between+asymmetric+demand+signal+and+forecast+accuracy+information%22%29&relpos=0&citeCnt=2&searchTerm=>. Acesso em: 7 mar. 2021.

WANG, X.; PETROPOULOS, F. To select or to combine? The inventory performance of model and expert forecasts. **International Journal of Production Research**, v. 54, p. 5271-5282, 2016. DOI: 10.1080 / 00207543.2016.1167983. Disponível em: <https://www-scopus.ez328.periodicos.capes.gov.br/record/display.uri?eid=2-s2.0-84977261503&origin=resultslist&sort=plf-f&src=s&st1=&st2=&sid=0f773d1fb838051dc1365bb7368cc808&sot=b&sdt=b&sl=72&s=TITLE-ABS-KEY%28%22The+inventory+performance+of+model+and+expert+forecasts%22%29&relpos=0&citeCnt=19&searchTerm=>. Acesso em: 15 mar. 2021.

WERNER, L. RIBEIRO, J. L. D. Modelo composto para prever demanda através da integração de previsões. **Gestão de Produção**, v. 16, n. 3, p. 493-509, 2006. doi.org/10.1590/S0103-65132006000300011. Disponível em: < <https://www.scielo.br/j/prod/a/mQHMsVRLXWnJGxLS3NXFcrJ/?msckid=5ba78f51cf0611ec9ab42650683c2315> >. Acesso em: 08 abr. 2022.

ZEKHNINI, K. ET AL. Supply chain management 4.0: a literature review and research framework. **Benchmarking**, v. 28, p. 465-501, 2020. DOI: 10.1108 / BIJ-04-2020-0156. Disponível em: <https://www.scopus.com/record/display.uri?eid=2-s2.0-85091370065&origin=resultslist&sort=plf-f&src=s&sid=805b241983b75fe046f35c8d9124e6f2&sot=b&sdt=b&sl=88&s=TITLE-ABS-KEY%28%22Supply+chain+management+4.0%3a+a+literature+review+and+research+framework%22%29&relpos=0&citeCnt=2&searchTerm=>. Acesso em: 8 abr. de 2021.

ZHANG, S.; DAN, B.; ZHOU, M. After-sale service deployment and information sharing in a supply chain under demand uncertainty. **European Journal of Operational Research**, v. 279, p. 353-363, 2019. DOI: 10.1016 / j.ejor.2019.05.014. Disponível em: <https://www-scopus.ez328.periodicos.capes.gov.br/record/display.uri?eid=2-s2.0-85067262982&origin=resultslist&sort=plf-f&src=s&st1=&st2=&sid=c0bfb67097b5775298c040e821ce82ae&sot=b&sdt=b&sl=113&s=TITLE-ABS-KEY%28%22After-sale+service+deployment+and+information+sharing+in+a+supply+chain+under+demand+uncertainty%22%29&relpos=0&citeCnt=15&searchTerm=>. Acesso em: 7 mar. 2021.

**APÊNDICE A - TABELA RESUMO DO PERFIL DE DEMANDA DE CADA  
FUNGICIDA**

TABELA RESUMO DO PERFIL DE DEMANDA DE CADA FUNGICIDA

Família	Algoritmo	DemandClass	Mean	Variance	Median	Skewness	ForecastabilityIndex
Fungicida 1	Empresa	Erratic	313.252	133.466.850.525	108.642	0,94	0,54
	Naive	Erratic	313.252	133.466.850.525	108.642	0,94	0,54
	Automático	Erratic	313.252	133.466.850.525	108.642	0,94	0,54
	Competição	Erratic	313.252	133.466.850.525	108.642	0,94	0,54
	Combinado	Erratic	313.252	133.466.850.525	108.642	0,94	0,54
	Competição	Erratic	313.252	133.466.850.525	108.642	0,94	0,54
	Combinado	Erratic	313.252	133.466.850.525	108.642	0,94	0,54
Fungicida 2	Empresa	Erratic	496.422	247.233.242.092	348.470	0,59	0,68
	Naive	Erratic	496.422	247.233.242.092	348.470	0,59	0,68
	Automático	Erratic	496.422	247.233.242.092	348.470	0,59	0,68
	Competição	Erratic	496.422	247.233.242.092	348.470	0,59	0,68
	Combinado	Erratic	496.422	247.233.242.092	348.470	0,59	0,68
	Competição	Erratic	496.422	247.233.242.092	348.470	0,59	0,68
	Combinado	Erratic	496.422	247.233.242.092	348.470	0,59	0,68
Fungicida 3	Empresa	Erratic	85.532	5.459.519.301	64.201	1,96	1,80
	Naive	Erratic	85.532	5.459.519.301	64.201	1,96	1,80
	Automático	Erratic	85.532	5.459.519.301	64.201	1,96	1,80
	Competição	Erratic	85.532	5.459.519.301	64.201	1,96	1,80
	Combinado	Erratic	85.532	5.459.519.301	64.201	1,96	1,80
	Competição	Erratic	85.532	5.459.519.301	64.201	1,96	1,80
	Combinado	Erratic	85.532	5.459.519.301	64.201	1,96	1,80
Fungicida 4	Empresa	Erratic	234.520	54.417.747.274	140.966	0,95	1,08
	Naive	Erratic	234.520	54.417.747.274	140.966	0,95	1,08
	Automático	Erratic	234.520	54.417.747.274	140.966	0,95	1,08
	Competição	Erratic	234.520	54.417.747.274	140.966	0,95	1,08
	Combinado	Erratic	234.520	54.417.747.274	140.966	0,95	1,08
	Competição	Erratic	234.520	54.417.747.274	140.966	0,95	1,08
	Combinado	Erratic	234.520	54.417.747.274	140.966	0,95	1,08
Fungicida 5	Empresa	Erratic	100.294	5.045.798.184	109.470	0,03	-
	Naive	Erratic	100.294	5.045.798.184	109.470	0,03	-
	Automático	Erratic	100.294	5.045.798.184	109.470	0,03	-
	Competição	Erratic	100.294	5.045.798.184	109.470	0,03	-
	Combinado	Erratic	100.294	5.045.798.184	109.470	0,03	-
	Competição	Erratic	100.294	5.045.798.184	109.470	0,03	-
	Combinado	Erratic	100.294	5.045.798.184	109.470	0,03	-
Fungicida 8	Empresa	Erratic	40.284	2.819.213.724	16.420	1,82	0,61
	Naive	Erratic	40.284	2.819.213.724	16.420	1,82	0,61
	Automático	Erratic	40.284	2.819.213.724	16.420	1,82	0,61
	Competição	Erratic	40.284	2.819.213.724	16.420	1,82	0,61
	Combinado	Erratic	40.284	2.819.213.724	16.420	1,82	0,61
	Competição	Erratic	40.284	2.819.213.724	16.420	1,82	0,61
	Combinado	Erratic	40.284	2.819.213.724	16.420	1,82	0,61

**APÊNDICE B - TABELA DE RESULTADOS DE CADA MODELO PROPOSTO**

## TABELA DE RESULTADOS DE CADA MODELO PROPOSTO

Família	Algoritmo	Melhor Método	Machine Learning?	Causal?	Amostra Treino	Amostra de Teste	RMSE Treino	RMSE Teste	WMAPE Treino	WMAPE teste
Funcicida 1	Empresa	Análise de julgamento	Não	Não	-	-	-	-	-	18,0
	Naive	Naive	Não	Não	66	6	235.780	822.758	55,9	39,4
	Automático	SVM Linear	Sim	Não	66	6	119.413	369.391	30,1	21,0
	Competição	SVM Linear	Sim	Não	66	6	119.413	369.391	30,1	21,0
	Combinado	Composto	Sim	Não	66	6	105.128	412.031	26,7	21,1
	Competição	GBM	Sim	Sim	66	6	74.118	357.135	19,5	11,9
	Combinado	Composto	Sim	Sim	66	6	86.997	400.845	22,5	17,2
Funcicida 2	Empresa	Análise de julgamento	Não	Não	-	-	-	-	-	8,7
	Naive	Naive	Não	Não	36	6	308.424	961.969	48,1	34,1
	Automático	SVM Linear	Sim	Não	36	6	150.185	404.564	26,5	8,5
	Competição	SVM Linear	Sim	Não	36	6	150.185	404.564	26,5	8,5
	Combinado	Composto	Sim	Não	36	6	135.028	485.492	22,9	11,4
	Competição	Arimax	Sim	Sim	36	6	108.116	295.414	21,1	8,2
	Combinado	Composto	Sim	Sim	36	6	90.481	364.164	17,0	11,0
Funcicida 3	Empresa	Análise de julgamento	Não	Não	-	-	-	-	-	43,0
	Naive	Naive	Não	Não	66	6	96.257	107.884	78,1	58,5
	Automático	SVM Linear	Sim	Não	66	6	48.052	61.579	40,1	40,4
	Competição	GBM	Sim	Não	66	6	46.443	48.142	40,7	19,0
	Combinado	Composto	Sim	Não	66	6	48.956	53.558	40,1	27,6
	Competição	GBM	Sim	Sim	66	6	46.482	45.916	40,5	24,0
	Combinado	Composto	Sim	Sim	66	6	48.965	52.530	39,7	30,2
Funcicida 4	Empresa	Análise de julgamento	Não	Não	-	-	-	-	-	12,7
	Naive	Naive	Não	Não	42	6	131.664	578.739	48,9	40,6
	Automático	SVM Linear	Sim	Não	42	6	93.393	279.331	36,1	19,9
	Competição	QRF	Sim	Não	42	6	51.287	216.456	19,3	12,1
	Combinado	Composto	Sim	Não	42	6	76.083	265.047	22,1	19,0
	Competição	SVM Linear	Sim	Sim	42	6	84.534	193.373	32,3	18,8
	Combinado	Composto	Sim	Sim	42	6	77.764	238.259	23,2	21,1
Funcicida 5	Empresa	Análise de julgamento	Não	Não	-	-	-	-	-	50,7
	Naive	Naive	Não	Não	22	6	71.947	72.740	59,7	30,0
	Automático	SVM Linear	Sim	Não	22	6	44.568	37.695	36,5	22,0
	Competição	Arimax	Sim	Não	22	6	46.551	30.848	40,9	20,2
	Combinado	Composto	Sim	Não	22	6	47.853	33.801	37,2	17,7
	Competição	AVNNet	Sim	Sim	22	6	38.997	31.295	34,4	17,5
	Combinado	Composto	Sim	Sim	22	6	46.685	32.070	34,7	17,4
Funcicida 8	Empresa	Análise de julgamento	Não	Não	-	-	-	-	-	104,1
	Naive	Naive	Não	Não	38	6	42.021	71.632	74,4	81,5
	Automático	SVM Linear	Sim	Não	38	6	27.895	78.923	58,3	59,1
	Competição	Naive	Não	Não	38	6	42.021	71.632	74,4	81,5
	Combinado	Composto	Sim	Não	38	6	33.427	72.242	51,2	66,2
	Competição	Naive	Não	Sim	38	6	42.021	71.632	74,4	81,5
	Combinado	Composto	Sim	Sim	38	6	32.938	72.331	51,3	64,6