

UNIVERSIDADE FEDERAL DE ALAGOAS

CAMPUS DO SERTÃO

CURSO DE ENGENHARIA DE PRODUÇÃO

THOMÁS DIOGO GOMES DUARTE

**O USO DE MODELOS DE PREVISÃO DE DEMANDA EM UMA INDÚSTRIA DO
RAMO ALIMENTÍCIO DO AGRESTE ALAGOANO**

Delmiro Gouveia - AL

2024

THOMÁS DIOGO GOMES DUARTE

**O USO DE MODELOS DE PREVISÃO DE DEMANDA EM UMA INDÚSTRIA DO
RAMO ALIMENTÍCIO DO AGRESTE ALAGOANO**

Trabalho de Conclusão de Curso apresentado ao Curso de Engenharia de Produção da Universidade Federal de Alagoas, como requisito parcial à obtenção do título de Bacharelado em Engenharia de Produção

Orientador: Prof. Dr. Marcelo Amanajás Pires

Coorientadora - Doutora, Renata de Oliveira Mota

Delmiro Gouveia - AL

2024

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

Bibliotecária responsável: Renata Oliveira de Souza CRB-4/2209

D812u Duarte, Thomás Diogo Gomes

O uso de modelos de previsão de demanda em uma indústria do ramo alimentício do agreste alagoano / Thomás Diogo Gomes Duarte. - 2024.

65 f. : il.

Orientação: Marcelo Amanajás Pires.

Coorientação: Renata de Oliveira Mota.

Monografia (Engenharia de Produção) – Universidade Federal de Alagoas. Curso de Engenharia de Produção. Delmiro Gouveia, 2024.

1. Engenharia de Produção. 2. Previsão de demanda. 3. Séries temporais. 4. Indústria alimentícia. I. Pires, Marcelo Amanajás, orient. II. Mota, Renata de Oliveira, coorient. III. Título.

CDU: 658.5

Folha de Aprovação

THOMÁS DIOGO GOMES DUARTE

O USO DE MODELOS DE PREVISÃO DE DEMANDA EM UMA INDÚSTRIA DO RAMO ALIMENTÍCIO DO AGRESTE ALAGOANO

Trabalho de Conclusão de Curso submetido à banca examinadora do curso de Engenharia de Produção da Universidade Federal de Alagoas e aprovada em 02 de abril de 2024.



Documento assinado digitalmente
MARCELO AMANAJAS PIRES
Data: 04/04/2024 09:18:53-0300
Verifique em <https://validar.iti.gov.br>

(Orientador - Doutor, Marcelo Amanajás Pires, UFAL)



Documento assinado digitalmente
RENATA DE OLIVEIRA MOTA
Data: 03/04/2024 16:37:29-0300
Verifique em <https://validar.iti.gov.br>

(Coorientadora - Doutora, Renata de Oliveira Mota, UFPB)

Banca examinadora:



Documento assinado digitalmente
ALLINE THAMYRES CLAUDINO DA SILVA
Data: 03/04/2024 17:13:02-0300
Verifique em <https://validar.iti.gov.br>

(Examinadora Interna - Mestre, Alline Thamyres Claudino da Silva, UFAL)



Documento assinado digitalmente
JONHATAN MAGNO NORTE DA SILVA
Data: 03/04/2024 14:39:07-0300
Verifique em <https://validar.iti.gov.br>

(Examinador Interno - Doutor, Jonhatan Magno Norte da Silva, UFAL)

AGRADECIMENTOS

A entrega deste trabalho marca a conclusão da minha graduação, um período repleto de experiências, superações e conquistas, que devo a muitas pessoas.

Agradeço aos meus pais, Edilene e Erisvaldo, que me proporcionaram todos os meios e apoio para construir a base educacional que me trouxe à UFAL. Agradeço a minha namorada, Bianca, pelo incondicional apoio e atenção a mim dedicados.

A meus amigos, Claudemirson, Izorlayne e Monique, por tornarem a caminhada mais leve e descontraída, além dos estudos conjuntos e trabalhos em grupo.

A minha orientadora, professora Renata Mota e meu coorientador, professor Marcelo Amanajás, pela atenção ímpar dedicada, pela generosidade com que dividiram seus conhecimentos, pela compreensão com que lidaram com minhas dificuldades e pela paciência que tiveram sobre minhas limitações.

Aos meus professores, em especial a professora Alline Thamyres e ao professor Jonhatan Magno pelos ensinamentos, conversas, lições e amizade durante toda a graduação.

A UFAL - Campus Sertão e servidores proporcionam um ensino de excelência, com direito a monitoria, movimento empresa júnior, diretório acadêmico, eventos, projetos e a convivência em campus.

RESUMO

O objetivo deste estudo foi analisar o desempenho de métodos quantitativos de previsão de demanda, baseados em séries temporais, em uma indústria alimentícia localizada no Agreste alagoano. Justifica-se este desenvolvimento diante da necessidade crescente das indústrias por ferramentas que lhes permitam expandir sua presença no mercado. A escolha de um método com menor margem de erro é de suma relevância para o planejamento estratégico das organizações. O modelo baseia-se na análise de séries temporais, com modelos univariadas, analisa por meio do coeficiente de variância a estacionariedade do conjunto de dados e observa os componentes da série: tendência, sazonalidade e erro, por fim, gera a previsão. O método de pesquisa aplicado foi a simulação, a partir da utilização de modelos de previsão, sendo eles: Método de suavização exponencial com base no erro, tendência e sazonalidade (ETS: *error, trend, seasonal*) e Arima Autoregressive de Box-Jenkins (AUTO.ARIMA), devido à alta capacidade que os modelos apresentaram no que se diz respeito a simulação de variados modelos a escolha do método que melhor se encaixou na série de dados da presente pesquisa. Os resultados alcançados demonstraram que o modelo que obteve o maior grau de acuracidade foi o ETS, para o feijão com melhores resultados nos coeficientes de erro: MAPE (12.338), MAE (51.893) e no MASE (0.77440), e o AUTO.ARIMA, para o arroz, com coeficientes em: MAPE (22.527), MAE (31.942), EM (-0.574), RMSE (42.635) e MASE (0.734), que tem por propósito trazer maior acurácia aos dados organizacionais, bem como gerar informações confiáveis e realistas para fomentar o desenvolvimento da empresa por meio da utilização de modelos de previsão modernos e de fácil utilização.

Palavras-chave: previsão de demanda; modelos quantitativos; séries temporais; ramo alimentício.

ABSTRACT

The objective of this study was to analyze the performance of quantitative demand forecasting methods based on time series in a food industry located in the Agreste region of Alagoas. This development is justified by the growing need of industries for tools that allow them to expand their presence in the market. The choice of a method with lower margin of error is of utmost relevance for the strategic planning of organizations. The model is based on time series analysis, examines the stationarity of the dataset through the coefficient of variation, and observes the components of the series: trend, seasonality, and error, finally generating the forecast. The research method applied was simulation, using forecasting models such as the Exponential Smoothing with Error, Trend, and Seasonality (ETS) method and the Box-Jenkins Autoregressive Integrated Moving Average (AUTO.ARIMA) method. Due to the high capacity of the models in simulating various scenarios, the choice of the method that best fit the dataset of this research was made. The results obtained demonstrated that the model with the highest degree of accuracy was ETS for beans, with better results in error coefficients: MAPE (12.338), MAE (51.893), and MASE (0.77440), and AUTO.ARIMA for rice, with coefficients: MAPE (22.527), MAE (31.942), EM (-0.574), RMSE (42.635), and MASE (0.734). The purpose of these models is to bring greater accuracy to organizational data, as well as to generate reliable and realistic information to foster the company's development through the use of modern and user-friendly forecasting models.

Keywords: Demand forecasting; quantitative models; time series; food industry.

LISTA DE FIGURAS

FIGURA 1 - COMPONENTE DAS SÉRIES TEMPORAIS	24
FIGURA 2 - CICLO INTERATIVO DE BOX-JENKINS	27

LISTA DE GRÁFICOS

GRÁFICO 1 - VENDAS EM SÉRIE DO FEIJÃO	34
GRÁFICO 2 - VENDAS EM PARALELO DO FEIJÃO	35
GRÁFICO 3 - IDENTIFICAÇÃO DE OUTLIERS NOS DADOS DO FEIJÃO	37
GRÁFICO 4 - VENDAS EM SÉRIE DO FEIJÃO SEM OUTLIERS	37
GRÁFICO 5 - VENDAS EM PARALELO DO FEIJÃO SEM OUTLIERS	38
GRÁFICO 6 - VENDAS EM SÉRIE DO ARROZ	39
GRÁFICO 7 - VENDAS EM PARALELO DO ARROZ	40
GRÁFICO 8 - IDENTIFICAÇÃO DOS OUTLIERS NOS DADOS DO ARROZ	40
GRÁFICO 9 - VENDAS EM SÉRIE DO ARROZ SEM OUTLIERS	41
GRÁFICO 10 - VENDAS EM PARALELO DO ARROZ SEM OUTLIERS	42
GRÁFICO 11- PREVISÃO GRÁFICA PARA O FEIJÃO COM O MODELO ETS	43
GRÁFICO 12 - PREVISÃO GRÁFICA PARA O ARROZ COM O MODELO AUTO.ARIMA	43
GRÁFICO 13 - PREVISÃO GRÁFICA PARA O ARROZ COM O MODELO ETS	45
GRÁFICO 14 - PREVISÃO GRÁFICA PARA O ARROZ COM O MODELO AUTO.ARIMA	46

LISTA DE QUADROS

QUADRO 1 - ETAPAS DE UMA PREVISÃO DE DEMANDA	20
QUADRO 2 - ETAPAS DO ESTUDO DE CASO	28

LISTA DE TABELAS

TABELA 1 - RESULTADOS DOS ERROS DOS MODELOS PARA OS DADOS DO FEIJÃO	45
TABELA 2 - PARÂMETROS DO MODELO ETS PARA O FEIJÃO	46
TABELA 3 - RESULTADOS DOS ERROS DOS MODELOS PARA OS DADOS DO ARROZ	47
TABELA 4 - PARÂMETROS DO MODELO AUTO.ARIMA PARA O ARROZ	48

LISTA DE ABREVIATURAS E SIGLAS

ABNT	Associação Brasileira de Normas Técnicas
IBGE	Instituto Brasileiro de Geografia e Estatística
UFAL	Universidade Federal de Alagoas
ETS	Error-Trend-Seasonality
ARIMA	AutoRegressive Integrated Moving Average
MAPE	Média Absoluta Percentual de Erro
MAE	Média Absoluta de Erro
EM	Erro Médio
RMSE	Raiz do Erro Quadrático Médio
MASE	Escalar Médio Absoluto
EMBRAPA	Empresa Brasileira de Pesquisa Agropecuária
CONAB	Companhia Nacional de Abastecimento
MAPA	Ministério da Agricultura Pecuária e Abastecimento
INMETRO	Instituto Nacional de Metrologia, Normalização e Qualidade Industrial

SUMÁRIO

1 INTRODUÇÃO.....	14
1.1 Problema da pesquisa.....	15
1.2 Justificativa.....	16
1.3 Objetivos da pesquisa.....	17
1.3.1 Objetivo geral.....	17
1.3.2 Objetivos específicos.....	18
1.4 Estrutura do estudo.....	18
2 REFERENCIAL TEÓRICO.....	20
2.1 Previsão de demanda.....	20
2.1.1. Etapas de previsão de demanda.....	21
2.2 Séries Temporais.....	23
2.2.1 ETS (Error-Trend-Seasonality).....	24
2.2.2.1 ARIMA.....	25
2.2.2.2 Pacote Forecast.....	27
2.4 Análise de outliers.....	28
2.4 Coeficiente de erro.....	28
3 MÉTODO DE PESQUISA.....	31
3.1 Classificação da pesquisa.....	31
3.2 Etapas do Estudo de caso.....	31
3.1.1 Coleta de dados.....	32
3.1.2 Tratamento dos dados	32
3.1.3 Análise dos dados e escolha dos métodos de previsão.....	33
3.1.4 Modelagem da demanda.....	34
4 ESTUDO DE CASO.....	35
4.1 Descrição da empresa em estudo.....	35
4.2 Coleta de dados.....	36
4.3 Análise de dados.....	36
4.3.1. Tratamento dos dados.....	36
4.3.2 Análise dos dados para o feijão.....	37
4.3.3 Análise de dados para o arroz.....	40
4.4 Análise dos modelos por produto e a sua escolha	44
4.4.1 Avaliação do modelo para o feijão.....	44
4.4.2 Avaliação do modelo para o arroz.....	46
4.4.3 Determinação do método ideal.....	48
5 DISCUSSÕES.....	49
5.1. Perspectivas micro e macroeconômicas.....	49
5.2. Sazonalidade e tendências de consumo na Região do Agreste Alagoano... 50	

6 CONSIDERAÇÕES FINAIS.....	52
6.1 Limitações da pesquisa.....	54
6.2 Propostas para trabalhos futuros.....	55
REFERÊNCIAS.....	56
APÊNDICE A – Banco de dados do feijão.....	62
APÊNDICE B – Banco de dados do arroz.....	63

1 INTRODUÇÃO

A evolução do agronegócio brasileiro se torna mais evidente quando observados os dados da EMBRAPA (Empresa Brasileira de Pesquisa Agropecuária) de 2021 que apontam a participação do Brasil no mercado mundial de alimentos, com um salto de 20,6 bilhões para 100 bilhões de dólares, nos últimos dez anos (EMBRAPA, 2021). Porém, de acordo com o relatório do Índice de Desperdício de Alimentos de 2021 da ONU (Nações Unidas), estima-se que 931 milhões de toneladas de alimentos, ou 17% do total de alimentos disponíveis aos consumidores em 2019, foram para o lixo de residências, varejo, restaurantes e outros serviços alimentares (ONU, 2021).

Observando tamanho desperdício, o uso de ferramentas que auxiliem na redução de desperdícios e alavancagem da produção de alimentos se apresenta fundamental. Dito isto, planejar é uma ação ordinária e primordial a todos os tipos de empresas, independente do ramo ou mercado em que atua. Essa atividade permite que a organização se mantenha estruturada, evitando grandes perturbações, escassez de recursos e custos inesperados.

O processo de previsão de demanda é uma das atividades de grande importância no planejamento e controle da produção, e tem como premissa que a demanda passada de um produto possa explicar, a sua demanda futura (Brito, 2020). Assim, previsões de demanda podem ser desenvolvidas utilizando métodos: quantitativos, qualitativos ou ainda combinações de métodos quantitativos e qualitativos. Krajewski, Ritzman e Malhotra (2009) ressaltam que os métodos quantitativos operam com dados históricos para prever a demanda em períodos futuros. A escolha do modelo de previsão de demanda apropriado possibilita às empresas direcionar seus planos de produção, estoque e compras, diminuir erros, suprir a demanda dos consumidores, além da definição de questões estratégicas mais complexas, tornando-se um fator crítico de sucesso para a gestão de negócios (Cecatto; Belfiore, 2015). Corrêa e Corrêa (2013) afirmam que os métodos qualitativos têm base em opiniões de especialistas ou gestores das organizações, e são valorosos quando a coleta de dados se mostra muito complexa, assim, fundamentam-se na confiabilidade do setor de vendas, conhecimento prévio de algum evento que possa interferir no cenário futuro e perspectivas dos consumidores.

Assim, por meio de um método quantitativo, este estudo é baseado na análise de diversos métodos para implementação de sistemas de previsão de demanda. A aplicação em

uma indústria do ramo de alimentos do agreste alagoano servirá para sustentar a demonstração dos resultados, tendo como intuito apresentar o método que mais se harmoniza aos principais produtos da empresa.

1.1 Problema da pesquisa

O tema previsão de demanda mostra-se atual e relevante para instituições de diversos segmentos (Ackermann; Sellitto, 2022). Além disso, a falta de planejamento adequado pode impactar negativamente na competitividade da empresa no mercado. Como consequência, pode afetar a qualidade, a satisfação do cliente e o custo, e prejudicar a eficiência operacional do negócio (Ferbar Tratar, 2015).

Para Fernandes e Godinho Filho (2009), os gerentes devem estar atentos às variações do mercado, de forma a identificar as necessidades de alteração nos métodos utilizados se estes não mais se apresentam eficientes para a organização. Caso não identificadas, possíveis mudanças podem se tornar custos desnecessários e comprometer os resultados da empresa.

Este trabalho surge como uma resposta ao desafio enfrentado pela indústria alimentícia de grãos do agreste alagoano em relação à previsão de demanda. A falta de previsões precisas e confiáveis pode levar a problemas como superprodução, escassez de produtos, altos custos operacionais, subutilização de recursos e insatisfação dos clientes (Hofmann, 2013). Além disso, a imprecisão nas previsões pode dificultar o planejamento estratégico da empresa, impactando negativamente sua competitividade e desempenho.

A indústria de grãos é particularmente desafiadora devido a fatores como sazonalidade, variações climáticas, flutuações de preços e mudanças nos hábitos de consumo. Essas características tornam a demanda desses produtos difícil de prever, o que pode resultar em problemas significativos no gerenciamento da cadeia de suprimentos e no atendimento às necessidades do mercado.

Ao abordar esse problema, busca-se contribuir para o avanço do conhecimento científico nessa área específica. Além do que, auxilia na identificação de oportunidades de mercado e na antecipação de tendências, proporcionando vantagem competitiva (Fildes, 2009). Através da aplicação de métodos de previsão de demanda adequados e da utilização de dados e informações relevantes, espera-se que este trabalho possa oferecer soluções para aprimorar a previsão de demanda na indústria de feijão e arroz, contribuindo para a eficiência

operacional, competitividade e sustentabilidade da organização, ao passo que, pode proporcionar também maior poder de consumo para a população por meio de preços mais acessíveis. Para Ackermann e Sellitto (2022) as técnicas de previsões permitem transformações das informações empresariais estratégicas para prever a demanda por novos produtos, novas tecnologias, novas participações de mercado ou melhor estratégia competitiva.

A empresa do estudo de caso se encontra no agreste de Alagoas e sua matéria-prima provém de pequenos produtores das cidades circunvizinhas. Portanto, o problema de pesquisa que motiva este trabalho é: *Qual método melhora a qualidade das previsões de demanda em uma indústria alimentícia, a fim de auxiliar a tomada de decisões estratégicas, reduzir custos operacionais e otimizar o uso de recursos?*

1.2 Justificativa

A previsão de demanda pode fornecer informações importantes para a identificação de padrões e tendências no processo de tomada de decisões de uma empresa e pode ser considerada como uma busca de informações a respeito das vendas futuras de um determinado item ou grupo de itens (Moreira, 2011). Ackermann e Sellitto (2022) salientam que a previsão de demanda se trata de uma metodologia de administração de empresas para estimar um valor futuro de uma grandeza de interesse.

De acordo com Cecatto e Belfiore (2015), empresas que mostram excelência no atendimento ao consumidor destacam-se também pelo planejamento de demanda, que permite conduzir os planos de produção, estoque, distribuição e compras, além de contrapor questões mais complexas, como a ramificação de produtos, promoções e crescimento da concorrência.

A previsão de demanda na Indústria alimentícia no Brasil desempenha ainda um papel muito importante nas esferas acadêmica, industrial e social. No âmbito acadêmico, a realização de estudos e pesquisas nesta área contribui para o avanço do conhecimento científico, permitindo o aperfeiçoamento e desenvolvimento de técnicas de previsão de demanda, modelagem estatística e metodologias específicas para este setor. Setor esse, que segundo Alves (2019) ainda possui escassez em dados de literatura. Essas pesquisas aprofundam o entendimento dos fatores que influenciam a demanda como sazonalidade, variações climáticas, mudanças socioeconômicas e hábitos de consumo, além de fornecer subsídios para a formação de profissionais capacitados e atualizados.

Na indústria, as previsões de demanda desempenham um papel muito importante. Praticamente todas as empresas, sejam elas de pequeno, médio ou grande porte, estatais, nacionais, privadas ou multinacionais, necessitam planejar seus recursos de produção, distribuição e compra de insumos ou serviços em face às condições futuras incertas (Da Veiga; Duclós, 2010). Com previsão adequada a organização tende a evitar problemas como superprodução ou escassez, reduzir custos operacionais, otimizar a utilização de recursos e maximizar a satisfação do cliente. A previsão de demanda também identifica oportunidades de mercado e prevê tendências, permitindo que as empresas ganhem vantagem competitiva e se adaptem às mudanças no ambiente de negócios.

Na esfera social, a previsão de demanda também desempenha um papel significativo, pois o feijão e o arroz são alimentos básicos na dieta da população brasileira, especialmente nas regiões mais carentes. A previsão de demanda eficiente possibilita uma produção adequada e um suprimento estável desses alimentos essenciais, garantindo o acesso da população a preços justos. Assim, pode-se notar que uma boa previsão de demanda é de interesse de todos os participantes da cadeia de suprimentos (Silva, 2020).

Dessa forma, a previsão de demanda impulsiona o avanço do conhecimento, auxilia na tomada de decisões estratégicas das empresas e contribui para a segurança alimentar e o bem-estar social das comunidades envolvidas. Ao considerar esses aspectos, é possível compreender a importância fundamental da previsão de demanda nesse setor.

O estudo em questão visa fomentar a força competitiva da companhia, ao ponto que descreve o comportamento futuro das vendas dos dois principais produtos da empresa. Esse estudo, eventualmente, poderá servir para o restante do portfólio, desde que ele manifeste características análogas. Um planejamento executado com rigor, levando em consideração o histórico da organização, fortalece o desenvolvimento da instituição, para ampliar sua participação em um mercado globalizado, podendo assim, ser referência em seu setor. Então, o estudo torna-se de grande valia, pois com previsões de demanda assertivas a empresa pode estimar seu horizonte futuro, aproveitando as oportunidades e reduzindo as margens de erro.

1.3 Objetivos da pesquisa

1.3.1 Objetivo geral

Analisar o desempenho de métodos quantitativos de previsão de demanda, baseados em séries temporais, em uma indústria alimentícia localizada no Agreste alagoano.

1.3.2 *Objetivos específicos*

Para alcançar o objetivo geral, almejou-se alcançar os seguintes objetivos específicos:

- Desenvolver um levantamento dos fatores que afetam a demanda da produção de feijão e arroz na indústria alimentícia;
- Comparar o comportamento das séries temporais em cenários distintos;
- Comparar o desempenho dos métodos quantitativos de previsão de demanda nos dados coletados;
- Demonstrar o impacto desse desenvolvimento nos produtos analisados.

1.4 **Estrutura do estudo**

A estrutura do trabalho é dividida em seis capítulos, cada um desempenhando um papel crucial na abordagem e análise do tema em questão. No Capítulo 1, é realizada a apresentação detalhada do tema escolhido, onde também são apresentados os objetivos gerais e específicos que norteiam a pesquisa. Além disso, a estrutura global adotada no trabalho é discutida, delineando suas diferentes seções e subseções.

No Capítulo 2, a pesquisa se aprofunda no referencial teórico que serve como a base fundamental para a investigação. Uma série de conceitos interligados que circundam o tema é explorada, proporcionando uma compreensão sólida do contexto em que a pesquisa está inserida. A partir de uma extensa pesquisa, informações relevantes são reunidas para enriquecer o entendimento e contribuir para a análise subsequente.

O Capítulo 3 é dedicado ao método de pesquisa adotado. Aqui, é fornecida uma caracterização abrangente do estudo, incluindo detalhes sobre a empresa escolhida como objeto de análise. As etapas e abordagens que compõem a pesquisa são descritas em profundidade, esclarecendo a lógica subjacente à abordagem e justificando as escolhas metodológicas.

No Capítulo 4, um estudo de caso é conduzido utilizando dados reais de uma empresa do setor alimentício. Essa análise prática permite a aplicação dos conceitos e métodos discutidos anteriormente, oferecendo *insights* concretos e exemplos tangíveis. Ao examinar os

dados coletados e os resultados obtidos, busca-se ilustrar a aplicação prática das teorias e técnicas discutidas.

No Capítulo 5 são feitas as discussões pertinentes ao tema, bem como o cenário micro e macroeconômico, cenários regional e nacional. Além de uma análise referente a sazonalidade e tendências de consumo na região Agreste de Alagoas.

Finalmente, no Capítulo 6, são apresentadas as considerações finais decorrentes desta pesquisa. Os resultados obtidos são refletidos, destacando como se relacionam com os objetivos iniciais. Além disso, as principais conclusões do estudo são ressaltadas e possíveis direções para pesquisas futuras são discutidas, identificando áreas que merecem maior investigação e desenvolvimento. As delimitações encontradas também são destacadas para garantir um foco claro e conciso.

2 REFERENCIAL TEÓRICO

2.1 Previsão de demanda

A previsão de demanda é um tópico de pesquisa bem estabelecido em muitas áreas, que utiliza dados do passado para fazer uma estimativa de valores ou variáveis para o futuro (Bundchen; Werner, 2016). De acordo com Tubino (2000, p. 63), “a previsão de demanda é a base para o planejamento estratégico da produção, vendas e finanças de qualquer empresa”. Para De Lima e Corso (2020) a previsão de demanda está entre os principais métodos utilizados para gerenciamento de processos, e seu uso possibilita que a organização tome suas decisões de forma mais estratégica e assertiva.

É importante ressaltar que a previsão de demanda se trata de um processo multidisciplinar, vista sua necessidade em todos os setores da organização, para embasar suas tomadas de decisão, tais como: no financeiro, utiliza para projetar orçamentos e fluxos de caixa; nos recursos humanos, antecipar o recrutamento, seleção e treinamento; no marketing, é indispensável para previsões de vendas; no chão de fábrica, para planejar níveis de produção, aquisição dos recursos, estoque e cronograma (Krajewski; Ritzman; Malhotra, 2009). De acordo com Santos (2020), a previsão de demanda é a chave para uma melhor gestão da empresa, com minimização de riscos devido a indisponibilidade de estoque ou ainda com custos menores devido a um inventário mais bem planejado.

A previsão de vendas pode ser dividida em três cenários, sendo eles: curto prazo - com a hipótese de que o futuro seja uma continuação do passado -, médio prazo - cuja hipótese é que as relações existentes no passado entre as vendas e outras variáveis, continuam a valer no futuro - e longo prazo - baseia-se na hipótese que o futuro não guarda uma relação direta com o passado (Corrêa, Giansi e Caon, 2001) .

Jain e Malehorn (2006) ressaltam que não existe um modelo de previsão “mágico” que seja eficiente em todas as situações, pois, trabalhar com previsão é usar a ciência em união à arte. Devido ao grande número de variáveis que podem ter impacto na demanda futura de produtos ou serviços, qualquer previsão apresentará erro em comparação com a demanda real (Silva, 2020).

O uso das previsões pode ainda não apresentar sempre resultados exatos, visto que não há consenso sobre um modelo de previsão que seja eficiente em todas as situações, todos são passíveis de erros, entretanto, se mantêm necessárias para a organização. A importância de

uma previsão deriva do fato de que as imprecisões não podem ser separadas da realidade, dessa forma, todas as organizações operam em um ambiente de insegurança (Contreras Juárez et al., 2016).

Os riscos de uma demanda futura incerta podem ser amenizados com uma previsão de demanda instituída com base em dados históricos e análise do cenário atual, estabelecendo premissas para as tomadas de decisões gerenciais, logísticas e gestão da cadeia de suprimentos (Bundchen; Werner, 2016). Dessa forma, é importante saber quais variáveis afetam a acuracidade dos dados e o quanto essa taxa de mudança influencia na previsão (Slack; Jones; Johnsnton, 2018).

Segundo Laugeni e Martins (2015), a coleta de dados e a escolha da previsão são pontos de atenção crítica, dada sua influência direta no resultado das estimativas. Sobre este aspecto, Corrêa, Giansesi e Caon (2001) expõe que isso pode envolver a criação e manutenção de uma base de dados do histórico de vendas, com informações que revelem as causas de seu desempenho e oscilações no passado, é vital o uso de modelos matemáticos que permitam explicar o comportamento da demanda, analisar como fatores ou variáveis internas (como a taxa de rotatividade dos funcionários) e externas (clima, condições econômicas) influenciam o comportamento dessa demanda.

2.1.1. Etapas de previsão de demanda

Uma tarefa de previsão geralmente envolve cinco etapas básicas (Hyndman; Athanasopoulos, 2018), as quais encontram-se descritas no Quadro 01.

Quadro 1 - Etapas de uma previsão de demanda

Etapa	Descrição
1	Definição do problema - requer uma compreensão da forma como as previsões serão usadas, quem requer as previsões e como a função de previsão se encaixa dentro da organização que requer as previsões.
2	Coletando informações - Há sempre pelo menos dois tipos de informações necessárias: (a) dados estatísticos e (b) a experiência acumulada das pessoas que coletam os dados e usam as previsões.
3	Análise preliminar (exploratória) - Comece sempre por representar graficamente os dados. Existem padrões consistentes? Existe uma tendência significativa? A sazonalidade é importante? Há evidências da presença de ciclos econômicos? Existem valores atípicos nos dados que precisam ser explicados por aqueles com conhecimento especializado? Quão fortes são as relações entre as variáveis disponíveis para análise?
4	Escolhendo e montando modelos - O melhor modelo a ser usado depende da disponibilidade de dados históricos, da força das relações entre a variável de previsão e quaisquer variáveis explicativas e da maneira como as previsões devem ser usadas. É comum comparar dois ou três modelos potenciais.

5	Usando e avaliando um modelo de previsão - Uma vez que um modelo tenha sido selecionado e seus parâmetros estimados, o modelo é usado para fazer previsões. O desempenho do modelo só pode ser avaliado adequadamente após os dados para o período de previsão terem se tornado disponíveis.
---	--

Fonte: adaptado de Hyndman e Athanasopoulos (2018)

A demanda tem relação com quatro fatores que corroboram para a determinação do melhor método de previsão, sendo eles: tendência (crescente, decrescente ou estacionária); ciclicidade (flutuações econômicas de ordem geral); sazonalidade (demanda varia de acordo com a época do ano) e componentes aleatórios (causas não identificadas) (Gonçalves, 2007).

Pode-se categorizar os métodos conforme o tipo de abordagem utilizada, ou seja, o conceito que fomenta a previsão (Corrêa e Corrêa, 2017). Dessa forma, classifica-se os métodos como qualitativos e quantitativos. As técnicas quantitativas têm base em modelos matemáticos que utilizam os dados históricos disponíveis e adequados, conseguindo assim identificar os comportamentos ocorridos e projetar para o futuro, dessa forma, são mais úteis em produtos existentes com mais tempo no mercado (Krajewski; Ritsman; Malhotra, 2009; Corrêa; Corrêa, 2013). Os métodos de previsão de demanda qualitativos, também chamados “métodos baseados no julgamento”, são fundamentados na capacidade de julgamento, de discernimento e no conhecimento empírico de especialistas (Petropoulos et al., 2018), podem ser usados quando a organização é carente de dados históricos que poderiam ser analisados como base de previsão (Peinaldo; GraemL, 2007).

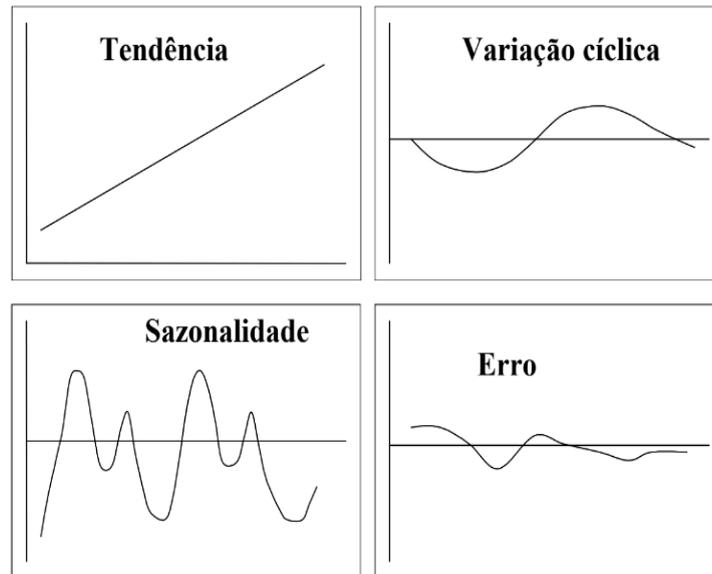
Os métodos quantitativos, foco de estudo deste trabalho, utilizam dados históricos para elaboração de modelos matemáticos a partir dos dados disponíveis e estimar a demanda futura. Esse grupo de dados é também denominado como série temporal e indica que os fatores que influenciaram no passado, serão os mesmos que influenciarão o futuro (Fernandes; Godinho Filho, 2009). Em contrapartida, existem também os modelos causais, que apresentam relação de causa-efeito com variáveis antecessoras, as quais são chamadas de "variáveis independentes" ou "causais". A demanda pode ser prevista por meio de uma função de variáveis como preço, país de origem, entre outras (Katsikopoulos; Durbach; Stewart, 2018). As técnicas qualitativas não foram dispostas por haver disponibilidade de dados históricos da demanda.

2.2 Séries Temporais

Também chamada de “modelagem univariada”, a modelagem com séries temporais geralmente usa o tempo como uma variável de entrada. É definida como um conjunto de observações geradas sequencialmente no tempo (Borojani et al., 2017). De acordo com Tubino (2000), para se montar o modelo de previsão com base em séries temporais, é necessário plotar os dados passados e identificar os agentes responsáveis pelas características da curva obtida. Uma curva temporal de previsão pode conter tendência, sazonalidade, variações irregulares (aleatoriedade) e variações randômicas (ciclo). Na Figura 1 pode ser observado graficamente os componentes, em que para Gonçalves (2007), essas componentes podem ser catalogadas como:

- Tendência: componente que representa o crescimento ou declínio de uma série no médio ou longo prazo;
- Sazonalidade: representa um comportamento periódico de curto ou médio prazo, em que os dados apresentam padrões que se repetem para cima ou para baixo;
- Aleatoriedade: são causadas principalmente por eventos particulares e não recorrentes;
- Ciclo: geralmente sofre influência de variações econômicas, reflete as flutuações ocorridas no longo prazo.

Figura 1 - Componente das séries temporais



Fonte: Carvalho (2003)

2.2.1 ETS (*Error-Trend-Seasonality*)

Os métodos de suavização exponencial com base no erro, tendência e sazonalidade (Método ETS) são métodos de série temporal em que ETS significa *error, trend, seasonal*. Rappel de Amorim (2021) elucida que o ETS é uma classe geral que descreve os modelos de suavização exponencial em função dos tipos de suas componentes de: Erro (E), Tendência (T) e Sazonalidade (S). Para cada componente, existem as possibilidades de:

- Erro: aditivo (A), multiplicativo (M);
- Tendência: nenhuma (N), aditiva (A), aditiva amortizada (Ad), multiplicativa (M),
- multiplicativa amortizada (Md);
- Sazonalidade: nenhuma (N), aditiva (A), multiplicativa (M).

De acordo com Hyndman e Athanasopoulos (2018) as previsões produzidas usando métodos de suavização exponencial são médias ponderadas de observações passadas, com os

pesos decaindo exponencialmente à medida que as observações envelhecem. Ou seja, quanto mais recente a observação, maior o peso associado.

Hyndman; Athanasopoulos (2018) destacam ainda que os modelos podem ser estimados em R usando a função no pacote *forecast*. A função não gera previsões. Em vez disso, ele estima os parâmetros do modelo e retorna informações sobre o modelo ajustado.

O modelo pode ser apresentado como: ETS (\cdot , \cdot , \cdot), em que a primeira parte representa o tipo de erro, a segunda o tipo de tendência e a terceira o tipo de sazonalidade. O modelo SES equipara-se ao ETS (A, N, N), Holt ao ETS (A, A, N), Holt com tendência amortizada ao ETS (A, Ad, N), HoltWinters aditivo ao ETS (A, A, A) e HoltWinters multiplicativo ao ETS (A, A, M) (RAPPEL DE AMORIM, 2021). Mais detalhes sobre a formulação matemática do modelo podem ser encontrados no livro “*Automatic Time Series Forecasting: the Forecast Package for R*” de Hyndman, R. J.; Khandakar, Y.

2.2.2 AUTO.ARIMA

A função “AUTO.ARIMA” em R, faz parte do pacote *forecast* e, usa uma variação do algoritmo de Hyndman-Khandakar (Hyndman; Khandakar, 2008), e tem por objetivo associar testes de raiz unitária, minimização do AICc (Critério de Informação de Akaike corrigido) e MLE (Estimação de Máxima Verossimilhança) para obter um modelo, podendo ser ARIMA (*Auto-Regressive Integrated Moving Average*), SARIMA (*Seasonal ARIMA*) ou Média Móvel Simples (SMA) (Hyndman; Athanasopoulos, 2018).

Uma das justificativas para a modelagem automática ARIMA se dá pela complexidade na construção de um modelo ARIMA para o utilizador, que demanda um bom conhecimento do campo de aplicação e a disponibilidade de um programa de computador especializado fácil de utilizar e versátil (Mélard; Pasteels, 2000), o que por vezes pode inviabilizar a implementação do método.

2.2.2.1 ARIMA

O modelo ARIMA (*AutoRegressive Integrated Moving Average*) de Box-Jenkins, é composto por componentes diferenciais autorregressivos (AR) e de média móvel (MA) incorporados de termos sazonais (S), o que permite a captura de padrões sazonais ao longo do tempo e melhoria da precisão das previsões em séries temporais com variação sazonal (Box et al., 2015).

Os modelos Autorregressivos (AR), filtro de Integração (I) e Média Móvel (MA) tem fundação no pressuposto de que a série temporal seja construída por meio de um sistema linear, e que possuem um termo de erro aleatório não correlacionado, com média zero e variância constante, ou seja, um ruído branco (Gujarati, 2000).

De acordo com Hyndman, Koehler, Ord e Snyder (2008), o ARIMA é uma das técnicas de previsão de séries temporais mais populares e amplamente utilizadas devido à sua capacidade de lidar com séries temporais complexas e à sua facilidade de implementação. Assim, os modelos ARIMA podem ajudar a entender a operação dos dados em uma determinada aplicação (Babu; Reddy, 2014).

Os modelos Box-Jenkins realizam a combinação de três filtros: o AR (componente Autorregressivo), o I (filtro de Integração) e o MA (componente de Médias Móveis), sendo que a série pode ser modelada por todos ou apenas um subconjunto destes, resultando em diversos modelos (Fava, 2000).

Assim, um modelo autorregressivo (AR) (1) de ordem p , representado compactamente por $AR(p)$, é escrito como:

$$y_t = c + \phi_1 \cdot y_{t-1} + \phi_2 \cdot y_{t-2} + \dots + \phi_p \cdot y_{t-p} + \varepsilon_t \quad (1)$$

Onde c é o intercepto e t uma sequência de variáveis aleatórias independentes igualmente distribuídas denominada erro ou resíduo (Hyndman; Athanasopoulos, 2018).

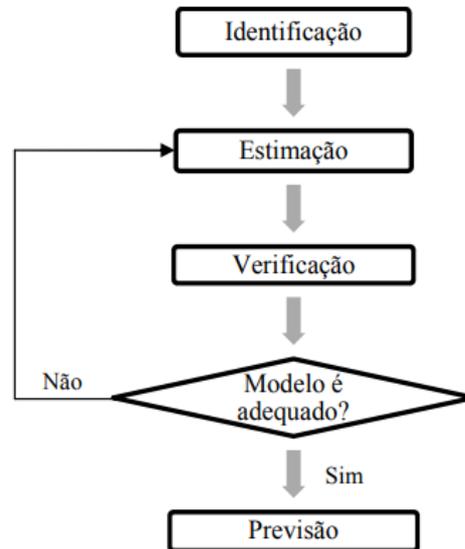
Já um modelo de média móvel (MA) (2) de ordem q , usa erros de previsão passados em um modelo semelhante a uma regressão:

$$\hat{y}_t = c + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q} \quad (2)$$

Segundo Morettin e Tolo (2004) a execução desse método tem base em um ciclo iterativo, e é composto por quatro etapas: identificação (baseado na verificação de qual modelo descreve o comportamento da série, faz uso da interpretação dos correlogramas das funções de autocorrelação (FAC) e das funções de autocorrelação parcial (FACP), estimação (realiza-se a estimativa dos parâmetros do componente auto regressivo, do componente de médias móveis e da variância), verificação (analisa se o modelo selecionado é condizente com o comportamento da série, por meio da análise dos resíduos) e previsão (entrega do objetivo

principal, realizada apenas se as etapas anteriores forem satisfatórias). A Figura 2 representa esse ciclo.

Figura 2 - Ciclo interativo de Box-Jenkins



Fonte: Marchezan (2007)

2.2.2.2 Pacote Forecast

Para Hyndman et al. (2020) o pacote *forecast* é constituído de métodos e ferramentas que permitem exibir e analisar as previsões de séries temporais univariadas, bem como suavização exponencial por meio de modelos de espaço de estados.

Ela calcula previsões pontuais e intervalos de predição a partir do modelo de série temporal. Existem métodos para modelos ajustados usando ETS (), AUTO.ARIMA (), ARIMA (), ARIMA (), AR (), HoltWinters () e StructTS () (Hyndman; Khandakar, 2008).

Hyndman e Khandakar (2008) ainda afirmam que a saída da função `forecast ()` é um objeto da classe "forecast" e inclui pelo menos as informações:

- A série original;
- Previsões pontuais;
- Intervalos de predição de cobertura especificada;
- O método de previsão usado e informações sobre o modelo ajustado;
- Resíduos do modelo ajustado;

- Previsões de um passo do modelo ajustado para o período dos dados observados.

Para previsão utilizando modelagem ETS, o comando realiza automaticamente um processo de minimização não linear do critério de informação adotado, calculando os parâmetros que serão utilizados nas equações de previsão (Cordeiro Júnior, 2007). De acordo com Martinello, L. M. et al (2021) o pacote forecast permite escolher o modelo de suavização exponencial e os dados são moldados mais satisfatoriamente.

Já quando utilizando o AUTO.ARIMA, o principal objetivo é selecionar um modelo adequado através da escolha da ordem p, d, q que é realizado através de testes de raiz unitária e o critério de AIC. Para dados não-sazonais, considera-se ARIMA (p, d, q) onde d é selecionado com base em sucessivos testes KPSS de raiz unitária. Para os dados sazonais, considera-se ARIMA (p, d, q) (P, D, Q) (Hyndman e Khandakar, 2008).

2.4 Análise de outliers

A detecção de outliers é o processo de identificar pontos de dados em um conjunto de dados que são significativamente diferentes do restante dos dados. Esses pontos atípicos podem ser mais altos ou mais baixos do que o esperado em relação ao padrão geral dos dados e podem distorcer análises estatísticas ou modelos preditivos se não forem tratados adequadamente. Existem várias abordagens estatísticas para identificar *outliers*. Alguns critérios comuns incluem:

- Regra dos 1,5 ou 3 desvios-padrão: Considera-se como outliers os valores que estão a uma certa distância (1,5 ou 3 vezes o desvio-padrão) da média.
- Intervalo interquartil (IQR): Calcula-se o intervalo interquartil (diferença entre o primeiro quartil $Q1$ e o terceiro quartil $Q3$) e considera-se outliers os valores que estão fora de uma faixa estabelecida (por exemplo, 1,5 vezes o IQR abaixo do $Q1$ ou acima do $Q3$).
- Z-score: Calcula-se o escore z para cada valor, que representa o número de desvios-padrão em relação à média. Valores com *score* z alto (acima de um limite estabelecido, como 2 ou 3) podem ser considerados outliers.
- MAD: O método envolve o cálculo do Desvio Absoluto Mediano, que é a mediana das diferenças absolutas entre cada valor e a mediana dos dados. Valores que

estão acima de um limiar, geralmente definido como um múltiplo do MAD (por exemplo, 2 vezes o MAD), são identificados como outliers.

2.4 Coeficiente de erro

A utilização de métodos que consigam identificar o tamanho do erro, se é grande ou pequeno, torna-se válida para análises desta importância. (Gujarati, 2011).

A Média Absoluta Percentual de Erro (MAPE) é uma medida de erro que reproduz a média das diferenças percentuais entre os valores previstos e os valores observados. Quanto menor o valor da MAPE, maior a precisão do modelo em relação aos dados observados (Montgomery; Jennings; Kulahci, 2015).

A Média Absoluta de Erro (MAE) é uma medida de erro que reflete a média das diferenças absolutas entre os valores previstos e os valores observados. É utilizada para avaliar a precisão de modelos de previsão em diferentes áreas, como finanças, economia, energia e meio ambiente. Quanto menor o valor da MAE, maior a precisão do modelo em relação aos dados observados (Pai; Lin, 2005; Hyndman; Koehler, 2006).

O Erro Médio (EM) é uma medida de erro que espelha a média aritmética dos erros, onde o erro é a diferença entre os valores previstos e os valores observados. Ele fornece uma base da direção geral do erro, mas não penaliza erros maiores do que os menores, como faz o RMSE. Quanto menor o valor do EM menor é a magnitude média dos erros entre as previsões e os dados observados, o que sugere uma precisão maior do modelo em relação aos dados reais (Pai; Lin, 2005; Hyndman; Koehler, 2006).

O Quadrático Médio da Raiz (RMSE) é uma medida de erro que representa a raiz quadrada da média dos erros ao quadrado. É uma medida mais sensível a grandes desvios em relação à MAE, pois penaliza mais fortemente os erros maiores. É amplamente utilizada em estudos de previsão em áreas como meteorologia, hidrologia e ciências ambientais. Quanto menor o valor do RMSE, maior a precisão do modelo em relação aos dados observados (Butcher; Smith, 2020).

O Escalar Médio Absoluto (MASE) é uma medida de erro que representa a relação entre a MAE do modelo e a MAE de um modelo de referência. É uma medida útil para comparar a precisão de diferentes modelos em séries temporais, pois elimina a necessidade de escolher um modelo de referência arbitrário. Quanto menor o valor do MASE, melhor o

desempenho do modelo em relação ao modelo de referência. É amplamente utilizado em estudos de previsão em áreas como energia, finanças e transporte (Hyndman; Koehler, 2006).

3 MÉTODO DE PESQUISA

No capítulo 3, serão abordados os seguintes tópicos: classificação da pesquisa e etapas do estudo de caso. A classificação da pesquisa incluirá a definição do tipo de pesquisa realizada e a metodologia adotada. As etapas do estudo de caso serão descritas desde a identificação do problema até a análise dos resultados obtidos

3.1 Classificação da pesquisa

A pesquisa tem caráter exploratório e explicativo, pois de acordo com Gil (2008), a pesquisa exploratória (que também pode assumir a forma de estudo de caso ou pesquisa bibliográfica) proporciona maior familiaridade com o problema. Ainda Gil (2008) discorre sobre a pesquisa explicativa, que faz uso de dados específicos para identificar os fatores que determinam ou que contribuem para a ocorrência dos fenômenos.

Com relação aos procedimentos técnicos de coleta de dados, a pesquisa é um estudo de caso. Pois, neste trabalho serão utilizados dados secundários, que segundo Gil (2008), são dados que de alguma forma já foram coletados e analisados, como, por exemplo, relatórios de empresas, tabelas estatísticas, entre outros. Estudo de caso que é quando envolve o estudo profundo e exaustivo de um ou poucos objetos de maneira que se permita o seu amplo e detalhado conhecimento (Silva; Menezes, 2005).

Gil (2010) destaca a importância de utilizar técnicas estatísticas adequadas para a análise dos resultados obtidos pelos modelos de previsão de demanda. Segundo o autor, a análise dos resultados deve levar em consideração a distribuição dos erros e a presença de possíveis outliers ou padrões sazonais nas séries de dados. Dessa forma, é possível identificar possíveis problemas nos modelos e ajustá-los para melhorar a precisão das previsões.

3.2 Etapas do Estudo de caso

Segundo Roesch (2017), o estudo de caso pode ser dividido em cinco etapas: o planejamento, a definição do problema, a preparação para a coleta de dados, a coleta e análise dos dados e, por fim, a elaboração do relatório final. O Quadro 2 descreve com mais detalhes as etapas.

Quadro 2 - Etapas do estudo de caso

Fase	Descrição
Planejamento	Definir objetivo geral, questões de pesquisa, selecionar

	casos e técnicas de coleta de dados.
Definição do problema	Identificar fontes de informação, analisar dados disponíveis e identificar o problema central do estudo.
Preparação para coleta de dados	Selecionar técnicas de coleta de dados, definir amostra e critérios de seleção dos participantes.
Coleta e análise dos dados	Coletar dados por meio de entrevistas, observação direta e análise de documentos. Analisar dados para identificar padrões, relações e categorias.
Elaboração do relatório final	Apresentar resultados e conclusões do estudo, incluindo descrição dos procedimentos metodológicos, análise dos dados coletados, discussão dos resultados obtidos e conclusões em relação às questões de pesquisa.

Fonte: adaptado de Roesch (2017)

3.1.1 Coleta de dados

Na primeira etapa, os dados coletados para a realização dos cálculos e aplicação dos modelos de previsão são oriundos da produção de feijão carioca tipo 1 e arroz branco tipo 2, ambos os produtos mais vendidos da organização. Os dados do histórico de vendas, que compreendem o período para análise é de janeiro de 2019 até dezembro de 2022, foram fornecidos por planilhas disponibilizadas por uma empresa de beneficiamento de cereais, localizada no Agreste de Alagoas.

3.1.2 Tratamento dos dados

Os dados foram tabulados em planilhas eletrônicas com o intuito de serem utilizados no *software* de análise de séries temporais. O *software* utilizado para análise das séries temporais foi o RStudio. A análise de *outliers*, que é uma etapa essencial no processo de análise exploratória de dados, foi aplicada, sendo fundamental para identificar pontos discrepantes que possam influenciar de maneira significativa os resultados ou inferências obtidas a partir dos dados, de acordo com Hodge e Austin (2004), geralmente pode ser descrito como um ponto de dados que é significativamente diferente de outros pontos de dados ou um ponto que não imita o comportamento típico esperado dos outros pontos.

3.1.3 Análise dos dados e escolha dos métodos de previsão

A terceira etapa é a análise dos dados de entrada, com uso do *software* computacional Microsoft Office Excel onde são feitas as diligências cabíveis para que a modelagem matemática estime da maneira mais confiável possível o comportamento dos dados da demanda e, por indução, possa gerar a melhor previsão.

Seguem-se os modelos utilizados e as justificativas de alguns modelos de séries temporais, dentre os apresentados, os mais confiáveis para prever a demanda por produto.

Para a elaboração do sistema de previsão de demanda, foi adotado o método quantitativo baseado na análise de séries temporais, que é utilizado para prever a demanda futura com base em dados históricos. Esse método é amplamente utilizado em empresas de diversos segmentos, inclusive no setor de alimentos, como apontado por Moreira (2011). Com a aplicação dos modelos seleção automática ETS e AUTO.ARIMA, que por meio da simulação em R, irão calcular todas as combinações possíveis dos modelos e apresentar os que obtiveram os melhores resultados.

A utilização do Modelo ETS pode ser justificada pela necessidade de capturar variações sazonais recentes e flutuações temporais de curto prazo na demanda por feijão e arroz. Dada a possível influência de fatores climáticos e hábitos sazonais de consumo, esse modelo oferece uma maneira de considerar essas flutuações em um período recente. Pela sua facilidade de adaptação para uma ampla variedade de séries temporais, incluindo aquelas com tendência, sazonalidade e variação irregular, o ETS permite ajustar modelos com diferentes combinações de erros, tendências e sazonalidades, tornando-o adequado para uma variedade de cenários. Além disso, o pacote *forecast* no R fornece funções convenientes para ajustar e prever com modelos ETS com apenas algumas linhas de código.

Por fim, o uso do Modelo AUTO.ARIMA encontra justificação quando se deseja capturar padrões sazonais complexos e correlações entre os dados, o modelo automatiza a seleção do melhor modelo ARIMA para uma determinada série temporal, com base em critérios estatísticos especialmente quando essas características são evidenciadas por meio de análises estatísticas como AIC (Critério de Informação de Akaike) e BIC (Critério de Informação Bayesiano). Isso elimina a necessidade de tentativa e erro na escolha do modelo adequado, sendo capaz de ajustar modelos ARIMA com diferentes combinações de termos autorregressivos, diferenciação e médias móveis para capturar a complexidade dos dados.

3.1.4 Modelagem da demanda

A última etapa envolve a modelagem matemática do comportamento da demanda. O modelo, determina padrões para o comportamento da demanda, e como todos os modelos baseados na análise de séries temporais, admite que esses padrões tendem a reincidir, e assim, cria as hipóteses para os períodos futuros.

A partir do resultado dos modelos, foi possível fazer a comparação dos resultados com intuito de selecionar os métodos mais adequados para o estudo de caso com base nos cálculos dos erros: Média Absoluta Percentual de Erro (MAPE), Média Absoluta de Erro (MAE), Erro Médio (EM), Raiz do Erro Quadrático Médio (RMSE) e Escalar Médio Absoluto (MASE).

4 ESTUDO DE CASO

O estudo de caso concentra-se em analisar a eficiência de modelos de previsão de demanda, crucial para a gestão eficaz de operações e estoques. Com base nos dados coletados, o estudo visa identificar o modelo de previsão mais adequado às características específicas das séries temporais de vendas. Diversos métodos de previsão serão aplicados e avaliados, com o intuito de selecionar aquele que apresentar a maior acurácia na previsão das vendas reais.

4.1 Descrição da empresa em estudo

A indústria do estudo de caso tem sede no agreste alagoano, e desde agosto de 2012 atua no mercado da produção de grãos, com instalações para beneficiamento e empacotamento de feijão, arroz e milho, em seus mais variados tipos. Possui laboratório de qualidade próprio e uma estrutura de armazenagem para a recepção e estocagem em silos para os grãos. A empresa mantém suas análises acompanhadas pelo Ministério da Agricultura Pecuária e Abastecimento (MAPA) e pelo Instituto Nacional de Metrologia, Normalização e Qualidade Industrial (INMETRO)

Referente a seu processo produtivo, as 3 células de produção são automatizadas, e cada uma conta com a operação de dois colaboradores na parte da operação. Em perspectiva geral, conta com 30 colaboradores, sendo 25 no setor de produção e 5 no administrativo. Tem capacidade de processamento de 5000 kg por hora de feijão carioca e 5000 kg de arroz branco. Ademais, na agroindústria os grãos passam por tratamentos de dedetização, a fim de evitar o surgimento de pragas e doenças nos grãos.

Atualmente a empresa utiliza o método da média móvel de 3 períodos para previsão de demanda. Embora o método da média móvel de 3 períodos seja vastamente empregado, é importante examinar suas limitações perante as complexidades do ambiente de negócios. Este método, embora cristalino e de fácil aplicação, pode não capturar devidamente padrões sazonais, tendências de longo prazo ou eventos extraordinários, como a pandemia de COVID-19. Para uma empresa que opera em um mercado dinâmico como o de grãos, é fundamental empregar técnicas de previsão mais avançadas que levem em consideração múltiplos fatores, como sazonalidade das culturas, flutuações nos preços de mercado, mudanças nas preferências do consumidor e eventos externos impactantes.

Além disso, o amparo de métodos de previsão mais avançados pode proporcionar uma vantagem competitiva, permitindo à empresa antecipar-se às demandas do mercado, otimizar seus estoques e recursos de produção, reduzir custos e melhorar a satisfação do cliente. Desse modo, é primordial que a empresa avalie constantemente e atualize suas técnicas de previsão,

4.2 Coleta de dados

A coleta dos dados teve como intervalo o período de janeiro de 2019 a dezembro de 2022. O motivo da não coleta dos dados anteriores a janeiro de 2019, foi a indisponibilidade deles no atual sistema utilizado pela organização, visto que não houve inserção destes dados mais antigos no novo sistema. É possível observar que no intervalo de tempo entre março e maio de 2020 houve um aumento relativo nas vendas tanto do feijão quanto do arroz, fato consumado devido ao estopim da pandemia, em que segundo o gestor, o governo buscou parceria com a organização para compra e posterior distribuição de alimentos a famílias de baixa renda impactadas diretamente pela necessidade do isolamento e fechamento de diversos setores da economia.

Mediante isso, o estudo de caso consistiu em uma análise de eficiência de modelos historicamente conhecidos, com o intuito de investigar qual deles melhor se adapta aos dados das vendas de feijão e arroz na agroindústria em questão. Esta análise não é apenas informativa, mas também essencial para entender como as tendências de consumo, o comportamento do consumidor e como as cadeias de suprimentos se comportam.

4.3 Análise de dados

4.3.1. Tratamento dos dados

O propósito desta seção é demonstrar a verificação de algumas características análogas das séries temporais já vistas nesse estudo, tais como: tendência, ciclicidade, sazonalidade e componentes aleatórios. Dessa forma, otimizando o processo decisório de qual modelo se adequa de maneira mais satisfatória para uma determinada situação. Entretanto, neste trabalho, o objetivo é analisar o desempenho de métodos quantitativos de previsão de demanda, baseados em séries temporais, em uma indústria alimentícia localizada no Agreste alagoano e selecionar entre eles o método com a maior acurácia possível, ou seja, a menor margem de erro para a previsão real. Isso significa que, embora a análise gráfica indique qual técnica será aplicada, outros modelos serão testados e avaliados.

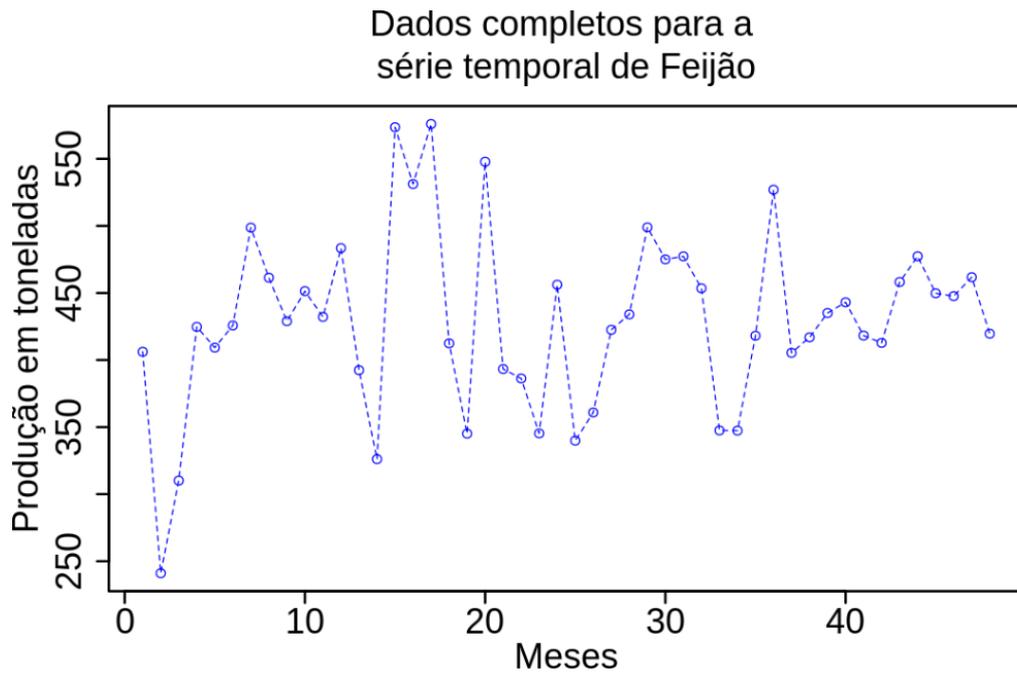
Os bancos de dados do feijão e do arroz utilizados como base para o estudo estão demonstrados nos apêndices A e B, respectivamente. Para realização de uma análise mais precisa, os gráficos foram dispostos em série e em paralelo. Em série, para analisar a possível presença da componente de tendência. E, em paralelo, para identificar a ocorrência ou não de sazonalidade.

4.3.2 Análise dos dados para o feijão

De acordo com relatório de Acompanhamento da Safra Brasileira de Grãos | V.7 – Safra 2019/20, N°1 – Primeiro Levantamento (CONAB, 2019) por ser uma cultura de ciclo curto, o feijão possibilita o plantio em até três momentos durante a temporada, na busca pelo equilíbrio no abastecimento e, ainda aponta que a perda de espaço para a cultura da soja e do milho foi expressiva, com destaque para a Região Sul do País, especialmente no Paraná, onde a redução foi estimada em 35,1%. Além disso, é evidente um pico, nos meses de março, abril e maio de 2020, quando a pandemia de COVID-19 eclodiu. Visto que a quarentena incentivou a população a fazer suas refeições em casa, fator que também contribuiu para o aumento do consumo do grão (Acompanhamento Da Safra Brasileira De Grãos | V.8 – Safra 2020/21, N°1 – Primeiro Levantamento, 2020).

No Gráfico 1 pode-se observar a leve tendência de crescimento nas vendas do feijão do período de 2019 a 2022, destaque para o vale detectado no início de 2019, considerando fatores políticos e econômicos da época.

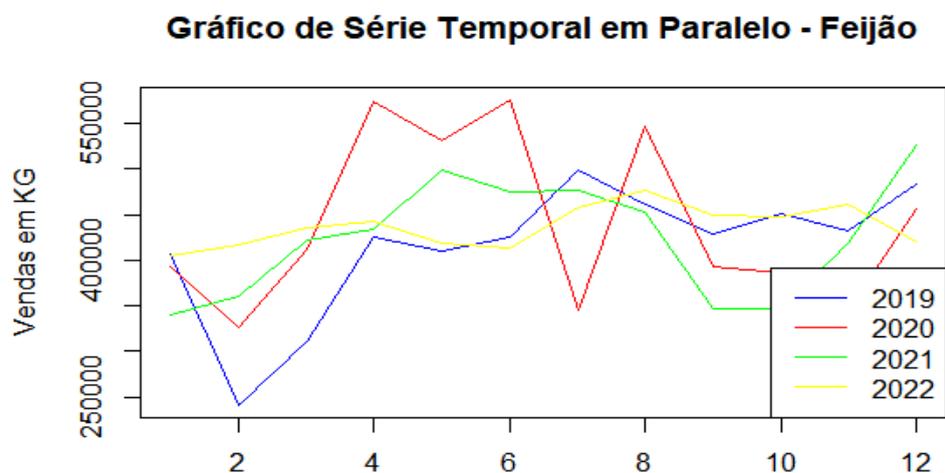
Gráfico 1 - Vendas em série do feijão



Fonte: Elaboração própria.

Para o Gráfico 2, é notório que não há um comportamento bem definido, o que pode caracterizar a presença da componente aleatória, entretanto, com uma análise mais a fundo, em alguns meses podemos identificar certo grau de semelhança, como no intervalo de setembro a dezembro, sendo essa a época de colheita da primeira safra, de janeiro a março, época da segunda safra, de abril e junho, época de colheita da terceira safra.

Gráfico 2 - vendas em paralelo do feijão

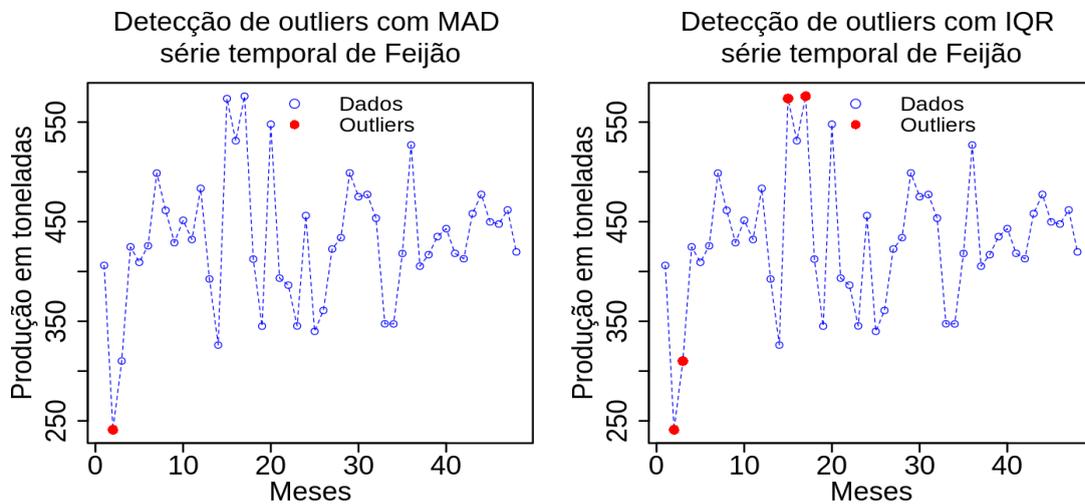


Fonte: Elaboração própria.

Dada a discrepância observada nos gráficos, uma análise de *outlier* foi aplicada com o uso de critérios estatísticos. Esses métodos estatísticos são especialmente úteis para mitigar o impacto de valores atípicos que podem distorcer a análise.

Para esse estudo, o Intervalo interquartil (IQR) e o Desvio Absoluto Mediano (MAD) foram aplicados para o feijão, por ser uma abordagem mais sólida, robusta e complementar, fornecendo uma validação cruzada e aumentando assim a confiabilidade da detecção de outliers, diminuindo o risco de falsos positivos ou falsos negativos. Os resultados são apresentados no Gráfico 3.

Gráfico 3 - identificação de outliers nos dados do feijão

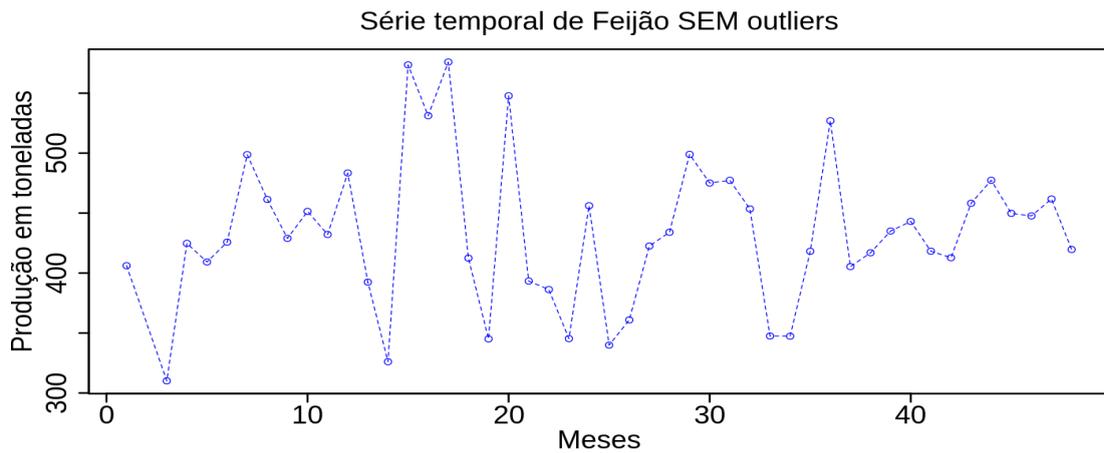


Fonte: Elaboração própria.

Com base na identificação de outliers usando os métodos (Intervalo interquartil - IQR e Desvio Absoluto Mediano - MAD), foi observado que apenas o segundo ponto do banco de dados foi identificado como *outlier* em ambas as abordagens, com um valor de 241.050. Esse resultado é relevante e tem implicações na análise dos dados. Portanto, fortalece a confiança na decisão de removê-lo.

Dada a remoção do *outlier*, no gráfico 4 pode-se observar o impacto causado na série temporal, à medida que, a linha de tendência saiu de um cenário claro de crescimento para um de considerável estacionariedade.

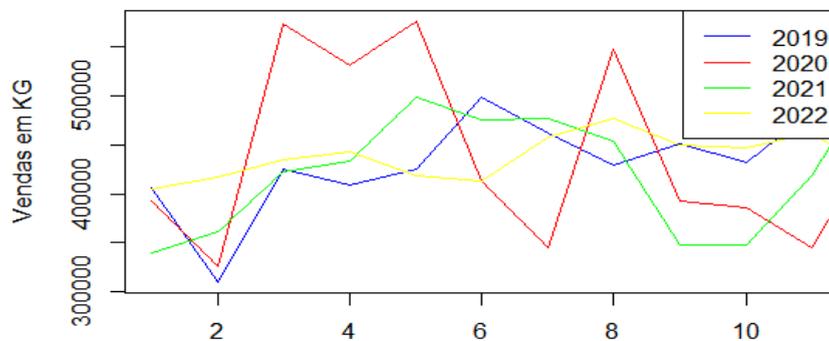
Gráfico 4 - vendas em série do feijão sem outliers



Na disposição em paralelo, no gráfico 5 fica clara a redução da oscilação nos valores de vendas em kg, ao ponto que foi extirpada uma variação de mais 50.000 kg da análise.

Gráfico 5 - vendas em paralelo do feijão sem outliers

Gráfico de Série Temporal em Paralelo Sem Outliers - Feijão



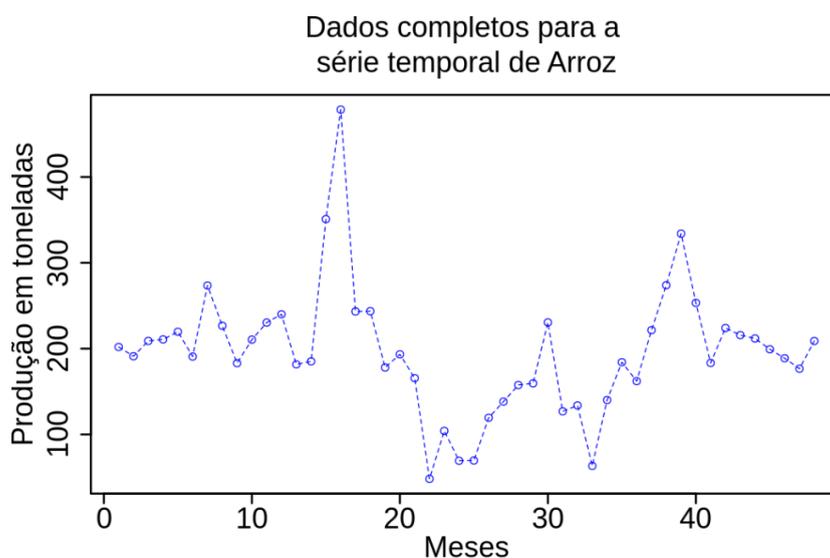
4.3.3 Análise de dados para o arroz

Identificou-se nos dados do arroz a tendência de queda, aliada a presença de vales no início e fim de 2021, devido às ocorrências de carência de arroz ocasionadas por fatores climáticos com longas estiagens nos períodos e, picos no início de 2020, caracterizado também pelo estopim da pandemia de COVID-19 e no início de 2022 mediante a um período de safra que ocorreu logo após a escassez da safra anterior.

A contração da tendência para a previsão pode ser atribuída a fatores excepcionais que

ocorreram neste ano, sendo o principal responsável a alta nos preços, refletindo a queda de produtividade e redução da área plantada, em meio à reduzida rentabilidade projetada para o setor, com a menor atratividade financeira do setor orizícola em relação às culturas concorrentes por área, como a soja e o milho (ACOMPANHAMENTO DA SAFRA BRASILEIRA DE GRÃOS | V.10 – SAFRA 2022/23, Nº1 – PRIMEIRO LEVANTAMENTO, 2022). No gráfico 6 ficam expostos os comentários realizados anteriormente.

Gráfico 6 - vendas em série do arroz

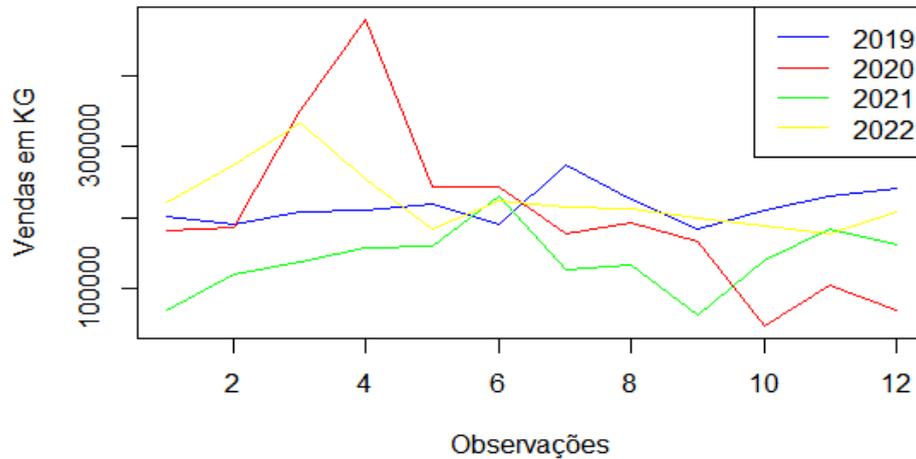


Fonte: Elaboração própria.

No gráfico 7, é válido ressaltar a presença de sazonalidade entre julho e setembro, caracterizado pela época de fim de safra na região, que é quando os estoques estão entrando em declínio. Não sendo possível a identificação da sazonalidade no restante do ano, muito por conta das oscilações na época de safra a partir de outubro até meados de fevereiro e, no restante do ano, pelas variações econômicas no mercado.

Gráfico 7 - vendas em paralelo do arroz

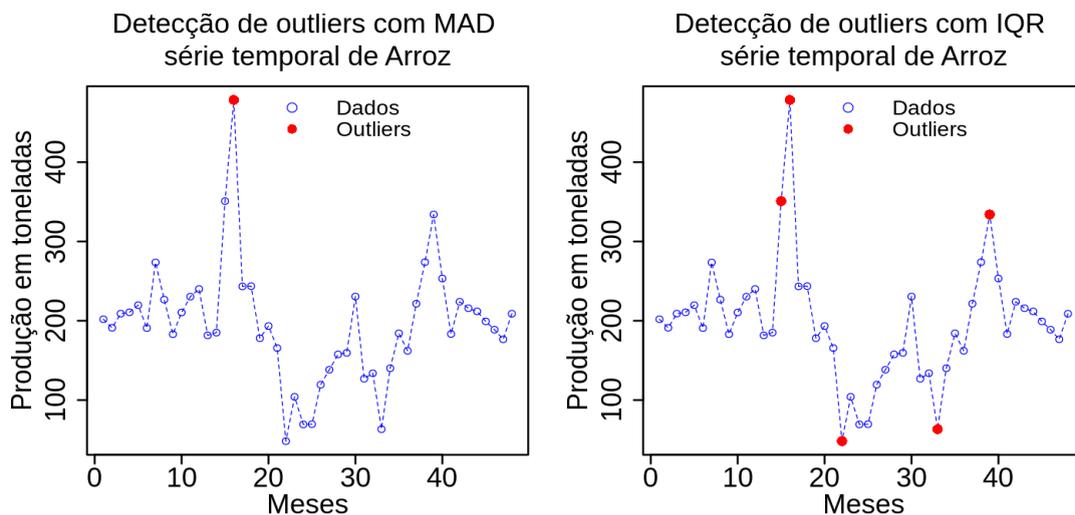
Gráfico de Série Temporal em Paralelo - Arroz



Fonte: Elaboração própria.

Identificados os fatores que podem ter impacto nos resultados, a análise de *outliers* foi mais uma vez utilizada seguindo os mesmos parâmetros aplicados para a análise do feijão. No gráfico 8 pode-se observar os *outliers* encontrados.

Gráfico 8 - identificação dos outliers nos dados do arroz



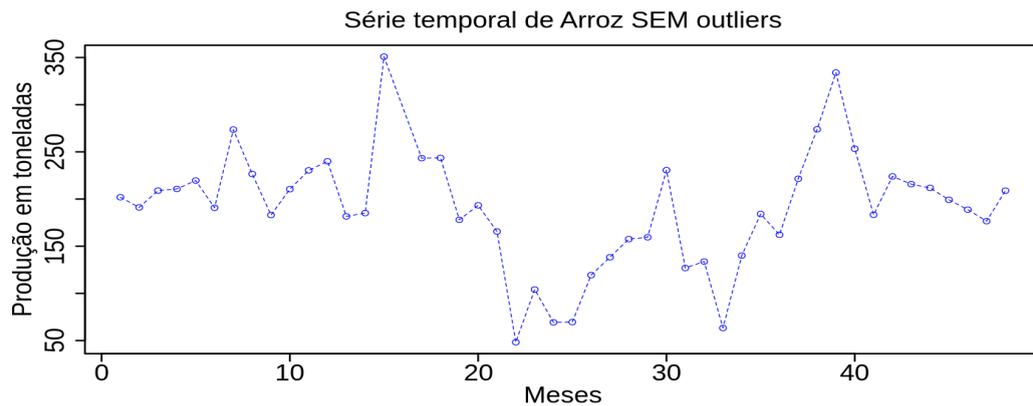
Fonte: Elaboração própria.

Com base na identificação de *outliers* usando os métodos MAD e IQR, foi observado que apenas o décimo sexto ponto do banco de dados foi identificado como outlier em ambas as abordagens, com um valor de 478.500. Esse resultado se apresenta como relevante e traz

implicações significativas para a análise dos dados. Conseqüentemente, ele aumenta a confiança na decisão de eliminar esse valor discrepante.

Dada a remoção do *outlier*, no gráfico 9 é nítida a minimização da tendência de queda, visto um decréscimo de mais de 50 toneladas na linha de tendência.

Gráfico 9 - vendas em série do arroz sem outliers

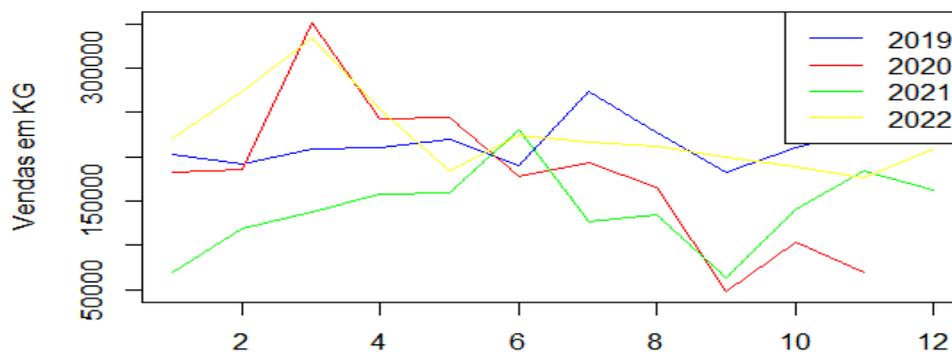


Fonte: Elaboração própria.

Na disposição em paralelo, no gráfico 10 já não é mais possível visualizar pontos de pico acentuados, havendo também redução de 150.000 kg na variação da análise.

Gráfico 10 - vendas em paralelo do arroz sem outliers

Gráfico de Série Temporal em Paralelo Sem Outliers - Arroz



Fonte: Elaboração própria.

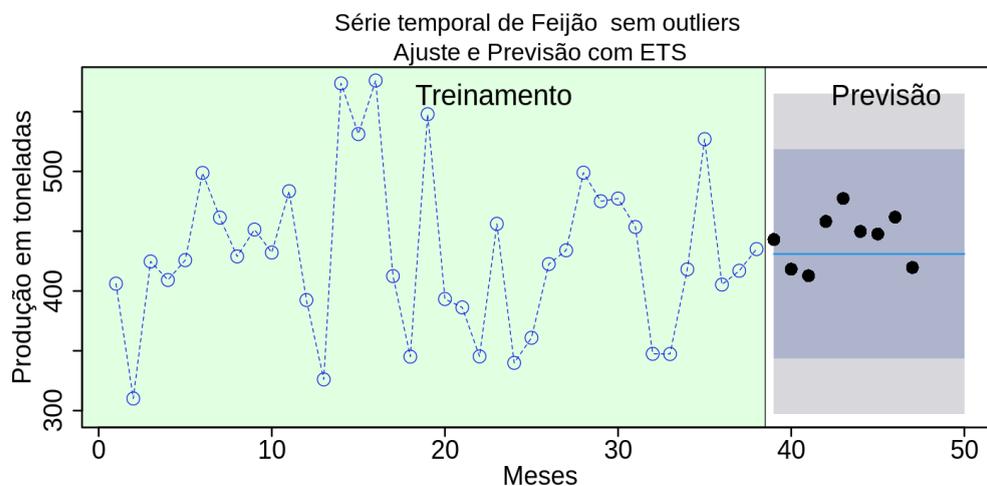
4.4 Análise dos modelos por produto e a sua escolha

Nesta seção, são apresentados os valores dos coeficientes dos vários modelos testados, bem como uma avaliação dos níveis de acurácia calculados a partir das previsões estimadas para análise e comparação de dados, para os dois cenários analisados anteriormente. A partir dessa análise, pode-se mostrar qual modelo proposto melhor se ajusta à amostra de dados observada para cada produto estudado. Para tanto, experimentar-se-ão os modelos de Média Móvel para 3 períodos, Suavização Exponencial Simples, Suavização Exponencial Dupla de Holt, Suavização Exponencial Tripla de Holt-Winters e SARIMA, em que o ETS e o AUTO.ARIMA irão apresentar o método que apresentar as melhores condições (menores coeficientes de erro). Vale destacar que a empresa em estudo utiliza para cálculo de previsões e planejamento a média móvel de 3 períodos.

4.4.1 Avaliação do modelo para o feijão

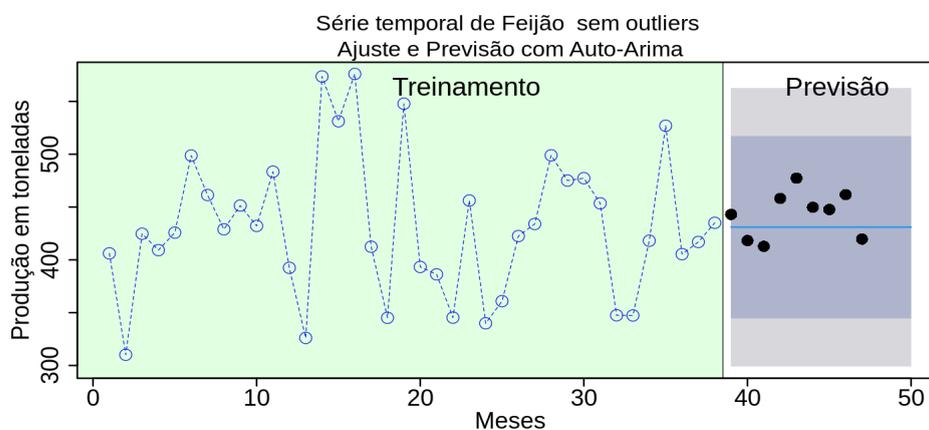
No Gráfico 11 e 12, com o modelo ETS e modelo AUTO.ARIMA, respectivamente, foi possível notar a manutenção do padrão dos últimos 4 anos para a previsão, com a tendência de queda no primeiro trimestre. O padrão pode ser interpretado como uma sazonalidade ou comportamento cíclico nas vendas ao longo dos anos. Esse padrão pode ser influenciado por vários fatores, como sazonalidade climática, eventos sazonais específicos do setor agrícola (como o que ocorreu em 2019), ou mesmo padrões de comportamento de compra do consumidor durante determinadas épocas do ano (como o que ocorreu em 2020).

Gráfico 11- previsão gráfica para o feijão com o modelo ETS



Fonte: Elaboração própria.

Gráfico 12 - previsão gráfica para o feijão com o modelo AUTO.ARIMA



Fonte: Elaboração própria.

Com o intuito de que se possa indicar qual, dentre os modelos testados é mais adequado ao padrão de dados referente à série disponibilizada para estudo, foram descritas as informações que, efetivamente, basearam a conclusão do modelo mais acurado, que são as medidas de acurácia: Média Absoluta Percentual de Erro (MAPE), Média Absoluta de Erro (MAE), Erro Médio (EM), Raiz do Erro Quadrático Médio (RMSE) e Escalar Médio Absoluto (MASE). Destacadas nas tabelas 1 e 2, para o feijão e o arroz, respectivamente.

Tabela 1- resultados dos erros dos modelos para os dados do feijão

MODELO	FEIJÃO				
	MAPE	MAE	EM	RMSE	MASE
ETS	12.338	51.893	0.047	66.458	0.77440
AUTO.ARIMA	12.340	51.896	9,693e-11	66.455	0.77443

Fonte: Elaboração própria.

Na tabela 1, com os dados de 2019 a 2022 para o feijão, pode-se observar em negrito qual modelo melhor se comportou em relação a cada uma das medidas de acurácia, com destaque para o ETS, que apresentou melhores resultados no MAPE (12.338), MAE (51.893) e no MASE (0.77440).

Tabela 2 – Parâmetros do modelo ETS para o feijão

FEIJÃO			
ETS	ERRO	TENDÊNCIA	SAZONALIDADE
PARÂMETROS	M	N	N

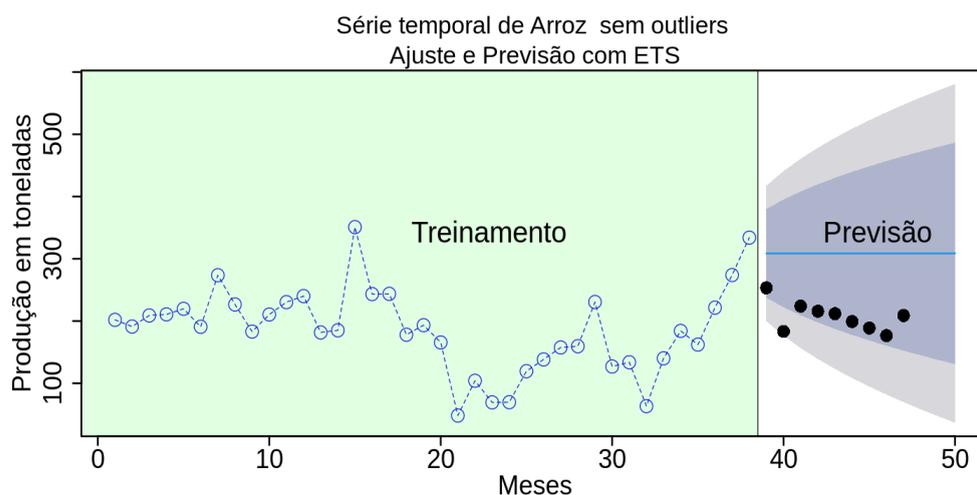
Fonte: Elaboração própria.

Na tabela 2, ficam expostos os parâmetros de erro, tendência e sazonalidade responsáveis pelos resultados apresentados na tabela 1. Com a configuração ETS (M, N, N), multiplicativo, nenhum e nenhum, respectivamente, tem-se uma suavização exponencial simples com erros aditivos, não havendo identificação de sazonalidade e tendência na série histórica.

4.4.2 Avaliação do modelo para o arroz

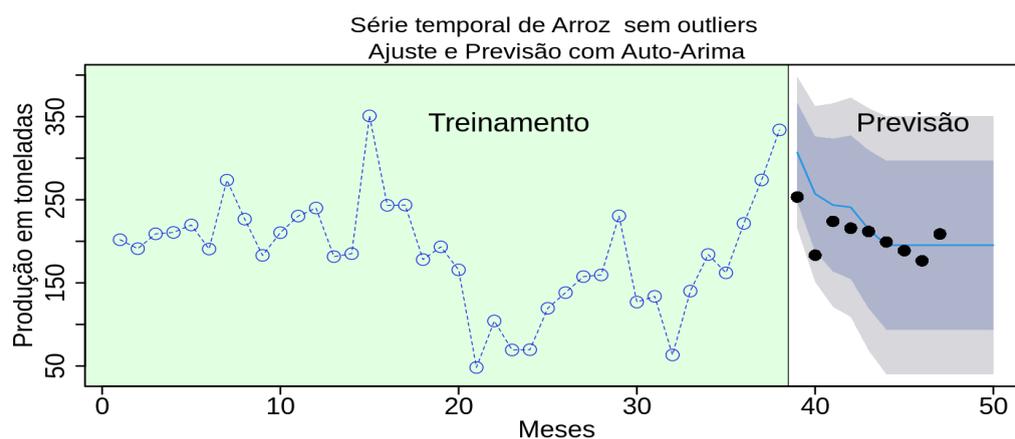
Com os dados do arroz, a previsão indicou de queda nas vendas, tanto utilizando o modelo ETS, no Gráfico 13, quanto utilizado o modelo AUTO.ARIMA, no Gráfico 14, contrapondo a alta de 2022, estimativa corroborada pela redução de aproximadamente 7% na colheita (10.033,2 toneladas, de 22/23 frente 10.780,5 toneladas, de 21/22) apresentada no relatório de Acompanhamento da Safra Brasileira de Grãos | V.11 – Safra 2023/24, N°1 – Primeiro Levantamento (CONAB, 2023).

Gráfico 13 - previsão gráfica para o arroz com o modelo ETS



Fonte: Elaboração própria.

Gráfico 14 - previsão gráfica para o arroz com o modelo AUTO.ARIMA



Fonte: Elaboração própria.

Os desempenhos das técnicas e metodologias propostas para o presente estudo de caso foram compilados na tabela 3, com os dados de 2019 a 2022 para o arroz, nele estão contidas as comparações entre metodologias de previsão em termos de diferentes medidas de discrepância para as previsões obtidas. Tem-se destaque para AUTO.ARIMA, com melhores resultados nos 5 coeficientes de erros utilizados.

Tabela 3 - resultados dos erros dos modelos para os dados do arroz

MODELO	COEFICIENTES	ARROZ				
		MAPE	MAE	EM	RMSE	MASE
ETS		28.950	41.091	4.127	54.042	0.945
TO.ARIMA		22.527	31.942	0.574	42.635	0.734

Fonte: Elaboração própria.

Pela tabela 4, ficam expostos os parâmetros de AR, D e MA responsáveis pelos resultados apresentados na tabela 3. Com a configuração (0, 0, 5), tem-se um modelo ser termos autorregressivos, sem diferenciação, mas com cinco termos de média móvel, que

indicam a dependência linear nos erros da série, sem necessidade de diferenciação para neutralizar a variância.

Tabela 4 - Parâmetros do modelo AUTO.ARIMA para os dados do arroz

ARROZ			
TO.ARIMA	AR	D	MA
PARÂMETROS	0	0	5

Fonte: Elaboração própria.

4.4.3 Determinação do método ideal

O método de previsão com o menor valor de erro para a referida série de dados será admitido como o mais adequado para o produto, ou seja, com maior grau de acurácia. Analisando os resultados da tabela 1, que analisa os dados do feijão, constatou-se que o método de maior acurácia foi o ETS, considerando as métricas de erros do MAPE (12.338), MAE (51.893) e no MASE (0.77440).

Para a tabela 3, que analisa os dados do arroz, o método que apresentou menor variação de erro foi o AUTO.ARIMA, considerando as métricas de erro do MAPE (22.527), MAE (31.942), EM (-0.574), RMSE (42.635) e MASE (0.734). A obtenção de valores de erro tão próximos das medidas reais já era esperada, visto que o método da AUTO.ARIMA considera os parâmetros de tendência e sazonalidade presentes nas séries temporais, para o arroz, ao observar os erros EM e MASE.

No caso do feijão, observou-se maior similaridade na comparação entre os dois métodos, com variações apenas nas casas decimais em quatro dos cinco coeficientes de erro. Portanto, no que diz respeito à aplicação das metodologias sugeridas para a empresa estudada, observa-se um evidente potencial de ganho em precisão ao adotar essas técnicas que tanto permitem a extração de informações relevantes em termos estratégicos quanto identificação de padrões de crescimento e sazonalidade.

5 DISCUSSÕES

5.1. Perspectivas micro e macroeconômicas

Com a análise dos resultados da presente pesquisa, foi possível observar o quanto os fatores externos podem impactar diretamente na produção, a se confirmar pela necessidade de remoção de *outliers* que não condizem com a realidade da organização.

O período de 2020 a 2022 foi marcado por uma série de desafios e transformações, principalmente devido à pandemia de COVID-19. A análise entre esses anos se torna crucial para entender os impactos dessa crise global na produção e demanda dos produtos da agroindústria em questão.

A variabilidade nos dados durante esse período revelou padrões específicos, como a elevação exponencial do consumo nos primeiros meses da pandemia, influenciados por mudanças nas condições do mercado, em que grande parte do comércio teve de fechar suas portas devido às orientações de isolamento social, comportamento do consumidor, que por passar mais tempo em casa consequentemente tendenciou a dar maior importância a garantir seu estoque pessoal de alimentos, e desafios logísticos decorrentes das medidas de contenção da pandemia, considerando que mesmo com o não fechamento da indústria alimentícia, os clientes com pequenos comércios enfrentaram as políticas de isolamento.

Além dos efeitos da pandemia, é importante considerar outras variações externas que afetaram a produção e a demanda, como: reduções de safra, que de acordo com o Acompanhamento da Safra Brasileira de Grãos | V.7 – Safra 2019/20, N°1 – Primeiro Levantamento (CONAB, 2019) no início de 2019 foram causadas pela baixa rentabilidade identificada nas últimas safras e por condições climáticas desfavoráveis.

Os impactos econômicos e sociais, como mudanças nas condições financeiras dos consumidores e nas políticas governamentais, também possuem influência nas tendências. Assim relata o Acompanhamento da Safra Brasileira de Grãos | V.10 – Safra 202/23, N°1 – Primeiro Levantamento (CONAB, 2022) ao apontar que a estabilidade dos preços do feijão já não agradava aos comerciantes, agora, com a queda das cotações no período do plantio, observou-se certa frustração no mercado em razão das poucas oportunidades de ganho, especialmente para os produtores e empresas empacotadoras. Logo, é de suma importância que a inteligência da organização se mantenha atualizada e atenta tudo que possa ter impacto

sobre ela e, utilizar-se das inovações tecnológicas para angariar espaço no mercado de maneira orgânica e sustentável, sendo eficiente, eficaz e efetiva.

É válido ainda ressaltar que toda previsão apresenta erros, portanto os resultados são apenas estimativas e levando em consideração um cenário que não cogita expansão da indústria ou grandes elevações nas vendas dos grãos. Sendo os resultados das previsões estimativas baseadas em períodos passados, devem ser interpretados com cautela, especialmente considerando a possibilidade de mudanças repentinas no ambiente econômico, como eventuais novas quebras de safra, aumento ou redução de equipe, fomento de novas ou perda de atuais parcerias, tanto em nível regional quanto nacional.

5.2. Sazonalidade e tendências de consumo na Região do Agreste Alagoano

De acordo com Carvalho (2016), o crescimento do mercado regional consumidor atraiu empresas de grande porte, exemplificando redes de supermercado, tais como: Atacadão, Pão de Açúcar e Bom Preço. Esse aumento se deu em decorrência do aumento da renda per capita da população alagoana, que por consequência, auxiliam no desenvolvimento das indústrias da região (Mendes, 2020).

Entre fatores socioeconômicos que tendem a impactar o setor, pode-se citar a futura instalação do Centro de Pesquisas de Alimentos da Embrapa, no estado de Alagoas, com o propósito de melhorar os produtos, a agregação de valor e a questão da comercialização para o Programa de Aquisição de Alimentos (PAA), e o Programa Nacional de Alimentação Escolar (PNAE) (Embrapa, 2023). Que deve abrir um leque ainda maior para inserção da indústria alimentícia regional em programas governamentais, logo, alavancando sua presença, reconhecimento e expansão no mercado,

Com relação às condições climáticas que impactam no plantio, desenvolvimento e colheita das safras, o Acompanhamento da Safra Brasileira de Grãos | V.11 – Safra 2023/24, Nº1 – Primeiro Levantamento (CONAB, 2013) relata que a expectativa é de que haja aumento de 10% na safra 23/24 em comparação com a safra 22/23, vistos que os volumes de chuva registrados no Nordeste beneficiaram as lavouras de safra da região do Sertão (Sergipe, Alagoas e Bahia).

É de referir ainda o risco que pode envolver a manutenção do cenário atual, que tende a uma estabilidade tanto para o feijão quanto para o arroz. Essa perspectiva traz perigo

econômico, ao passo que oscilações na taxa de inflação podem afetar os custos de produção, transporte e armazenamento dos alimentos, e mercadológico, com a entrada de novos produtores ou a expansão de concorrentes já estabelecidos pode aumentar a competição no mercado, reduzindo as margens de lucro.

Acompanhar regularmente indicadores econômicos, climáticos e de mercado para identificar tendências e ajustar as estratégias conforme necessário é de suma importância para mitigar esse cenário de risco, assim como adotar tecnologias mais atuais possíveis na produção agrícola, armazenamento e logística para aumentar a eficiência e reduzir custos operacionais.

6 CONSIDERAÇÕES FINAIS

As inseguranças características da indústria de alimentos, bem como os objetivos e promoções da empresa em questão, tornam o processo de precisão incerto por natureza. Na seção anterior, observou-se o atendimento do objetivo geral do estudo: Analisar o desempenho de métodos quantitativos de previsão de demanda, baseada em séries temporais, em uma indústria alimentícia localizada no agreste alagoano. Bem como a resposta ao problema de pesquisa ao identificar-se o método que melhora a qualidade das previsões de demanda em uma indústria alimentícia, a fim de auxiliar na tomada de decisões estratégicas, reduzir custos operacionais e otimizar o uso de recursos. Visto que, a utilização de modelos que não minimizam os erros prejudica o funcionamento do negócio e, a realização de previsões equivocadas pode surtir um efeito negativo tanto estratégica quanto financeiramente.

Após a estimação dos modelos, foram analisados os critérios de informação, descobrindo os menores valores de erro. Em relação aos objetivos específicos, torna-se fundamental reforçar que para cada produto, houve um método mais adequado de acordo com o banco de dados disponibilizado. Desse modo, não predominando nenhum método sobre outros, cada produto teve sua característica especial, dado isso, com os testes de cada modelo, houve um exclusivo para cada produto.

Com o objetivo de comparar métodos estatísticos de previsão a partir de dados de produção de feijão e arroz em uma agroindústria do agreste alagoano no período de 2019 a 2022, ambos os modelos ETS e AUTO.ARIMA apresentaram resultados satisfatórios, com o ETS levemente superior nos dados do feijão e o AUTO.ARIMA superior nos dados no arroz.

O modelo que obteve maior grau de acuracidade, foi o ARIMA, com a melhor configuração das componentes (p, d, q) nos valores (0, 0, 5), para o feijão, o modelo ARIMA é caracterizado pelos parâmetros (p, d, q), que representam a ordem do componente autorregressivo, a ordem de diferenciação e a ordem do componente de média móvel, respectivamente. O modelo encontrado pelo método AUTO.ARIMA é simples, pois não inclui termos autorregressivos nem de diferenciação, apenas ajusta um valor médio constante à série temporal, com cinco termos de média móvel. Modelo ideal quando as séries temporais exibem dependência linear nos erros anteriores e não necessita diferenciação para neutralizar a variância.

A suavização exponencial simples com tendência linear e erros aditivos (ETS (M, N, N)) foi o modelo que obteve maior grau de acuracidade para as previsões do arroz, método que atribui pesos exponencialmente decrescentes aos pontos de dados históricos, com o parâmetro "M" referindo-se à linearidade da tendência, o que implica que o método assume que os erros ao longo do tempo têm uma distribuição constante e são independentes. Já a parte "N" do modelo indica que estão sendo assumidos erros aditivos, logo, os erros não estão relacionados à magnitude ou sazonalidade dos valores previstos, com o primeiro "N" indicando a ausência de tendência na série e o segundo "N" acusando não haver componente sazonal na série. A suposição de erros aditivos é frequentemente aplicada quando a variabilidade dos dados não está oscilando continuamente ao longo do tempo. Assim, sendo uma abordagem útil quando a série temporal não apresenta padrões claros de tendência ou sazonalidade e os erros podem ser considerados independentes e consistentes em magnitude.

O estudo destacou a importância da adaptabilidade dos modelos de previsão, respeitando as particularidades de cada item. Com destaque para a principal crítica ao uso do ARIMA, o processo de seleção de ordem (p, d, q), que geralmente é considerado subjetivo e complexo, o algoritmo AUTO.ARIMA do pacote Forecast do R mostrou-se de grande valia, pois define a escolha das ordens do modelo através dos testes de raiz unitária e critério de informação AIC. Além disso, a aplicação de ferramentas de previsão acessíveis contribui para um planejamento estratégico mais eficaz, especialmente em um setor sujeito a inseguranças e mudanças constantes. Sendo válido ainda pontuar que, a inserção de novos dados no banco, pode acarretar um melhor ajuste a outro método que não os aplicados neste momento da pesquisa. Dado isso, a realização de teste de aderência para novos modelos à medida que novos dados e eventos externos surgem é de suma importância para a manutenção de boas previsões.

Ainda durante a etapa de finalização do estudo, uma reunião presencial foi realizada com gestor para apresentação do modelo e análise de viabilidade de aplicação, visto que, este trabalho foi conduzido considerando o contexto real da empresa, seus valores e suas necessidades, surtindo resultados positivos para uma futura aplicação do modelo na organização com o intuito de alavancar resultados e reduzir perdas, mediante aplicação conjunta da experiência do gestor para aproveitar ao máximo o resultados para suas tomadas de decisão.

Ficam então, disponíveis para o público em geral os códigos desenvolvidos, podendo ser acessados via GitHub, uma plataforma de hospedagem de código fonte e colaboração para desenvolvimento de software baseado em controle de versão Git. O GitHub permite que os desenvolvedores colaborem em projetos, gerenciem o versionamento do código e realizem revisões de código de forma eficiente. O acesso aos códigos pode ser feito através do link disponível em “https://github.com/thomduart/TCC_Thom-s_Previs-o_De_Demanda.git”.

Destaca-se ainda o uso dos algoritmos automatizados de previsão, otimizando o tempo necessário para a geração de novas informações, com a capacidade de processar e analisar dados rapidamente, as previsões automatizadas permitem uma resposta ágil a mudanças repentinas no mercado ou na demanda. Além disso, algoritmos automatizados têm a capacidade de processar grandes volumes de dados de forma rápida e eficiente, permitindo análises mais abrangentes e precisas em comparação com métodos manuais

O algoritmo desenvolvido em R aplicou os modelos de previsão selecionados sobre as linhas de produto, gerando gráficos de identificação de outliers, gráficos de análise em série e em paralelo, gráficos de previsão e tabelas de análise de erros, que permitiram a comparação do desempenho dos modelos para cada produto. Em complementaridade, sugere-se neste trabalho um periódico monitoramento dos erros, com o objetivo de que se controle a adesão do modelo proposto no decorrer do tempo, ou ainda, a sua particular necessidade de ajuste.

6.1 Limitações da pesquisa

O presente estudo discorre sobre a aplicação das metodologias na solução de um problema específico, à vista disso, apresenta restrições. A primeira limitação diz respeito ao caráter dos trabalhos envolvendo o tema previsão, em outras palavras, não é desígnio deste trabalho determinar qual dos modelos de previsão apresentados deve ser utilizado incessantemente, e sim expor qual modelo melhor se adequa a realidade do estudo, com base nos dados que foram disponibilizados, em outros termos, mostrar o modelo mais acurado no que compete à capacidade de gerar previsões acuradas.

Os modelos de previsão utilizados neste trabalho compreendem os modelos de séries temporais ETS e AUTO.ARIMA, não sendo abordados, de forma detalhada, os modelos referentes às séries causais. O estudo de caso apresentado neste trabalho teve alicerce em alguns produtos de uma indústria do ramo alimentício, bem como, algumas de suas

especificidades. Desse modo, não é a intenção deste trabalho generalizar os resultados obtidos para outras indústrias do mesmo ramo.

É necessário enfatizar também que esse foi um estudo univariado. Se indicadores econômicos, políticos e sociais fossem abordados diretamente nos modelos de previsão, a acurácia seria maior, sobretudo para grandes sazonalidades. Outra limitação foi a impossibilidade de analisar os dados anteriores ao período de 2019, sendo importante ver o poder de previsão dos modelos com a inclusão de dados em um cenário mais extenso.

6.2 Propostas para trabalhos futuros

Este trabalho não pretende encerrar o tema relativo à previsão de demanda para os produtos estudados, neste contrato, ficam como sugestões para trabalhos futuros:

- Desenvolvimento de interfaces gráficas amigáveis (GUIs) para facilitar a interação dos usuários com o R.
- Alimentação constante do banco de dados. Os modelos de previsão trabalham melhor quando uma série de dados maior é utilizada, assim estudos futuros devem utilizar conjunto de dados maiores, tanto de treinamento quanto de teste.
- Exploração de algoritmos de machine learning e deep learning para previsão de demanda, análise de dados não estruturados, segmentação de mercado e tomada de decisões estratégicas.
- Aplicação de métodos qualitativos para identificar fatores causais por trás de padrões observados nos dados quantitativos, permitindo uma análise mais profunda das relações de causa e efeito.

REFERÊNCIAS

ALVES, C. DA C. **Application of statistical methods with exponential smoothing double and triple for demand forecasting in the inventory management.** 2019.

BABU, C. N.; REDDY, B. E. **Prediction of selected Indian stock using a partitioning-interpolation based ARIMA-GARCH model.** Applied Computing and Informatics, [s.l.], v. 11, n. 2, p. 130-143, Nov. 2017.

BALLOU, Ronald H. **Gerenciamento da cadeia de suprimentos: planejamento, organização e logística empresarial.** 4. ed. Porto Alegre: Bookman, 2001.

BOROOJENI, Kianoosh G. et al. **A novel multi-time-scale modeling for electric power demand forecasting: From short-term to medium-term horizon.** Electric Power Systems Research, v. 142, p. 58-73, 2017.

BOX, G.E.; JENKINS, G.M.; REINSEL, G.C.; LJUNG, G.M. **Time series analysis: forecasting and control.** John Wiley & Sons, 2015.

BRITO, B. B. DA C. **Utilização de métodos quantitativos na previsão de demandas de cargas marítimas para uma plataforma de petróleo na bacia de Campos.** Dissertação (Mestrado) - Universidade Federal Fluminense, Rio das Ostras, 2020.

BUNDCHEN, Cristiane; WERNER, Liane. **Comparação da acurácia de previsões de demanda turística em sedes olímpicas.** Revista Turismo em Análise, v. 27, n. 1, p. 85-107, 2016.

BUTCHER, B.; SMITH, B. J. **Feature Engineering and Selection: A Practical Approach for Predictive Models.** The American Statistician, v. 74, n. 3, p. 308–309, 2 jul. 2020.

CECATTO, C.; BELFIORE, P. **O uso de métodos de previsão de demanda nas indústrias alimentícias brasileiras.** Gestão & Produção, v. 22, n. 2, p. 404–418, jun. 2015.

CONAB - ACOMPANHAMENTO DA SAFRA BRASILEIRA OBSERVATÓRIO AGRÍCOLA. **Monitoramento agrícola grãos.** [v.7 - SAFRA 2019/20.]. Disponível em:

https://www.conab.gov.br/info-agro/safras/graos/boletim-da-safra-de-graos/item/download/45051_a45dd0e7e0fe867dbcdadcf3bba85139. Acesso em: 17 jan. 2024

CONAB - ACOMPANHAMENTO DA SAFRA BRASILEIRA OBSERVATÓRIO AGRÍCOLA. **Monitoramento agrícola grãos**. [v.10 - SAFRA 2022/23.]. Disponível em: https://www.conab.gov.br/info-agro/safras/graos/boletim-da-safra-de-graos/item/download/44552_ba45a0b27ca41b0fccb368a668e7b039. Acesso em: 17 jan. 2024

CONAB - ACOMPANHAMENTO DA SAFRA BRASILEIRA OBSERVATÓRIO AGRÍCOLA. **Monitoramento agrícola grãos**. [v.11 - SAFRA 2023/24.]. Disponível em: https://www.conab.gov.br/info-agro/safras/graos/boletim-da-safra-de-graos/item/download/49593_596c818070b5dc225a4d1750a9747c79. Acesso em: 17 jan. 2024

CONAB - **Histórico mensal feijão**. Disponível em: <https://www.conab.gov.br/info-agro/analises-do-mercado-agropecuário-e-extrativista/analises-do-mercado/historico-mensal-de-feijao?start=10>. Acesso em: 17 jan. 2024.

CONAB. **Acompanhamento de safra brasileira: Grãos**. Brasília, v. 8, Safra 2020/2021, n. 4, fev. 2021. Disponível em: <https://www.conab.gov.br/info-agro/safras/graos>. Acesso em: 19 jan. 2023.

CONTRERAS JUÁREZ, A.; ATZIRY ZUÑIGA, C.; MARTÍNEZ FLORES, J.L.; SÁNCHEZ PARTIDA, D. 2016. **Análisis de series de tiempo en el pronóstico de la demanda de almacenamiento de productos perecederos**. Estudios Gerenciales. 32(141):387-396. Disponível em: <http://dx.doi.org/10.1016/j.estger.2016.11.0028>. Acesso em: 12 fev. 2023.

CORDEIRO JÚNIOR, O. A. **Utilizando séries temporais na previsão da arrecadação do imposto de renda**. 2007. Monografia (Especialização em Orçamento Público) – Instituto Serzedello Corrêa, Centro de Formação, Treinamento e Aperfeiçoamento, Brasília, 2007.

CORRÊA, Henrique L.; CORRÊA, Carlos A. **Administração de Produção e de Operações. Manufatura e serviços: uma abordagem estratégica**. 4. ed. São Paulo: Atlas, 2017.

EMBRAPA. **O Agro Brasileiro alimenta 800 milhões de pessoas**, 2021. Disponível em: <https://www.embrapa.br/busca-de-noticias/-/noticia/59784047/o-agro-brasileiro-alimenta-800-milhoes-de-pessoas-diz-estudo-da-embrapa> - Portal Embrapa. Acesso em 06 fev. 2023.

EMBRAPA. **Embrapa Alimentos e Territórios lança futura sede e privilegia parcerias.** Disponível em:

<<https://www.embrapa.br/busca-de-noticias/-/noticia/84863776/embrapa-alimentos-e-territorios-lanca-futura-sede-e-privilegia-parcerias>>. Acesso em: 15 jan. 2024.

FAVA, Vera Lucia. Metodologia de Box-Jenkins para Modelos Univariados. **Manual de Econometria.** Vasconcelos, M.A.S. & Alves, D. Editora Atlas, São Paulo, 2000.

FILDES, Robert et al. **Effective forecasting and judgmental adjustments: an empirical evaluation and strategies for improvement in supply-chain planning.** International journal of forecasting, v. 25, n. 1, p. 3-23, 2009.

GIL, Antônio Carlos. **Como elaborar projetos de pesquisa.** 4. ed. São Paulo: Atlas, 2002.

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

HODGE, Victoria; AUSTIN, Jim. **A survey of outlier detection methodologies.** Artificial intelligence review, v. 22, p. 85-126, 2004.

HOFMANN, E. Book review. **Journal of Purchasing and Supply Management**, v. 19, n. 3, p. 212–213, set. 2013.

HYNDMAN, R. J.; KHANDAKAR, Y. **Automatic Time Series Forecasting: the Forecast Package for R.** Journal of Statistical Software, v. 27, n. 3, 2008.

HYNDMAN, R. J.; KOEHLER, A. B. **Another look at measures of forecast accuracy.** **International Journal of Forecasting**, v. 22, n. 4, p. 679–688, out. 2006.

HYNDMAN, R.J.; ATHANASOPOULOS, G. **Forecasting: principles and practice.** 2. ed. Melbourne, Austrália: OTexts, 2018. Disponível em: <https://otexts.com/fpp2/>. Acesso em: 23 jan. 2023.

HYNDMAN, R.J.; BILLAH, B. **A comparison of exponential smoothing methods for forecasting time series.** Journal of Forecasting, 2003. 22(5), 443-460.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. **Cidades e estados. AL. Arapiraca.** IBGE, 2021. Disponível em: <https://www.ibge.gov.br/cidades-e-estados/al/arapiraca.html>. Acesso em: 1 jan. 2023.

KATSIKOPOULOS, Konstantinos V.; DURBACH, Ian N.; STEWART, Theodor J. **When should we use simple decision models? A synthesis of various research strands**. *Omega*, v. 81, p. 17-25, 2018.

LAMBERT, D. M.; COOPER, M. C. **Issues in supply chain management**. *Industrial Marketing Management*, London, v. 29, n. 2, p. 65-83, 2000.

LAUGENI, F. P.; MARTINS, P. G. **Administração da Produção**. 3. ed. São Paulo: Saraiva, 2015.

MARCHEZAN, A.; SOUZA, A. M. **Previsão do preço dos principais grãos produzidos no Rio Grande do Sul**. *Ciência Rural*, [s.l.], v. 40, n. 11, p. 2368-2374, nov. 2010. Disponível em: <http://dx.doi.org/10.1590/s0103-84782010001100019>. Acesso em: 19 jan. 2023.

MARTINELLO, L. M. et al. **Estudo comparativo entre os modelos de previsão ARIMA e ETS para dados temporais da produção de leite no Brasil**. *Revista do Instituto de Laticínios Cândido Tostes*, v. 76, n. 1, p. 12–27, 31 dez. 2021.

MEIJDEN, V. D. L. H.; NUNEN, J. A. E. E. V.; RAMONDT, A. Forecasting: bridging the gap between sales and manufacturing. *International Journal of Production Economics*, 1994, 37(1), 101-114.

MÉLARD, G.; PASTEELS, J.-M. **Automatic ARIMA modeling including interventions, using time series expert software**. *International Journal of Forecasting*, v. 16, n. 4, p. 497–508, out. 2000.

MENDES, Hinckley Wendell do Nascimento. **A indústria de alimentos em Alagoas e a formação dos mercados de Maceió e Arapiraca**. 2020. 257 f. Dissertação (Mestrado em Geografia) – Instituto de Geografia, Desenvolvimento e Meio Ambiente, Programa de Pós-Graduação em Geografia, Universidade Federal de Alagoas, Maceió, 2020.

MONTGOMERY, D. C.; JENNINGS, C. L.; KULAHCI, M. **Introduction to Time Series Analysis and Forecasting**. [s.l.] John Wiley & Sons, 2015.

MOREIRA, Daniel Augusto. **Administração da Produção e Operações**. 2. ed. São Paulo: Cengage Learning, 2011.

MORETTIN, P. A.; TOLOI, C. M. C. **Análise de séries temporais**. São Paulo: Edgard Blucher, 2004.

ONU - Organização das Nações Unidas. **Relatório Índice de Desperdício de Alimentos 2021**. Disponível em: <https://brasil.un.org/pt-br/114718-onu-17-de-todos-os-alimentos-dispon%C3%ADveis-para-consumo-s%C3%A3o-desperdi%C3%A7ados>. Acesso em 06 fev. 2023.

PAI, P.-F.; LIN, C.-S. **A hybrid ARIMA and support vector machines model in stock price forecasting**. *Omega*, v. 33, n. 6, p. 497–505, dez. 2005.

PELEGRINI, F. R. Metodologia para Implementação de Sistemas de Previsão de Demanda. Dissertação (Mestrado) - Universidade Federal do Rio Grande do Sul, Porto Alegre, RS, 2000.

PETROPOULOS, Fotios et al. **Judgmental selection of forecasting models**. *Journal of Operations Management*, v. 60, p. 34-46, 2018.

RIBEMBOIM, Jacques Alberto. **Produtos agrícolas e mercados no agronegócio**. Agronegócio. São Paulo. Atlas, 2008.

ROESCH, Sílvia Maria Azevedo. **Projetos de estágio e de pesquisa em administração: guia para estágios, trabalhos de conclusão, dissertações e estudos de caso**. 3. ed. São Paulo: Atlas, 2017.

SANTOS, Pedro Vieira Souza. **Previsão da demanda como suporte à filosofia lean**. *Exacta*, v. 18, n. 1, p. 226-243, 2020.

SILVA, F. R. DA. **Previsão de demanda e planejamento comercial**. [s.l.] Editora Senac São Paulo, 2020.

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

YIN, R. K. **Estudo de caso: planejamento e métodos**. 2.ed. Porto Alegre: Bookman, 2001.

APÊNDICE A – Banco de dados do feijão

Apêndice A - Dados históricos das vendas de feijão							
MÊS	VENDAS (KG)	MÊS	VENDAS (KG)	MÊS	VENDAS (KG)	MÊS	VENDAS (KG)
/01/2019	406.140	/01/2020	392.450	/01/2021	339.910	/01/2022	405.370
/02/2019	241.050	/02/2020	326.100	/02/2021	360.910	/02/2022	416.920
/03/2019	310.110	/03/2020	573.590	/03/2021	422.530	/03/2022	435.060
/04/2019	424.710	/04/2020	531.230	/04/2021	434.000	/04/2022	443.030
/05/2019	409.236	/05/2020	575.980	/05/2021	498.940	/05/2022	418.230
/06/2019	425.790	/06/2020	412.440	/06/2021	475.080	/06/2022	412.780
/07/2019	498.720	/07/2020	345.110	/07/2021	477.310	/07/2022	458.160
/08/2019	461.370	/08/2020	547.810	/08/2021	453.490	/08/2022	477.350
/09/2019	428.940	/09/2020	393.310	/09/2021	347.500	/09/2022	449.790
/10/2019	451.370	/10/2020	386.260	/10/2021	347.350	/10/2022	447.650
/11/2019	432.140	/11/2020	345.320	/11/2021	418.120	/11/2022	461.750
/12/2019	483.450	/12/2020	456.150	/12/2021	526.978	/12/2022	419.650

APÊNDICE B – Banco de dados do arroz

Apêndice B - Dados históricos das vendas de arroz							
MÊS	VENDAS (KG)	MÊS	VENDAS (KG)	MÊS	VENDAS (KG)	MÊS	VENDAS (KG)
/01/2019	201.899	/01/2020	181.620	/01/2021	69.600	/01/2022	221.520
/02/2019	191.130	/02/2020	185.100	/02/2021	119.400	/02/2022	273.870
/03/2019	208.950	/03/2020	350.880	/03/2021	138.300	/03/2022	333.990
/04/2019	210.690	/04/2020	478.500	/04/2021	157.560	/04/2022	253.290
/05/2019	219.630	/05/2020	243.300	/05/2021	159.540	/05/2022	183.300
/06/2019	190.740	/06/2020	243.630	/06/2021	230.550	/06/2022	223.980
/07/2019	273.570	/07/2020	178.020	/07/2021	126.900	/07/2022	215.760
/08/2019	226.620	/08/2020	193.330	/08/2021	133.800	/08/2022	211.800
/09/2019	183.030	/09/2020	165.600	/09/2021	63.300	/09/2022	199.200
/10/2019	210.450	/10/2020	48.210	/10/2021	140.100	/10/2022	188.760
/11/2019	230.345	/11/2020	104.100	/11/2021	184.170	/11/2022	176.580
/12/2019	240.030	/12/2020	69.300	/12/2021	162.090	/12/2022	208.860