



UNIVERSIDADE FEDERAL DE PERNAMBUCO

DEPARTAMENTO DE ENGENHARIA DE PRODUÇÃO

CURSO DE GRADUAÇÃO EM ENGENHARIA DE PRODUÇÃO

**Análise de dados históricos e aplicação de modelos estatísticos
para previsão de demanda em uma empresa distribuidora de
alimentos.**

TRABALHO DE CONCLUSÃO DE CURSO DE GRADUAÇÃO

POR

Paulo Victor de Oliveira Gomes Menezes

Orientadora: Profa. Dra. Isis Didier Lins

RECIFE, abril/2023

PAULO VICTOR DE OLIVEIRA GOMES MENEZES

**Análise de dados históricos e aplicação de modelos estatísticos
para previsão de demanda em uma empresa distribuidora de
alimentos.**

Trabalho de Conclusão de Curso
apresentado ao Curso de Engenharia de
Produção da Universidade Federal de
Pernambuco, como requisito parcial para
obtenção do título de Bacharel.

Orientador (a): Profa. Dra. Isis Didier Lins

Recife
2023

Ficha de identificação da obra elaborada pelo autor,
através do programa de geração automática do SIB/UFPE

Oliveira Gomes Menezes, Paulo Victor de.

Análise de dados históricos e aplicação de modelos estatísticos para previsão
de demanda em uma empresa distribuidora de alimentos / Paulo Victor de
Oliveira Gomes Menezes. - Recife, 2023.
59 : il., tab.

Orientador(a): Isis Didier Lins

(Graduação) - Universidade Federal de Pernambuco, Centro de Tecnologia e
Geociências, , 2023.

Inclui referências, apêndices, anexos.

1. Previsão de Demanda. 2. Análise de Séries temporais. I. Didier Lins,
Isis. (Orientação). II. Título.

620 CDD (22.ed.)

PAULO VICTOR DE OLIVEIRA GOMES MENEZES

**Análise de dados históricos e aplicação de modelos estatísticos
para previsão de demanda em uma empresa distribuidora de
alimentos.**

Trabalho de Conclusão de Curso
apresentado ao Curso de Engenharia de
Produção da Universidade Federal de
Pernambuco, como requisito parcial para
obtenção do título de Bacharel.

Aprovado em: 27/04/2023

BANCA EXAMINADORA

Profa. Dra. Isis Didier Lins (Orientadora)
Universidade Federal de Pernambuco

Prof. Dr. João Mateus Marques de Santana (Examinador Interno)
Universidade Federal de Pernambuco

Prof. Dr. Alexandre Ramalho Alberti (Examinador Interno)
Universidade Federal de Pernambuco

AGRADECIMENTO

Agradeço primeiramente a Deus por me guiar e iluminar todos os dias nesta jornada.

Gostaria de agradecer a minha Família, em especial ao meu avô Iran, que me apoiou, guiou, motivou e sempre foi um grande exemplo que sigo todos os dias e que me trouxeram ensinamentos que ajudaram muito durante a graduação. Agradecer as minhas avós Zeza e Rosa que estavam ao meu lado sempre, agradecer também aos meus pais, que sempre estiveram ao meu lado, apoiando, dando suporte e celebrando todas as minhas conquistas. Por fim, gostaria de agradecer a minha noiva, Beatriz que esteve ao meu lado em todos os momentos, compartilhando das dificuldades e aprendizados, e me ajudando a seguir em frente na busca dos meus sonhos. Amo vocês.

Na minha vida acadêmica gostaria de agradecer também a UFPE, em especial ao DEP, por todos os ensinamentos, aulas, projetos e trabalhos que me guiaram na formação e me ajudaram a criar uma base sólida de conteúdos que uso diariamente na minha vida profissional, gostaria de agradecer em especial ao Movimento Empresa Júnior, a Arco Consultoria, FEJEPE e Brasil Junior que foram importantíssimas na construção de um aprendizado prático, unindo teoria e vivência empresarial. Sem dúvidas, a graduação e o MEJ transformaram minha vida.

Gostaria de agradecer aos diversos amigos e colegas que estiveram comigo durante a graduação, em especial a Giovanna Bim e Rafael Gomes companheiros da graduação e aos amigos João Vitor e Paulo Guedes, os quais dividi quase todos os dias durante os últimos anos. Vocês foram fundamentais para eu chegar até aqui, Obrigado!

Profissionalmente gostaria de agradecer a Exed Consulting, por ter sido minha primeira casa, onde tenho aprendido diariamente com profissionais e colegas da engenharia que se importam com meu aprendizado e desenvolvimento, tem sido um orgulho fazer parte desta equipe. Agradecer também a Exed por ter me permitido utilizar os softwares utilizados nesta pesquisa, bem como aos amigos, Bruno, Lucas e Vicente que permitiram usar sua empresa como objeto de estudo para esta pesquisa.

Por fim, gostaria de agradecer a Professora Isis por ter me acompanhado durante todo o projeto, me guiando e ajudando a construir um trabalho de excelência, muito obrigado professora, seu esforço, trabalho e inteligência foi um exemplo e um grande diferencial.

RESUMO

A previsão de demanda é um processo importante nas organizações, pois, a partir dela é possível planejar o futuro, baseando nesses números previsões orçamentárias, de vendas, compras e até mesmo necessidades de expansão das operações, como a instalação de uma nova fábrica, além disso é possível entender os gargalos do negócio, posicionamento de mercado e traçar ações estratégicas para corrigir possíveis erros e melhorar os resultados. Devido a isso, o presente estudo buscou estudar os resultados gerados pela adoção de um processo de previsão quantitativo de demanda com modelos estatísticos em uma empresa distribuidora de alimentos no Nordeste do Brasil. O estudo buscou entender inicialmente o referencial teórico que seria importante para o trabalho, desde os processos de planejamento integrado de vendas e operações, a teoria do planejamento de demanda e modelos estatísticos, e acompanhamento dos resultados, com o cálculo de erro. Também foi analisado o estado da arte das pesquisas já realizadas no tema, entendendo qual seria o posicionamento do trabalho e quais pontos seriam relevantes de diferenciação e contribuição. O estudo então dividiu-se em 4 etapas, todas executadas com auxílio do software SAP IBP. A primeira etapa foi a organização de uma base de dados consistente com informações acerca da empresa, produtos, clientes e o faturamento mês a mês, a segunda etapa do estudo buscou estudar a segmentação dos produtos, classificando-os a partir de uma segmentação ABC | XYZ, a terceira parte foi direcionada à análise das séries temporais, buscando classificá-las e posteriormente filtrar quais modelos estatísticos se adequavam às classificações de cada uma das séries estudadas, por fim, a última etapa tratou da aplicação e execução dos modelos, com análise de erro em cenários de execução diferentes. Os resultados obtidos com as pesquisas foram excelentes, com um estudo que gerou valor à empresa e permitiu uma análise completa, gerando uma previsão para todo o ano de 2023 que guiará os planejamentos e estratégias adotadas ao longo do ano.

Palavras-chave: Previsão de demanda, análise de séries temporais, métodos estatísticos para previsão de demanda.

ABSTRACT

Demand forecasting is an important process in organizations, as it allows for future planning based on predicted numbers, including a budget, sales, purchasing, and even operational expansion needs such as installing a new factory. It also helps to understand business bottlenecks, market positioning, and strategic actions to correct potential errors and improve results. Therefore, this study aimed to examine the results generated by adopting a quantitative demand forecasting process with statistical models in a food distributor company in Northeast Brazil. The study began by exploring the theoretical background, including integrated sales and operations planning processes, demand planning theory, statistical models, and result monitoring with error calculation. Additionally, the state of the art of previous research on the topic was analyzed to understand the research position and identify relevant differentiation and contribution points. The study was then divided into four stages, all of which were executed using SAP IBP software. The first stage involved organizing a consistent database with information about the company, products, customers, and monthly revenue. The second stage focused on product segmentation by classifying them according to an ABC | XYZ segmentation. The third stage was dedicated to analyzing time series data by classifying them and filtering the statistical models that best fit each series studied. Finally, the last stage involved applying and executing the models, and analyzing errors in different execution scenarios. The research generated excellent results, adding value to the company and providing a comprehensive analysis that generated a forecast for the entire year of 2023. This forecast will guide planning and strategies adopted throughout the year.

Keywords: Demand Planning, Time-series Analysis, Statistical Methods for demand forecasting.

SUMÁRIO

1. INTRODUÇÃO	11
1.1. Justificativa e relevância	12
1.2. Objetivos do trabalho	12
1.2.1. Objetivo geral	12
1.2.2. Objetivos específicos	13
1.3. Metodologia	13
1.4. Organização do trabalho	15
2. REFERENCIAL TEÓRICO E REVISÃO BIBLIOGRÁFICA	16
2.1. Fundamentação teórica	16
2.1.1. Planejamento de vendas e operações (<i>Sales & operations planning</i>)	16
2.1.2. Segmentação ABC XYZ	17
2.1.3. Previsão de demanda	17
2.1.3.1. Modelos estatísticos	18
2.1.3.2 Medida de de erro	22
2.2. Revisão da literatura	23
2.3. Síntese do estado da arte e posicionamento deste trabalho	28
3. ESTUDO DESENVOLVIDO	29
3.1. Contexto da aplicação	29
3.2. Contexto da aplicação	29
3.3. Estruturação dos dados	30
3.4. Segmentação ABC XYZ	32
3.5. Análise de séries temporais	34
3.6. Previsão de demanda	41
4. CONCLUSÕES	11

4.1 Conclusões	53
4.2 Limitações e sugestões para trabalhos futuros	54
5. REFERÊNCIAS BIBLIOGRÁFICAS	56

LISTA DE FIGURAS

Figura 1- Fluxograma do processo de previsão de demanda	14
Figura 2- Etapas do ciclo de <i>sales & operations planning</i>	17
Figura 3- Estrutura de dados de produtos	31
Figura 4- Estrutura de dados transacionais de faturamento	31
Figura 5- Matriz de correlação segmentação ABC XYZ	33
Figura 6- Padrões de séries temporais	34
Figura 7- Série temporal de faturamento da empresa por mês	36
Figura 8- Série temporal de faturamento de carne congelada por mês	37
Figura 9- Série temporal de faturamento de congelados por mês	37
Figura 10- Série temporal de faturamento de embutidos por mês	38
Figura 11- Série temporal de faturamento de frango por mês	38
Figura 12- Série temporal de faturamento de margarina e manteiga por mês	39
Figura 13- Série temporal de faturamento de queijos por mês	39

LISTA DE TABELAS

Tabela 1- Resultados da pesquisa de Veiga, Veiga & Duclós (2010)	25
Tabela 2- Resultados segmentação ABC XYZ	33
Tabela 3- Padrões das séries temporais	34
Tabela 4- Classificações das séries temporais	35
Tabela 5- Resultados do MAPE da previsão estatística para carne congelada	43
Tabela 6- Resultados do MAPE da previsão estatística para congelados	43
Tabela 7- Resultados do MAPE da previsão estatística para embutidos	44
Tabela 8- Resultados do MAPE da previsão estatística para frango	44
Tabela 9- Resultados do MAPE da previsão estatística para margarina e manteiga	44
Tabela 10- Resultados do MAPE da previsão estatística para queijos	45
Tabela 11- Resultados da previsão estatística para empresa no primeiro trimestre de 2023	47
Tabela 12- Resultados da previsão estatística para carne congelada no primeiro trimestre de 2023	48
Tabela 13- Resultados da previsão estatística para congelados no primeiro trimestre de 2023	48
Tabela 14- Resultados da previsão estatística para embutidos no primeiro trimestre de 2023	48
Tabela 15- Resultados da previsão estatística para frango no primeiro trimestre de 2023	49
Tabela 16- Resultados da previsão estatística para margarina e manteiga no primeiro trimestre de 2023	49
Tabela 17- Resultados da previsão estatística para queijos no primeiro trimestre de 2023	49
Tabela 18- Resultados da previsão estatística para empresa para o segundo, terceiro e quarto trimestres de 2023	52

LISTA DE GRÁFICOS

Gráfico 1- <i>Previsão de demanda e valores faturados para o primeiro trimestre de 2023</i>	47
Gráfico 2- <i>Previsão de demanda para o segundo, terceiro e quarto trimestre de 2023</i>	51

1. INTRODUÇÃO

A indústria alimentícia Brasileira é um dos setores produtivos que possuem maior impacto na economia. Segundo o levantamento da Associação Brasileira da Indústria de Alimentos (Abia), cerca de 10.6% do PIB foi gerado por esse setor no ano de 2021. Com base nesses dados, torna-se evidente a necessidade de o setor aplicar as melhores técnicas e práticas gerenciais para manter-se competitivo, principalmente frente às fortes disputas no mercado interno e posicionamento estratégico no mercado externo, representando cerca de 17,6% das exportações do País, segundo dados da Abia.

Diante desse cenário, tem-se visto uma movimentação das indústrias, empresas de consultoria e associações para alavancar a digitalização do setor, com a adoção de sistemas e práticas cada vez mais avançadas de suporte à gestão. Dessa forma, grandes empresas no Brasil já possuem sistemas de gestão integrada do negócio, gerindo de forma unificada toda sua cadeia produtiva, desde a gestão de fornecedores, clientes, logística e manufatura.

Entretanto, nesse mercado existem diversas pequenas e médias empresas, que atuam mais próximas aos clientes, realizando distribuição e vendas em varejo. Em sua maioria essas empresas não possuem um planejamento adequado e não usam práticas eficazes de gestão. Dessa forma, o presente trabalho busca analisar e entender os impactos e desafios da adoção de um processo de previsão de demanda em uma empresa de médio porte, que atua na distribuição de alimentos.

O estudo retrata o impacto e resultados gerados por previsões estatísticas para famílias de produtos distintos seguindo um processo de levantamento e tratamento de dados, análise de séries temporais e posterior previsão de demanda por meio de alguns modelos estatísticos. Esse estudo foi motivado pela oportunidade de ganhos na cadeia de suprimentos da empresa com aumento da satisfação dos clientes, diminuição dos níveis de estoque e posterior aumento de lucratividade.

1.1. Justificativa e relevância

O estudo em questão se justifica devido a necessidade de uma gestão acurada e eficaz no ramo da indústria de alimentos devido sua perecibilidade e alta facilidade de substituição entre produtos equivalentes de marcas variadas. A empresa em questão por sua vez, é uma distribuidora de alimentos que possui parte da sua cadeia de suprimentos refrigerada, ou seja, além da complexidade de gerir diversos fornecedores e clientes, perecibilidade dos produtos, alta competitividade, os alimentos como carne, queijos, margarinas necessitam de um armazenamento resfriado ou congelado que aumentam consideravelmente os custos com estoques e transporte.

Sendo assim, o planejamento de demanda que já é um processo importante para todo negócio, torna-se ainda mais importante e estratégico devido ao cenário observado no estudo. Soma-se a estes fatos uma dificuldade na gestão dos estoques por parte da empresa, o que leva à falta recorrente de produtos e em alguns casos produtos que precisam ser vendidos em promoções devido à validade ou custos altos de armazenamento.

Ainda, segundo Ceccato e Belfiore (2015), as empresas no contexto brasileiro possuem dificuldade na utilização de métodos quantitativos de previsão de demanda. Devido a isso, é importante explorar novas possibilidades, estudar novos casos, analisando os resultados, principalmente em mercados e contextos carentes de pesquisas como é o ramo de distribuição de alimentos com logística refrigerada, no Nordeste brasileiro, caso em que se insere o presente estudo.

1.2. Objetivos do trabalho

1.2.1. Objetivo geral

O objetivo deste trabalho é investigar e aplicar os métodos quantitativos de previsão de demanda para antever a demanda das famílias de produtos de Carne Congelada, Congelados, Embutidos, Frango, Queijos e Margarina e Manteiga da empresa distribuidora de alimentos objeto do estudo. Busca-se melhorar o processo de planejamento de demanda entendendo o comportamento de mercado de cada uma dessas famílias, gerando aprendizados e direcionamentos para as estratégias futuras.

1.2.2. Objetivos específicos

Os objetivos específicos deste trabalho são:

- Análise e entendimento do comportamento da demanda ao longo do tempo;
- Definição do modelo de extração, limpeza e organização de dados;
- Seleção de métodos adequados de previsão de demanda para cada família de produtos estudada;
- Previsão de demanda para o ano de 2023, da empresa estudada;
- Definição do processo de planejamento de demanda.

Comentado [PM1]: (ISIS)Pensar em mais objetivos específicos... Estatística descritiva dos dados, por exemplo...

Comentado [PM2R1]: Adicionado!!

1.3. Metodologia

Baseando-se em Gil (2008), esta pesquisa segue o método científico dedutivo, pois as teorias e métodos utilizados partem do geral para o específico. Os conhecimentos voltados para a previsão estatística e métodos utilizados estão bem definidos e busca-se avaliar os resultados obtidos com a aplicação desses algoritmos no contexto do estudo.

Quanto à finalidade esta pesquisa pode ser classificada como aplicada, pois segundo Gil (1991) teremos o estudo focado em uma empresa específica impactando diretamente na tomada de decisão dos gestores, solucionando problemas reais da empresa.

Quanto ao objetivo da pesquisa, busca-se estudar, descrever e estabelecer as relações entre as variáveis para o contexto estudado, sendo assim, como citado por Gil (1991) se caracteriza como uma pesquisa descritiva.

Quanto à natureza da pesquisa, tem-se uma pesquisa quantitativa pois será realizado o trabalho com dados transacionais da empresa, dados de faturamento, onde será medido a mensurabilidade dos resultados obtidos em cada período.

Quanto aos dados, baseando-se na convenção proposta por Yin (2001), temos um estudo de caso holístico, pois trata aprofundar o estudo em um caso específico de uma única empresa a fim de se obter uma análise ampla e detalhada sobre o objeto de estudo.

Quanto às técnicas de pesquisa serão empregadas a documentação direta, onde serão coletados dados diretamente no local onde ocorre os fenômenos, a pesquisa de campo será

realizada na própria empresa, com a coleta dos dados de faturamento da empresa nos últimos três anos, devido a disponibilidade de dados.

O problema abordado neste trabalho é a implementação de um processo de previsão de demanda por meio de métodos quantitativos em uma distribuidora de alimentos. A empresa em questão é familiar e não possui um processo bem definido de previsão, portanto não planeja de forma processual as atividades esperadas para a operação.

Desse modo o estudo inicia com a preparação e limpeza dos dados históricos de faturamento dos últimos anos, padronizando e unificando-os em uma mesma base. Posteriormente será realizada uma análise das séries temporais de cada família de produtos em estudo e rodadas de previsão estatísticas com o auxílio do software **SAP IBP** (*Integrated Business Planning*) que é utilizado para realizar planejamento empresarial de forma integrada, o objetivo do software é ajudar as organizações a integrar e otimizar os processos de planejamento, em áreas como cadeias de suprimentos, finanças, vendas e marketing. Neste estudo, utilizaremos o módulo *IBP for Demand*, que é um módulo focado na previsão de demanda.




Figura 1 - Fluxograma do processo de previsão de demanda

Fonte: Esta Pesquisa (2023)

Comentado [IL3]: Só três anos?

Comentado [PM4R3]: Sim, eles só tem dados dos últimos 36 meses.

Comentado [PM5R3]: Entretanto, em negócios o comum é que se utilize realmente 36 meses de faturamento. Pois, normalmente o patamar do negócio altera com o tempo, e com um treinamento com mais de 36 meses costuma gerar um overfitting da previsão, e espelhar comportamentos meio "errados", daí no geral, pelo menos no quesito de boas práticas da SAP (uma das maiores empresa de software para empresas) costuma-se quase sempre utilizar apenas os 36 meses de histórico. Daí, já conectando com o ponto que tem lá embaixo, o MAPE do período utilizado pra teste costuma ficar mais alto, mas quando a gente joga pros períodos do futuro esse MAPE fica bem menor, e o planejamento é refeito mês a mês, daí esse bloco de período de 36 vai andando com o tempo e as previsões vão ficando cada vez melhores...

Comentado [IL6R3]: Vc poderia incluir esses comentários no texto. Não todo ele. Condensa as ideias em poucas linhas.

Comentado [IL7]: Colocar uma referência, poderia dar um pouco mais de detalhes?

Comentado [PM8R7]: Feito

Comentado [IL9]: É planejamento da demanda mesmo? O que é ABC-XYZ?

Comentado [PM10R9]: Sim, coloquei como planejamento de demanda por quê a previsão estatística é apenas a etapa inicial desse processo. A partir disso, vêm processos como colaboração de marketing, vendas e por fim o consenso da demanda irrestrita. Daí, mescla as contribuições estatísticas com uma visão de negócio, e informações mais acuradas como novos contratos, campanhas de marketing, aumento de área de atendimento ou melhorias nas equipes de vendas. Como é um processo bem variável, a previsão estatística por si só não consegue prever essas ações.

Comentado [IL11R9]: Massa. Incluir a definição de planejamento de demanda. Onde seria o melhor local? Na primeira vez em que aparece e reforçado no referencial teórico? Incluir referências. Literatura sobre S&OP fala de "planejamento de demanda"?

1.4. Organização do trabalho

O presente trabalho encontra-se dividido em 4 capítulos, introdução, referencial teórico, estudo desenvolvido e conclusões. O primeiro capítulo trata da justificativa e relevância da pesquisa, seus objetivos e metodologia aplicada, bem como uma breve introdução ao trabalho.

Em seguida, no segundo capítulo, foi realizada a fundamentação teórica do trabalho, explicitando os principais conceitos que são relevantes ao tema em estudo, sendo eles o processo de planejamento de vendas e operações (*sales & operations planning*), planejamento e previsão de demanda, modelos quantitativos de previsão de demanda e medidas de erro. Ainda no segundo capítulo foi realizada uma revisão da literatura em que trabalhos recentes que discutem os temas de planejamento de demanda, previsão estatística, análise de séries temporais e gestão da cadeia de suprimentos.

No terceiro capítulo, foi introduzido o contexto e descrição da problemática em estudo e foi realizado o estudo de caso, aplicando os processos definidos de segmentação ABC | XYZ, análise de séries temporais e posterior previsão de demanda com a utilização de modelos quantitativos. Por fim, no quarto capítulo foram feitas as conclusões, limitações do trabalho e sugestões para trabalhos futuros.

2. REFERENCIAL TEÓRICO E REVISÃO BIBLIOGRÁFICA

Neste capítulo serão abordados os referenciais teóricos utilizados na pesquisa, a revisão que guiou a produção do trabalho, bem como a contribuição que da presente pesquisa. A base teórica é de extrema importância na construção de um estudo de caso e permite estruturar de forma organizada sua construção.

2.1. Fundamentação teórica

Esta seção é destinada à apresentação das referências nas quais o presente trabalho se baseia, servindo, assim, como uma breve introdução aos temas. O entendimento dos três temas apresentados a seguir é fundamental para a compreensão do presente trabalho.

2.1.1. Planejamento de vendas e operações (*Sales & Operations Planning*)

Sales & Operations Planning, segundo Chopra e Meindl (2003) tem como objetivo gerir a capacidade de fornecimento e atendimento ao cliente através dos estoques e a capacidade de gerir a demanda utilizando-se de mudanças de preço em curto prazo. Agregando a visão de Chopra e Meindl, Grant (2013), tem-se a ideia de que a gestão da cadeia de suprimentos permite o fornecimento de produtos da forma correta, entregando o pedido ao cliente no momento desejado. Fato este que evidencia a importância que a gestão da demanda tem para o alcance dos níveis desejados de satisfação do cliente.

Bertaglia (2009) explicita o conceito de que o planejamento de vendas e operações é o principal responsável por alinhar, dentro de suas limitações, a demanda do mercado e a disponibilidade de produtos em uma empresa. Mas, Corrêa et al (2013). traz a visão do que é o Sales & Operations Planning no contexto interno da organização, o primeiro ponto é que o S&OP é responsável por unir áreas que atuam de forma desconexa, como Marketing, Vendas, Produção e Finanças. Dessa forma, o S&OP é um processo que permite o negócio conversar em diversos níveis, horizontes de tempo e áreas funcionais. O segundo ponto trazido por Corrêa é que o S&OP atua como um elo importante entre as decisões realizadas em nível estratégico com as decisões tomadas em níveis gerenciais, sendo responsável por traduzir as diretrizes estratégicas do negócio para níveis mais operacionais.

Como mostrado na Figura 2, o processo de S&OP se dá em seis etapas. A primeira etapa é o levantamento de dados históricos transacionais como faturamento e dados mestres como Clientes, Produtos, Localidades (Centros de Distribuição ou Fábricas), entre outros que

Comentado [IL12]: Ano da referência.

Comentado [PM13R12]: Feito

Comentado [IL14]: Colocar a figura depois que ela é citada.

Comentado [PM15R14]: Feito

representam e estruturam o negócio. Essa etapa é bastante importante, pois esses dados servirão de base para as análises desenvolvidas nas etapas seguintes.

A segunda etapa, o planejamento de demanda onde serão executadas as previsões de demanda, sejam elas qualitativas como as colaborações de gestores, vendedores e especialistas ou quantitativas com o auxílio de algoritmos de previsão de demanda. Na terceira etapa, têm-se o planejamento de fornecimento, ou seja, com base na demanda planejada na etapa anterior é construído um plano de atendimento, seguindo as limitações e restrições da cadeia produtiva, buscando-se otimizar o uso dos recursos disponíveis.

A quarta etapa do processo de S&OP dá-se pela reunião preliminar de S&OP que é uma reunião para validação dos números, entretanto, ainda em nível de gerentes, planejadores e assistentes. Ao término desta etapa, têm-se a quinta etapa dada pela Reunião Executiva de S&OP, esta que tem o mesmo objetivo da etapa 4, entretanto os números serão revisados e consensados pela alta gestão da empresa, sendo validados e aprovados no mais alto nível de gestão. Por fim, a última etapa é a desagregação para o MPS (*Master Production Schedule*), como o S&OP é feito em níveis agregados, como por exemplo, no nível de família de produtos, na última etapa do processo é preciso desagregar o planejamento para o nível de produção para que seja traduzido em quantidades a serem fabricadas ou compradas.




Figura 2 - Etapas do Ciclo de Sales & Operations Planning.

Fonte: adaptado de Corrêa et al. (2013)

2.1.2. Segmentação ABC | XYZ

A segmentação ABC | XYZ é uma metodologia valiosa para as empresas que buscam otimizar a eficiência e a eficácia de seus sistemas de gerenciamentos de estoques (GOSSELIN, 1997). Ao combinar a análise de valor (ABC) com a análise de previsibilidade de demanda (XYZ), essa abordagem permite a identificação dos itens que requerem maior atenção e recursos para garantir um estoque equilibrado e adequado às necessidades do negócio

Comentado [IL16]: Planejada ou prevista?

Comentado [PM17R16]: Nessa explicação sobre o processo de S&OP seria realmente planejada, pois envolve outros processos além da previsão estatística.

(PRAKASH; MOHANTY, 2013; PASCOE, 1998). A aplicação da segmentação ABC | XYZ também auxilia no gerenciamento de riscos, fornecendo insights sobre a volatilidade da demanda e possibilitando uma resposta mais ágil às mudanças no mercado (WILSON; NORTON, 1989; RENDLEMAN, 1976). Além disso, a utilização dessa metodologia pode impulsionar a melhoria contínua e a inovação no processo de gerenciamento de estoques, contribuindo para a competitividade e o crescimento sustentável das empresas (HARRIS, 1990).

2.1.3. Previsão de Demanda

Segundo Martins e Laugeni (2005), a previsão é o processo de determinação de dados futuros com base em modelos estatísticos, matemáticos ou econométricos.

As previsões desempenham um papel importante nas organizações, pois permitem aos gestores da empresa prever o futuro e, assim, planejar adequadamente suas ações (TUBINO, 2008).

De acordo com Slack et al. (2007), sem previsão, as empresas não teriam acesso a informações vitais que poderiam ajudar a planejar adequadamente as contingências futuras, mas apenas reagir a elas.

A qualidade da previsão de demanda está relacionada à capacidade do método escolhido em estimar corretamente os valores futuros (MAKRIDAKIS et al., 1998). Para obter previsões consistentes, é necessário usar um processo formal de especificação (ELIKAI et al., 1999).

Métodos quantitativos são muitas vezes de natureza subjetiva e requer julgamento por parte de especialistas. As previsões qualitativas são frequentemente usadas em situações em que há pouco ou nenhum dado histórico para basear a previsão. Um exemplo seria a introdução de um novo produto, para o qual não há histórico relevante. (LEMONS, 2006).

O método qualitativo, segundo Goodwin (2002), resume formalmente os padrões nos dados e expressa uma relação estatística entre os valores anteriores e atuais da variável. Em seguida, o modelo é usado para projetar os padrões dos dados no futuro. Em outras palavras, o modelo de previsão é usado para extrapolar o comportamento passado e atual para o futuro.

As técnicas qualitativas são mais rápidas de preparar. Portanto, são utilizados quando não há tempo para coletar e analisar dados de demanda passada (TUBINO, 2000).

As séries temporais podem mostrar tendência, sazonalidade, periodicidade e ruído. Suas diferenças podem ser vistas a seguir (MAKRIDAKIS et al., 1998):

- Tendência: Possui um padrão de movimento direcional que pode ser ascendente ou descendente.
- Sazonalidade: tem um padrão de movimento que se repete em determinados intervalos. Esses eventos podem ser causados por: temperatura, chuva, mês do ano, feriados, etc.
- Periodicidade: apresenta movimento oscilante e sazonalidade, a diferença é que a periodicidade não apresenta uma periodicidade fixa.
- Ruído: é uma componente aleatória.

A razão pela qual a previsão é tão importante, segundo Borges e Mattos (2021), é que a previsão de eventos futuros é uma entrada crítica em muitos tipos de processos de planejamento e tomada de decisão com aplicação em áreas como as seguintes: Gestão de Operações, Marketing, Finanças e Gestão de Riscos, Economia, Controle de Processos Industriais.

2.1.3.1 Modelos Estatísticos

Existem vários tipos de modelos de previsão de uso geral, desde modelos simples como média simples e média móvel, até modelos de regressão, suavização exponencial, autorregressão e modelos que utilizam aprendizagem de máquina (ex. redes neurais). Os modelos de médias são bem simples e nem sempre permitem um cálculo acurado de previsão, a depender das características das séries temporais e das necessidades de previsão, entretanto por muitas vezes as médias servem como indicador e fonte de análise para o negócio utilizando as observações mais recentes para realizar os cálculos.

Os modelos de regressão fazem uso de relacionamentos entre a variável de interesse e uma ou mais variáveis preditoras relacionadas (BASSETO, 2015). Às vezes, os modelos de regressão são chamados de modelos de previsão causais, porque se supõe que as variáveis preditoras descrevam as forças que causam ou impulsionam os valores observados da variável de interesse. Um exemplo seria usar dados sobre compras de casas como uma variável preditora para prever as vendas de móveis. O método dos mínimos quadrados é a base formal da maioria dos modelos de regressão linear (VERÍSSIMO, 2012).

Sendo assim, temos dois importantes modelos de regressão que serão usados no estudo em questão, o modelo de regressão linear sazonal e o modelo de regressão linear múltipla. A regressão linear sazonal é um modelo utilizado quando os dados possuem padrões sazonais claros, bem definidos, como por exemplo padrões cíclicos mensais ou anuais. A regressão linear

Comentado [IL18]: Depende da série... Não é geral.

Comentado [PM19R18]: Reescrito!

sazonal, por sua vez, é uma extensão de uma regressão linear simples, onde a variável dependente é modelada como uma variável independente sazonal. A formulação da regressão linear sazonal é dada por:

$$Y(t) = a + b * t + c1 * Sen(2 * \pi * T) + c2 * Cos(2\pi / T) + \epsilon$$

Onde, Y(t) é o valor da variável dependente para o período t, a é a constante, b é o coeficiente de inclinação, c1 e c2 são os coeficientes das funções seno e cosseno, T é o período sazonal e ϵ é o erro aleatório.

Por sua vez, a regressão linear múltipla também é uma extensão de uma regressão linear simples, entretanto o método é utilizado para modelar uma relação entre uma variável dependente e duas ou mais variáveis independentes. Ou seja, a regressão linear múltipla é interessante e útil quando existem várias variáveis dependentes que podem afetar a variável independente, como por exemplo, preço, inflação e renda per capita podem afetar a quantidade de vendas de uma empresa. A fórmula utilizada para a regressão linear múltipla é:

$$y = \beta_0 + \beta_1 * x_1 + \beta_2 * x_2 + \dots + \beta_n * x_n + \epsilon$$

Onde, y é o valor da variável dependente, β_0 é a constante, $\beta_1, \beta_2 \dots \beta_n$ são os parâmetros do modelo (coeficientes das variáveis independentes), $x_1, x_2 \dots x_n$ são as variáveis independentes e ϵ o erro aleatório.

O modelo autorregressivo integrado de média móvel (ARIMA) é um procedimento popular em modelagem estatística para análise de séries temporais (LEE; KO, 2011). O modelo foi proposto por Box e Jenkins na década de 1970 e se originou de modelos autorregressivos (AR), modelos de média móvel (MA) e modelos AR e MA combinados (ARMA). Além dos modelos não estacionários (ARIMA), há também a versão que incorpora a sazonalidade (SARIMA).

A notação usada para o modelo é $ARIMA(p, d, q)$, em que p é a componente de autoregressão, d é a ordem do componente de diferenciação e q é a componente de média móvel. Os valores de p, d e q são determinados através de técnicas de análise de autocorrelação e autocorrelação parcial. Já o modelo SARIMA que é uma extensão do modelo ARIMA, onde leva-se em consideração a sazonalidade, o modelo recebe mais três componentes de sazonalidade, logo, $SARIMA(p, d, q)(P, D, Q)m$. Onde, p, d e q são as mesmas componentes

Comentado [IL20]: Esses modelos foram usados? Quais as variáveis preditoras do modelo de regressão múltipla?

Comentado [PM21R20]: Sim, foram utilizados.

Na regressão múltipla minha ideia inicial seria implementar com variáveis dependentes de preço, preço médio do mercado, eventos (variável categoria pra carnaval, natal, dia das mães...), entretanto não tinha suficiente e organizados, daí implementei o modelo utilizado os meses como variável categórica. Comentei sobre isso na página 41.

Inclusive citei como melhoria para trabalhos futuros, mas ficou bem simples. Vou dar uma melhorada e deixar um comentário pra senhora ver lá.

do modelo ARIMA e P é a ordem da componente sazonal de autoregressão, D é a componente sazonal de diferenciação, Q é a ordem da componente sazonal de média móvel e m é o número de períodos sazonais em uma temporada. Os valores de P, D e Q são determinados da mesma forma que o modelo de ARIMA, através de análises de autocorrelação e autocorrelação parcial.

Os modelos de suavização geralmente empregam uma função simples de observações anteriores para fornecer uma previsão da variável de interesse. Esses métodos podem ter uma base estatística formal, mas eles são frequentemente usados e justificados heurísticamente com base no fato de serem fáceis de usar e produzirem resultados satisfatórios (BORGES e MATTOS, 2021).

Os métodos de suavização exponencial consistem em decompor uma série em componentes (tendência e sazonalidade) e suavizar seus valores passados, ou seja, atribuir diferentes pesos cujos valores decaem exponencialmente para zero à medida que o número de observações aumenta, atribuindo assim maior peso para a observação mais recente (KOENIG, 2014).

A suavização exponencial simples não funciona bem quando há uma tendência nos dados (séries temporais) (NIST, 2003). As tendências envolvem níveis e crescimento, que não são captados adequadamente pela suavização exponencial simples. De forma simplificada, a suavização exponencial simples é um modelo de previsão baseado em médias móveis ponderadas, em que o peso dado a cada observação anterior diminui exponencialmente à medida em que essa observação se afasta no tempo. Ou seja, as observações mais recentes possuem maior peso na previsão, a equação da suavização exponencial simples é:

$$F_{t+1} = \alpha * A_t + (1 - \alpha) * F_t$$

Onde, F_{t+1} é a previsão do próximo período, A_t é o valor atual, F_t é a previsão que foi calculada para o período atual e α é o coeficiente de suavização. O coeficiente de suavização (α), é um valor pré-fixado que varia de 0 a 1, quando o valor é fixado mais próximo de 1, dá-se mais importância às observações mais recentes, enquanto mais próximo de 0 a curva torna-se mais suave e menos responsiva às mudanças recentes nos valores da série temporal.

A suavização exponencial dupla, é um avanço do modelo de suavização exponencial simples, pois leva em consideração a tendência da série temporal. Entretanto, assim como a

Comentado [IL22]: Reformular.

Comentado [PM23R22]: Feito.

Comentado [IL24R22]: Editei. Verificar se a ideia permanece coerente.

Comentado [PM25R22]: Obrigado

suavização exponencial simples, ela não é um modelo eficiente para prever mudanças abruptas ou lidar com padrões sazonais irregulares. A equação para a suavização exponencial dupla é:

$$\begin{aligned} Ft + 1 &= \alpha * At + (1 - \alpha) * (Ft + Tt) \\ Tt + 1 &= \beta * (Ft + 1 - Ft) + (1 - \beta) * Tt \end{aligned}$$

Onde, $Ft+1$ é a previsão para o período seguinte, At é o valor atual, Ft é a previsão para o período atual, Tt é a tendência para o período atual, α é o coeficiente de suavização e β é o coeficiente de suavização da tendência.

O modelo de suavização exponencial tripla, também conhecido como Holt-Winters, foi criado por Peter Winters, baseado na teoria de seu professor Charles Holt. O modelo de Holt-Winters é um modelo que considera tendências sazonais ou sazonalidade ao calcular valores futuros. Ou seja, em complemento à suavização exponencial simples e dupla, que não levam em consideração a sazonalidade, a suavização exponencial tripla, une as características da SES, que suaviza apenas os valores da série temporal, a SED que suaviza os valores da série e leva em consideração a tendência da série temporal e adiciona mais um parâmetro de suavização que é a sazonalidade.

O modelo Holt-Winters possui o componente de suavização (α), o componente de suavização de tendência (β) e o componente de suavização de sazonalidade (γ), sendo a equação geral do do modelo a seguinte:

$$F_{t+m} = (S_t + mb_t) * I_{t-L+m}$$

Onde,

$$\begin{aligned} S_t &= \alpha * (y_t / I_{t-L}) + (1 - \alpha) * (S_{t-1} + B_{t-1}) \\ B_t &= \beta (S_t - S_{t-1}) + (1 - \beta) * b_{t-1} \\ I_t &= \gamma * (y_t / S_t) + (1 - \gamma) * I_{t-L} \end{aligned}$$

Onde, S é a observação suavizada, B é o fator de tendência e I é o índice sazonal. Os outros fatores seguem a mesma estrutura das suavizações exponenciais simples e dupla.

2.1.3.2 Medidas de Erro

O MAPE (erro médio percentual absoluto), é uma métrica de avaliação de desempenho amplamente utilizada para avaliar a precisão dos modelos de previsão estatísticas em relação aos dados históricos, devido a sua facilidade de interpretação, pois retorna um valor médio em porcentagem.

O cálculo do MAPE também é simples, ou seja, ele mede de forma absoluta a diferença entre os valores reais e valores previstos, dividido pelos valores reais:

$$MAPE = 1/n \sum |(A_t - F_t)/A_t|$$

Onde,

A_t = É o valor observado

F_t = Valor previsto

n = Número total de pontos na série temporal

2.2. Revisão da literatura

Há diversos estudos que mostram a aplicabilidade da previsão de demanda no cenário empresarial brasileiro. A pesquisa de Cecatto & Belfiore (2015) tem como objetivo analisar quais as práticas de previsão de demanda utilizadas, sendo assim, foram selecionadas 450 empresas do setor dentre as quais 65 empresas participaram da pesquisa, abrangendo diversos setores do ramo de indústrias alimentícias Brasileiro.

Foi verificado na pesquisa que o atendimento de excelência ao cliente é comum a empresas que também desempenham com excelência o papel da previsão de demanda; isso está ligado intimamente à melhoria nos processos de gestão de estoque, compras, distribuição que são decorrentes de uma previsão de demanda acertada, entretanto, como citado por Jain & Malehorn (2006) nenhum modelo de previsão é mágica, e existem erros e fatores não previstos envolvidos no processo que precisam ser levados em consideração. O estudo de Cecatto & Belfiore (2015) então, levantou seis hipóteses para analisar o cenário das indústrias alimentícias brasileiras, sendo elas:

- Hipótese 1: As indústrias alimentícias pesquisadas utilizam um dos modelos de previsão listados no questionário (Simulação, Pesquisa de mercado, Delphi, Paineis de

Comentado [IL26]: Está boa, mas pode ficar melhor organizada. Vc pode pensar em uma revisão de literatura com um fluxo de ideias estruturado: primeiro mostrar trabalhos no contexto específico de alimentos (senti falta de trabalhos que tratem de produtos perecíveis, refrigerados). Depois em contextos correlatos. Depois fazer uma análise dos métodos (causais, series temporais, machine learning, com ou sem inclusão de análises qualitativas)... E todos eles reforçam os benefícios de uma previsão auxiliada por modelos/métodos.

Comentado [PM27R26]: Professoram poderia fazer isso após a defesa? Não consigo refazer e terminar a tempo de entregar amanhã. Nessa parte de revisão de literatura eu sou bem lento, e tenho um pouco de dificuldade, fico com medo começar a fazer e me atrapalhar pra entregar no prazo.

Comentado [IL28R26]: Ok. Dps da defesa.

Comentado [IL29]: Qual estudo? O de Cecatto ou o de Malehorn?

Comentado [PM30R29]: Resolvido.

especialistas, Análise histórica, Média móvel, Alisamento exponencial, ARIMA, Regressão, Econométrico, Redes Neurais).

- Hipótese 2: A maioria das empresas pesquisadas fornecedoras de produtos alimentícios não utiliza modelos sofisticados.
- Hipótese 3: O modelo de previsão mais utilizado pelas indústrias alimentícias pesquisadas é o alisamento exponencial.
- Hipótese 4: Não há consenso entre as indústrias de alimentos pesquisadas em relação à utilização de um único modelo de previsão de demanda.
- Hipótese 5: A precisão, facilidade no entendimento e uso e o custo são os principais fatores que influenciam a escolha do modelo de previsão nas indústrias alimentícias pesquisadas.
- Hipótese 6: A dificuldade no entendimento e uso, além do alto custo, são os principais fatores que influenciam a escolha do modelo pelas indústrias alimentícias pesquisadas.

Dessa forma, através dos estudos e análises dos dados com estatística descritiva e técnicas estatísticas multivariadas chegou-se às seguintes conclusões. A hipótese 1 de que as indústrias alimentícias pesquisadas utilizam um dos modelos de previsão listados no questionário é verdadeira, as empresas utilizam modelos de previsão de demanda, sendo a mais comum a análise histórica (35 empresas), Análise de Mercado (13 empresas) e o modelo de média móvel (13 empresas). Com esses dados, conclui-se também que a hipótese 2 de que a maioria das empresas pesquisadas fornecedoras de produtos alimentícios não utiliza modelos sofisticados também é verdadeira e, por consequência, rejeita-se a hipótese 3 de que o modelo de previsão mais utilizado pelas indústrias alimentícias pesquisadas é o alisamento exponencial e também a hipótese 4 de que não há consenso entre as indústrias de alimentos pesquisadas em relação à utilização de um único modelo de previsão de demanda, dado que em sua maioria as empresas não utilizam o alisamento exponencial e tampouco utilizam um único modelo para realizar as previsões. Para as hipóteses 5 e 6 conclui-se que a disponibilidade de software seguido da dificuldade no entendimento são as principais dificuldades e influenciadores para o uso e escolha dos modelos de previsão.

Dados os resultados vistos na pesquisa de Cecatto & Belfiore (2015), a previsão de demanda impacta diretamente nos resultados financeiros de uma empresa, sendo este o objeto de estudo da pesquisa de Veiga, Veiga e Duclós (2010) que propuseram uma investigação da

Comentado [IL31]: Hipótese de que há ou não há consenso?

Comentado [PM32R31]: Não há

Comentado [IL33]: Frase muito grande, difícil de acompanhar. Pode subdividir para a hipótese 5 e hipótese 6...

Comentado [PM34R33]: Resolvido

relação causal entre as acurácias da previsão de demanda (variável independente), a responsividade da demanda (variável dependente 1) e o desempenho financeiro (variável dependente 2). A empresa em estudo é do ramo de alimentos, possuindo grande relevância no cenário nacional figurando entre os cinco líderes do mercado no segmento em que atua.

A metodologia da pesquisa consiste em comparar os resultados obtidos por métodos estatísticos propostos em comparação aos resultados obtidos pelo método estatístico utilizado pela empresa, dessa forma, os produtos foram divididos em cinco grupos e os algoritmos estatísticos propostos utilizados foram Suavização Exponencial Simples, Holt, Winter (Holt-Winters) e ARIMA. Dessa forma os resultados obtidos estão explicitados na tabela abaixo, sendo responsividade da demanda a taxa de atendimento, ou seja, percentual em que o cliente procura o produto e o produto está disponível):

Grupo de Produtos	Modelo Escolhido	MAPE	Responsividade empresa	Responsividade estudo
Grupo A	ARIMA	3,71%	94,20%	99,70%
Grupo B	ARIMA	7,52%	91,90%	92,65%
Grupo C	Winter (Holt-Winters)	7,43%	93,31%	96,02%
Grupo D	Holt	6,44%	95,01%	97,09%
Grupo E	ARIMA	11,49%	93,40%	98,53%

Tabela 1 – Resultados da pesquisa de Veiga, Veiga & Duclós (2010).

Fonte: Adaptado de Veiga, Veiga & Duclós (2010)

Com a utilização dos algoritmos propostos pelo estudo a empresa em questão poderia ter um aumento anual de faturamento na casa dos 2 milhões e 700 mil reais, valor relevante e impactante que justifica a importância da aplicação de técnicas de previsão estatísticas e o desenvolvimento de mais pesquisas relacionadas ao tema para que o setor empresarial Brasileiro consiga ser mais competitivo e atenda melhor às demandas dos clientes.

Com intuito de entender a aplicabilidade e resultados obtidos a partir da implementação da previsão de demanda em casos específicos, traremos alguns estudos relevantes no tema, envolvendo as indústrias de materiais eletromecânicos, vestuário e agroindústria. O estudo de Zanella, Vieira & Barichello (2016) foi realizado na Cooperativa Central Oeste Catarinense que comercializa carnes suínas, aves, lácteos, massas, vegetais e suplementos para nutrição animal, sendo focado principalmente na produção de carne de aves e suínos. Foi constatado que a indústria utiliza métodos quantitativos para previsão de demanda, mas posteriormente o

Comentado [IL35]: Holt-Winters, não?

Comentado [PM36R35]: Sim, é que nesse caso na pesquisa chamaram de Winter (que é o nome original), mas é comumente chamado de holt winter porque é uma extensão do modelo holter.

Comentado [PM37R35]: Dai pra seguir o mesmo padrão da citação que estava na pesquisa, deixei como winter.

Comentado [IL38]: O que significa "responsividade"?

Comentado [PM39R38]: ok

Comentado [IL40]: Fazer tabela no próprio Word.

Comentado [PM41R40]: Ok

Comentado [IL42]: Não é necessariamente modelo mais sofisticado q vai dar a melhor resposta. A ideia é mais de modelos alternativos... regressão não é menos sofisticada que Holt ou Holt-Winters, são abordagens diferentes para tratar o problema.

Comentado [PM43R42]: Corrigido.

processo sofre colaborações e ajustes de forma qualitativa por especialistas fato este que corrobora com a afirmação de Armstrong (2001) que a junção de métodos qualitativos e quantitativos tendem a entregar melhores resultados.

No tocante à indústria do estudo de Zanella, Vieira & Barichello (2016) foi constatado que o método utilizado consistia na construção e avaliação de cenários de demanda, construídos através de média móvel simples e opinião de especialistas. O estudo em questão aplicou os modelos de suavização exponencial de Holt e de Holt-Winters e constatou que os resultados obtidos pelo processo utilizado pela indústria retornou valores mais acurados para o período em estudo, o que indica que não necessariamente a implementação de modelos mais sofisticados matemática e estatisticamente irá retornar resultados mais acurados, sendo necessário em todos os casos a ponderação e análise dos resultados obtidos por cada um dos algoritmos e modelos de previsão.

Em complementaridade às análises trazidas anteriormente temos o estudo de Zan & Sellitto (2007) que realizou o estudo sobre técnicas de previsão de demanda com dados de venda de materiais eletromecânicos. Foram analisados três produtos com comportamento de séries temporais variados, sendo eles: Tendencial, aleatório e sazonal. No tocante ao produto com comportamento tendencial, observou-se o método de regressão linear retornou resultados satisfatórios, o produto com comportamento aleatório por sua vez obteve resultados satisfatórios com os métodos de média móvel ponderada e suavização exponencial e, por fim, para o produto com comportamento sazonal sugeriu-se dar atenção apenas à previsão do mês com sazonalidade para o caso da empresa em estudo.

Dessa forma, os estudos analisados indicam que os métodos e algoritmos estatísticos utilizados para realizar uma previsão quantitativa de demanda diferem com relação à indústria analisada, mercado, fatores externos, mas em especial em relação ao comportamento da série temporal do produto.

Um outro estudo, realizado na Universidade da Região de Joinville, de Alves et al. (2019) corrobora mais uma vez ao entendimento de que para cada série temporal os algoritmos de previsão estatísticas reagem de forma diferente. No estudo, realizado para duas categorias de produtos produzidos por uma metalúrgica no estado de Santa Catarina notou-se as séries desses produtos possuíam tendências de crescimento positivo período a período, entretanto para a família de produtos de eletrodutos o método de suavização exponencial tripla de Holt-Winters

Comentado [IL44]: Vc faz isso? Na síntese do estado da arte e posicionamento, vc precisa justificar o porquê de fazer ou não fazer. Se não faz tb pode entrar como sugestão para trabalhos futuros.

Comentado [PM45R44]: Não fiz, mas vou fazer!!

Comentado [PM46R44]: Feito

troux resultados mais satisfatórios enquanto na família de produtos de buchas, os métodos de suavização exponencial dupla de Holt retornou resultados melhores.

Este fato, complementa a análise preliminar reforçando que inclusive dentro de uma mesma área de negócio, em uma mesma indústria, produtos com comportamentos similares podem e costumam reagir de forma diferente para cada algoritmo, reforçando e indicando a importância de testar os modelos para cada série temporal e analisar qual destes algoritmos gerará um melhor resultado dado o objetivo esperado.

Analizando, agora o contexto internacional temos alguns estudos relevantes, por exemplo, o de García & García (2021), que traz uma constatação teórica e aplicada que de modelos preditivos de Sales & Operations, como os modelos citados anteriormente de previsão de demanda são capazes de fazer com que o nível de serviço seja melhorado, devido ao melhor atendimento das demandas do cliente. Alinhado a isso, também foram obtidas conclusões empíricas no estudo, trazendo uma série de benefícios percebidos a partir da adoção de modelos de previsão sendo esses benefícios: menor tempo de entrega (Lead Time), diminuição dos níveis de estoque, maior estabilidade de planejamento, baixo investimento comparado com as economias operacionais e uma menor perda de produtos.

Na mesma linha de pesquisa, o estudo de Basson, Kilbourn & Walters (2019) traz esses resultados através de números. Nele foi observado que antes e depois da adoção de métodos de previsão de demanda os níveis de serviço ao cliente cresceram de 86% para 95%, um aumento considerável e que impacta positivamente a operação da empresa. Além disso também foi observada uma diminuição considerável nos custos referentes à logística: o percentual que antes da intervenção era de 7,8% de custos logísticos sobre as vendas diminuiu para 6%. Esses números indicam e estão em linha com todos os resultados vistos anteriormente e reforçam a importância e impacto que um bom planejamento de demanda por meio das tecnologias disponíveis e das melhores práticas pode causar em uma indústria.

Uma outra vertente da previsão de demanda, defende a mescla de modelos quantitativos e qualitativos. Esse fator foi estudado por Meneghini et al. (2018) e se chegou à conclusão de que os resultados entre previsões de demanda puramente quantitativas em comparação com previsões de demanda com auxílio de métodos qualitativos, as previsões com auxílio qualitativo de especialistas retornaram resultados significativamente melhores. Esse fato se dá porque fatores do ambiente e dados reais do dia a dia da operação do negócio influenciam diretamente nas demandas e os modelos matemáticos têm dificuldades em trazer esses fatores. Na pesquisa

em questão, o erro estatístico utilizando apenas modelos quantitativos foi de 38% enquanto os modelos propostos com auxílio de especialistas tiveram um erro máximo de 10%.

Por fim, fechando o ciclo de análise do estado da arte em planejamento de demanda, tem-se um direcionamento bastante claro de que algoritmos de aprendizagem de máquina estão começando a ser utilizados nas empresas do cenário internacional, inclusive, com softwares trazendo módulos prontos para a aplicação de soluções de *machine learning* (aprendizagem de máquina). Nesta vertente de pesquisa, há o estudo de Schmidt & Hoque (2022) que avaliou por meio de três bases de dados mais de 20 modelos de *machine learning*, para entender qual modelo se encaixava melhor nas necessidades reais, para a construção de um modelo de previsão de demanda de curto prazo. O modelo de RNN (Recurrent Neural Network) foi o que teve o melhor desempenho entre todos os modelos estudados na pesquisa. Por ora, o estudo indica que os algoritmos de *machine learning* têm trazido resultados satisfatórios e promissores para previsões de um dia, ou seja, prevendo a demanda do dia seguinte, entretanto estudos devem avançar e analisar as benesses da implementação de algoritmos de *machine learning* em previsões em horizontes de tempo maiores.

2.3. Síntese do estado da arte e posicionamento deste trabalho

Esta pesquisa possui potencial de inovação, pois, apesar de ser um tópico amplamente estudado, com diversos estudos publicados, sendo universalmente aceita a hipótese de que a previsão de demanda é um grande aliado dos negócios e que gera impactos financeiros relevantes além dos impactos no atendimento ao cliente, posicionamento de mercado, gestão de estoques e compras, entre outros diversos aspectos relacionados à operação. A previsão de demanda, ainda assim é aplicada de forma simplória, e como indicou Cecatto & Belfiore (2015) existe uma dificuldade de acesso a softwares e entendimento dos modelos estatísticos nas indústrias e empresas do cenário Brasileiro.

Este estudo busca implementar em uma empresa distribuidora de alimentos de pequeno porte, métodos quantitativos de previsão de demanda com auxílio do software SAP IBP, um dos principais softwares de planejamento integrado de negócios no mundo que possui um módulo específico para a realização da previsão de demanda. Esse módulo permite calcular os resultados da previsão estatística com base em diversos algoritmos e métodos, facilitando a análise dos resultados obtidos e o entendimento de qual modelo deve ser adotado para cada

Comentado [IL47]: Vc não usa ML. Acredito q a ideia é testar os modelos existentes no SAP IBP e ele não contém ML.

Comentado [PM48R47]: Isso, não utilizei ML. A ideia inicial era utilizar, inclusive no IBP tem o gradient boosting of decision trees, mas eu queria na ideia inicial rodar o amazon forecast tbm, só que não consegui em tempo. Retiro isso? Ou ponho como sugestão para trabalhos futuros?

Comentado [IL49R47]: Na revisão de literatura aqui, vc cita, mas deixa claro no posicionamento da pesquisa, que vai usar os modelos específicos do IBP, com a ideia de aproveitar o q já se tem disponível. Coloca tb como sugestões para trabalhos futuros.

família de produtos. O estudo permitirá, por consequência, entender o impacto que as novas tecnologias têm de agregar valor à operação de pequenas e médias empresas.

3. CONTEXTO E DESCRIÇÃO DO PROBLEMA

3.1. Contexto da aplicação

O objeto de estudo desta pesquisa será o estudo de caso da implementação de métodos quantitativos de previsão de demanda em uma empresa distribuidora de alimentos, localizada em Maceió-AL, que conta com dois centros de distribuição e atende a diversos clientes em todo o estado de Alagoas. Em razão da perecibilidade dos itens vendidos, a empresa tem tido dificuldade em manter os estoques em níveis adequados, o que ocasiona quebras frequentes de estoque e diminui o nível de serviço prestado ao cliente.

Sendo assim, a distribuidora de alimentos busca implementar um processo de previsão de demanda para guiar os rumos do negócio, o que se dará com o auxílio do Software SAP IBP, permitindo aos decisores analisarem os resultados obtidos com a implementação do processo e posterior aplicação prática no dia a dia da empresa.

3.2. Descrição do problema

O problema identificado na distribuidora de alimentos envolve a necessidade de estruturação do *Sales & Operations Planning*, principalmente na etapa de planejamento de demanda em específico. Devido ao fato de ser uma empresa familiar, administrada pelos donos e, com um crescimento considerável nos últimos anos, alguns processos não estão bem definidos e dependem de decisões qualitativas e de imediato dos gestores da empresa.

De forma mais detalhada atualmente a empresa trabalha com um cenário de compras sob demanda, sendo o setor de compras responsável por acompanhar os níveis de estoque dos produtos e entrar em negociação com os fornecedores. Com isso, as compras são realizadas tendo como base quase sempre apenas os preços e oportunidades de mercado, devido a isso, por muitas vezes a empresa perde vendas e receita devido à falta de produtos e algumas vezes, falta de uma família inteira de produtos.

Caso comum na empresa, são os que os clientes desejam comprar toda a gama de produtos que necessitam e a empresa não tem disponível em estoque, o que faz com que os clientes tenham que realizar compras em concorrentes, gerando margem para não fidelizá-lo e em alguns casos esses não voltam a comprar mais devido ao concorrente ter sempre todos os

Comentado [IL50]: Pode estar no próximo capítulo do estudo de caso. Capítulo de página única... melhor retirar.

Comentado [PM51R50]: Posso fazer essa alteração após a defesa? Ou aumentar o contexto e descrição? Por quê iria desconfigurar o documento todo, e eu não tenho tanta habilidade com o word... Iria perder muito tempo agora com isso, se puder seria melhor

Comentado [IL52R50]: O pessoal vai falar... Coloca mais descrição. Mas q seja pertinente. Tomar o cuidado para não ser repetitivo.

produtos disponíveis, e apesar de em alguns casos o preço não ser o melhor para o cliente final, ele opta por comprar tudo em um só lugar.

Com esses problemas são gerados custos exacerbados com estoque devido a compras erradas e por outro lado o nível de atendimento ao cliente impactado negativamente devido a falta de produtos. Isso têm sido cenário constante e que afeta o desempenho financeiro da empresa, que apesar de ter lucros consistentes, sofre os impactos negativos da falta de planejamento. Dessa forma, o estudo do planejamento de demanda com a implementação de métodos quantitativos em um horizonte de tempo adequado, será o objetivo do estudo para auxiliar os gestores da empresa a tomar decisões baseadas nos dados históricos e alcançar um nível satisfatório de balanceamento entre demanda e fornecimento.

3.3. Estruturação dos Dados

Na etapa inicial do estudo, foram necessárias diversas reuniões na empresa para extrair os dados de forma correta do sistema ERP utilizado, para que através dessas extrações fosse possível estruturar e configurar uma área de planejamento no SAP IBP.

Nessa fase do processo, foi realizado junto aos donos e analista responsável pelo sistema, entender os processos de faturamento, vendas, estruturação dos dados e extrair informações importantes sobre o negócio. Em parceria com a equipe da empresa, construiu-se toda a base de dados mestres e posteriormente as informações de dados transacionais de faturamento.

Os dados mestres foram organizados em:

- Cliente: para simplificar, foi criado apenas um cliente no sistema indicando que seriam as vendas em atacado.
- Localidade: para simplificar também foi criada apenas uma localidade de vendas, neste caso, indicou-se o centro de distribuição da empresa, que é o local de onde as vendas em atacado são enviadas aos clientes.
- Produto: no tocante aos produtos, foram cadastrados 2002 produtos. Na estrutura de dados mestre do produto, foram cadastrados os atributos:

- Código do Produto (*Product ID*)
- Descrição do Produto (*Product Desc*)
- Família do Produto (*Product Family*)
- Subfamília do Produto (*Product Subfamily*)
- Unidade de Medida base (*Base UOM*)
- Descrição da Unidade de Medida base (*Base UOM Desc.*)

Exemplo da estruturação dos dados de produto, na Figura 3 a seguir:

Product ID	Product Desc	Product Family	Product Subfamily	Base UOM Desc.	Base UOM
100	BUCHO BV CG - SAO FRANCISCO	CARNE CONGELADA	BOV VISCERAS	QUILO	KG
1000	BIFE ANCHO PORC ANGUS BV CG - LAS PIED	CARNE CONGELADA	BOV CORTE ESPECIAL	QUILO	KG
1002	SALAME ITALIANO KG - SADIA	EMBUTIDOS	MORTADELA/SALAME	QUILO	KG
1003	LING TOSC BLACK AP 600G CG-EXCELENCIA	EMBUTIDOS	LINGUIÇA NACIONAL	CAIXA	CX
1004	LOMBINHO DIAF BV CG KG - MARFRIG	CARNE CONGELADA	BOV CORTE NACIONAL	QUILO	KG
1005	PEITO C/OSSO IND CG KG - SOMAVE	FRANGO	PEITO DE FGO INDIV	CAIXA	CX
1007	CARNE MOIDA BV CG 500G - PURISSIMA	CARNE CONGELADA	BOV CORTE NACIONAL	CAIXA	CX

Figura 3 – Estrutura de dados de produtos

Fonte: Esta pesquisa (2023)

- Dados Transacionais de Faturamento
 - Os dados de faturamento foram extraídos do sistema a partir de um relatório, constando os valores e quantidades faturadas para cada produto. O período utilizado no estudo é dos anos de 2020, 2021 e 2022, bem como os meses de janeiro e fevereiro de 2023.

No SAP IBP, foram imputados os dados de faturamento relativos à quantidade faturada, em quilo, para cada produto e posteriormente foi realizada a agregação de valores para o nível de família de produtos.

A estrutura dos dados no sistema está estruturada como na Figura 4 a seguir:

Comentado [IL53]: Isso é uma figura? Incluir legenda

Comentado [PM54R53]: ok

Comentado [IL55]: Cada produto ou família de produto??

Comentado [PM56R55]: Isso, o relatório que eu utilizei com a empresa era por produto, daí precisei cadastrar o faturamento de todos os produtos, e depois fiz a agregação dos valores para as famílias.

Comentado [IL57R55]: Informar isso em algum ponto para ficar claro.

Comentado [IL58]: Incluir legenda da figura e citar...

Comentado [PM59R58]: ok

Product ID	Key Figure	20-Mar	20-Apr	20-May	20-Jun	20-Jul	20-Aug	20-Sep	20-Oct	20-Nov	20-Dec
261	Actuals Qty., VF	7260	7580	9386.33	13120	11700					20
1087	Actuals Qty., VF			6460		6620	8440				
1031	Actuals Qty., VF								6721	8021	3198
660	Actuals Qty., VF	19806	17136	18216	15684	11796	12096	9936	12540	12600	9912
349	Actuals Qty., VF	3061.902	4752.4	3730.53	2045.48	2364.22	68.25			881.834	3855.622
22	Actuals Qty., VF	6163.61	5972.5	4177.5	325	11220	6310	8882.5	5472.5	8222.5	10037.5

Figura 4 – Estrutura de dados transacionais

Fonte: Esta pesquisa (2023)

3.4. Segmentação ABC|XYZ

A segmentação ABC | XYZ é uma etapa muito importante do processo de planejamento de demanda que visa identificar os produtos com maior ou menor importância na empresa, neste estudo as segmentações foram realizadas através do sistema do SAP IBP. Seguindo os seguintes parâmetros:

Para a Segmentação ABC, classificou-se os produtos com base no histórico dos 12 últimos meses de faturamento, de acordo com a quantidade faturada. Então, foi feita uma análise mês a mês da série temporal de cada um dos produtos e classificou-se entre produtos A (itens de alto valor), B (itens de valor intermediário) e C (itens de baixo valor) através do princípio de Pareto. Com isso, foram classificados os produtos A como os produtos responsáveis por 70% do faturamento, os produtos B como responsáveis por 20% e os produtos C pelos 10% restantes.

Apesar de envolver um método simples, o resultado da segmentação ABC permitiu durante o processo de planejamento, aos decisores entender quais produtos eram mais importantes de serem analisados com precisão, os produtos que possuem uma classificação A tem uma importância maior no faturamento da empresa, consequentemente erros de previsão nesse produto podem afetar significativamente os resultados.

Já a segmentação XYZ, por sua vez, é baseada na demanda dos itens ao longo do tempo. Essa técnica consiste basicamente em classificar os produtos em três categorias, de acordo com o comportamento de demanda: X (itens com demanda constante ou estável), Y (itens com demanda variável) e Z (itens com demanda irregular ou intermitente). Ou seja, a categoria X representa os itens mais fáceis de serem previstos, pois tem certa previsibilidade dado o histórico de valores, enquanto os itens Z representam os itens que

Comentado [IL60]: Planejamento ou previsão?

Comentado [PM61R60]: Planejamento, pois ele serve mais de input para as colaborações do que para as previsões estatísticas em si. Pq, as colaborações de vendas são feitas no nível de produto e depois que a gente agrega pra nível de família e consensa

possuem menor previsibilidade, tendo assim uma necessidade de análises mais detalhadas e utilização de algoritmos e técnicas de previsão mais sofisticadas.

Tendo em vista essas informações, é possível construir uma matriz de prioridades relacionando os resultados da análise ABC e XYZ, como na Figura 5 a seguir:




Figura 5 – Matriz de correlação segmentação ABC | XYZ

Fonte: SAP IBP Business Applications Release 2302 (2023)

A análise dos dados nesse estudo foi feita no nível de produto, devido à base de dados extensa e uma grande quantidade de produtos que estão cadastrados, mas que não possuem vendas nos últimos 12 meses, os resultados indicam vários produtos sem classificação. Entretanto, entre os produtos que possuem histórico, os resultados são:

XYZ	ABC	Quantidade
X	Total	91
	A	18
	B	20
	C	53
Y	Total	157
	A	3
	B	15
	C	139
Z	Total	124
	B	7
	C	117

Tabela 2 – Resultados segmentação ABC | XYZ

Comentado [IL62]: Mede a criticidade do item? Na explicação parece ter a ver com o tipo de demanda...

Comentado [PM63R62]: Isso, devido a volatilidade do item que é medido pela XYZ, o item se torna mais crítico no planejamento. Daí itens classificados como Z, são difíceis de prever devido as características da série temporal. Por isso, criticidade.

Comentado [IL64]: Massa! Isso deveria estar na fundamentação teórica, devidamente referenciado. Aqui isso viraria um tópico, um parágrafo, só dizendo o q foi feito especificamente no estudo de caso.

Comentado [PM65R64]: Como comentado anteriormente, posso adicionar isso no referência teórico após a defesa?

Comentado [IL66R64]: Pode.

Comentado [IL67]: Incluir legenda e fonte. Citar no texto.

Comentado [PM68R67]: Feito.

Comentado [IL69]: Família de produto?

Comentado [PM70R69]: Essa etapa a gente fez no nível de produto mesmo, analisando cada um dos produtos.

Fonte: Esta Pesquisa (2023)

3.5. Análise de Séries Temporais

A análise de séries temporais é uma etapa importante no processo de previsão de demanda, pois, através desta análise é possível identificar padrões, como tendências e sazonalidades. O objetivo principal dessa análise no estudo é entender como a demanda de cada família de produtos da empresa distribuidora se comportou nos últimos 36 meses.

O SAP IBP, software utilizado para realizar a análise computacional das séries, nos permite classificar as séries temporais a partir do padrão, da tendência e sazonalidade. Dentro dessas três características gerais podemos entender como aquele dado temporal se comporta ao longo do tempo. Dessa forma, podemos classificar as séries temporais em quatro padrões distintos, sendo eles:

Padrão	Descrição
Contínuo (Continuous)	Série temporal com valores coletados de forma consistente ao longo do tempo, com frequência constante e sem interrupções.
Intermitente (Intermittent)	Série temporal com períodos de atividades seguidos por períodos de inatividade causando diversas lacunas nos dados.
Granular (Lumpy)	Série temporal caracterizada por períodos de atividade intensa seguidos por períodos de inatividade. Difere da intermitente por ter picos de atividades mais concentrados e acentuados com maior volume com menos previsibilidade sobre esses picos.
Irregular (Irregular)	Série temporal com característica de variações aleatórias e imprevisíveis dos dados, sem apresentar estrutura clara ou padrões consistentes.

Tabela 3 – Padrões de séries temporais.

Fonte: Esta Pesquisa (2023)

Comentado [IL71]: É o lumpy da figura?? É um subtipo de contínua? Pela figura, se for lumpy, não parece...

Comentado [PM72R71]: Reformulei a descrição para melhor entendimento.




Figura 6 –Padrões de séries temporais

Fonte: SAP IBP Business Applications Release 2302 (2023)

Após a identificação do padrão da série temporal, são adicionadas à análise duas classificações, sendo elas uma análise da tendência da série, podendo estar classificada como uma série com tendência de queda ou aumento, a exemplo de um produto recém-lançado que vai possuir uma tendência de crescimento de vendas. A segunda classificação é no tocante à sazonalidade da série, ou seja, essa série tem comportamento de alterações em determinados períodos, sendo assim, é possível classificá-la com padrão de sazonalidade aditivo ou multiplicativo. Uma sazonalidade multiplicativa seria de uma série temporal que possui um aumento de 2.5x a cada 3 meses ou aditiva se as vendas decrescem 100 unidades a cada mês.

Classificação	Descrição	Característica	Descrição
Tendência	Série temporal em que os valores mudam consistentemente em uma direção (Aumento ou queda).	Queda	Série temporal em que os valores decaem consistentemente.
		Aumento	Série temporal em que os valores crescem consistentemente.
Sazonalidade	Série temporal em que os valores crescem ou diminuem, repetidamente, em uma determinada frequência.	Aditivo	Variação sazonal em que o crescimento acontece por meio de uma subtração ou adição. Por exemplo, a cada X períodos é acrescido em média Y toneladas.
		Multiplicativo	Variação sazonal em que o crescimento acontece por meio de uma multiplicação. Por exemplo, as vendas crescem 2x a cada semestre.

Tabela 4 – Classificações de séries temporais.

Fonte: Adaptado de SAP Business Applications Release 2302 (2023)

Com base nisso, foram realizadas as análises de tendência, sazonalidade, intermitência e volatilidade. Os parâmetros utilizados no software foram:

1. **Nível de cálculo:** Família de produto
2. **Dados temporais:** Faturamento da empresa (Kg/Mês)
3. **Quantidade de períodos históricos:** 36 Meses
4. **Nível de significância para o teste de tendência:** 95%
 - a. O nível de significância, é o parâmetro em que definimos o nível de certeza em que a tendência é identificada. Neste caso, foi definido que o software identificaria a tendência com um nível de confiança de 95%.
5. **Nível de sensibilidade para sazonalidade:** 0.3
 - a. O nível de sensibilidade para sazonalidade, é o parâmetro utilizado para guiar a autocorrelação entre os valores da série. Ou seja, para esta definição,

Comentado [PM74R73]: Deixei o padrão separado, porque essa classificação complementa o padrão. Exemplo intermitente com sazonalidade aditiva. Daí se fosse tudo junto a tabela ia ficar muito grande

Comentado [IL73]: Legenda da tabela.... Citar no texto. P q não incluir aqui o padrão tb?

a sazonalidade é identificada quando o maior coeficiente de autocorrelação da série temporal está acima de 0.3.

Os dados de faturamento da empresa são os seguintes, explicitados na Figura 7 abaixo:




Figura 7 – Série temporal de faturamento da empresa por mês

Fonte: Esta pesquisa (2023)

Com base nesses valores, dividimos o faturamento para cada uma das famílias de produtos e foi realizada a classificação da série temporal. Com base no gráfico é possível validar e identificar visualmente a classificação da série.

Resultados Obtidos, por família de produtos:

- **Carne Congelada**

- Classificação: Série temporal Contínua com sazonalidade e tendência. A Sazonalidade é do tipo multiplicativa a cada 3 meses e a tendência é de crescimento.

Comentado [IL75]: Citar como figura no texto, incluir legenda, incluir nomes dos eixos...

Comentado [PM76R75]: feito




Figura 8 – Série temporal de faturamento de carne congelada por mês

Fonte: Esta pesquisa (2023)

- **Congelados**

- Classificação: Série temporal contínua com sazonalidade multiplicativa a cada 17 meses.




Figura 9 – Série temporal de faturamento de congelados por mês

Fonte: Esta pesquisa (2023)

Comentado [IL77]: Não inclui carne congelada?

Comentado [PM78R77]: Não, carne congelada é uma família e esses congelados são por exemplo, lasanha, pão de queijo...

- Embutidos

- Classificação: Série temporal contínua




Figura 10 – Série temporal de faturamento de embutidos por mês

Fonte: Esta pesquisa (2023)

- Frango

- Classificação: Série temporal contínua




Figura 11 – Série temporal de faturamento de frango por mês

Fonte: Esta pesquisa (2023)

Comentado [IL79]: Não tem tendencia nem sazonalidade?

Comentado [PM80R79]: Com os níveis de significância e sensibilidade que eu utilizei, não!!

Comentado [IL81R79]: Q níveis de significância e sensibilidade?

Comentado [PM82R79]: Na página 36 e 37 pus os parâmetros que utilizei para a análise de séries temporais

Comentado [IL83]: Mesmo q o comentário anterior.

Comentado [PM84R83]: Com os níveis de significância e sensibilidade que eu utilizei, não!!

- **Margarina e Manteiga**

- Classificação: Série temporal contínua com sazonalidade multiplicativa (4 meses) e tendência de queda.




Figura 12 – Série temporal de faturamento de margarina e manteiga por mês

Fonte: Esta pesquisa (2023)

- **Queijos**

- Classificação: Série temporal contínua.




Figura 13 – Série temporal de faturamento de queijo por mês

Fonte: Esta pesquisa (2023)

Com os dados das séries temporais para cada produto foi possível analisar e discutir com a equipe da empresa sobre cada um dos cenários, já nesta etapa os sócios e gerentes viram um valor enorme em ter um processo de planejamento de demanda bem definido. Com os gráficos plotados e a classificação das séries temporais em mãos, a equipe traçou e entendeu os motivos pelos quais a demanda estava se comportando dessa maneira, analisamos no nível do produto quais produtos tinha decrescido ou aumentado demanda, e surgiram alguns planos de ação interessantes a partir destas análises. Duas famílias de produto que apresentaram uma tendência de queda foram a família de margarina e manteiga e a família de produtos de queijos.

No tocante a família de produtos de queijos, entendeu-se que a demanda decresceu na distribuidora, inicialmente pelo fato do grupo ter aberto um atacarejo, então alguns dos clientes pequenos empresários passaram a comprar no atacarejo, devido a isso, uma parcela das vendas que eram realizadas através da distribuidora passou a ser realizada através da nova operação. Um segundo entendimento foi o fato de a distribuidoras ter adquirido um contrato de exclusividade com algumas marcas fornecedoras de queijo, leite e derivados (fato que também influenciou nas vendas de margarinas e manteigas).

Discutiu-se bastante na reunião sobre esse contrato de exclusividade, no entanto a decisão foi tomada de forma estratégica e apesar de perder uma fatia de mercado no primeiro momento, a operação tem uma margem interessante para o negócio e permite um posicionamento estratégico de mercado para a empresa. Entretanto, a companhia tomou alguns direcionamentos apenas com base nessa análise inicial das séries, e inicialmente o setor comercial e marketing recebeu uma atividade conjunta de planejar ações de venda específicas na base de clientes que são compradores usuais de queijo, à exemplo de pizzarias, restaurantes e mercados.

Por sua vez, na família de margarinas e manteigas percebeu-se a questão tanto da marca que a exclusividade engloba as margarinas e manteigas, mas percebeu-se que uma nova entrante no mercado, que fabrica a linha de manteiga e margarina em Alagoas, próximo a Maceió, local onde a distribuidora atua está ganhando uma fatia de mercado grande, e uma concorrente possui o contrato de exclusividade de distribuição dessa marca na capital. Esse fato foi validado tanto por contato com os clientes, que alegaram que a qualidade do produto era satisfatória e o custo menor, quanto pela análise das vendas no atacarejo, onde as vendas dos produtos dessa marca estavam crescendo mês a mês, com isso, alguns direcionamentos surgiram mais

estrategicamente, onde o dono traçou um plano de ação de visita a fábrica e tentativa de negociação de contrato para atuar no interior ou na região metropolitana, entretanto, uma primeira ação já havia sido tomada no mês de junho de 2022, na negociação dos preços de compra e margem, o que refletiu num aumento considerável nas vendas nos meses seguintes, entretanto, por ser uma linha de produtos estratégica pra empresa, a análise inicial dos dados foi muito interessante pois trouxe discussões e ideias interessantes de forma integrada entre todos os setores.

Nas outras famílias de produtos, por decisões estratégicas foi solicitado que não estivessem todas as decisões e planos de ações traçados, entretanto, de forma geral, foram traçados planos de ações em todos os níveis para que as outras famílias de produtos passassem a ter uma tendência de crescimento mais acentuada, então a partir da análise dos dados pensou-se em algumas estratégias para os setores de recursos humanos, logística, compras, vendas e marketing para que busca-se alavancar os patamares de vendas.

Ao final do trabalho, serão analisados os resultados dos meses seguintes e se as estratégias traçadas a partir das análises obtiveram um resultado positivo.

3.6. Previsão de Demanda

Para a previsão estatística seguimos utilizando o SAP IBP como software de planejamento, nesta etapa fizemos proveito da capacidade computacional do software para realizar rodadas de previsão com 8 algoritmos estatísticos distintos para previsão das séries temporais definindo qual algoritmo rodar para cada série com base nos resultados obtidos na etapa anterior de análise da série temporal, o intuito desta etapa é entender, para uma base simples de dados, em um nível agregado de planejamento, num contexto de uma empresa de médio porte a diferença entre resultados ao executar algoritmos estatísticos avançados e algoritmos mais simples, à exemplo de uma média móvel simples.

Nesta linha, o foco central foi estudar a capacidade dos modelos em gerar valores assertivos e encontrar para cada família de produto qual modelo se adequou melhor, tendo como indicador principal o MAPE (Erro Percentual Absoluto Médio). Essa análise, de antemão gerou um impacto bastante positivo na empresa estudada, pois no início do estudo, acreditava-se ser complexo demais a utilização de métodos estatísticos para facilitar e guiar o processo de planejamento de demanda, à exemplo da colaboração do time de vendas, mas durante a

execução do estudo ficou claro para toda a equipe que processos simples, desde que bem estruturados e guiados da forma correta podem gerar percepções e conhecimento de grande valia para o negócio.

Dessa forma, foram utilizados os algoritmos:

- **Suavização Exponencial Simples**
- **Suavização Exponencial Dupla**
- **Suavização Exponencial Tripla**
- **Auto – ARIMA/SARIMA**
 - Caso a série temporal apresente sazonalidade, escolhe-se automaticamente o SARIMA, caso não possua, escolhe-se o ARIMA.
- **Média Simples**
- **Média Móvel simples**
- **Regressão Linear Sazonal**
- **Regressão Linear Múltipla**
 - À nível de simplificação e falta de dados, a regressão linear sazonal utilizou-se de variáveis dependentes fictícias para cada um dos meses.

À nível de experimentação foram realizadas 2 rodadas de testes dos algoritmos, utilizando cenários de previsão diferentes. Realizamos o primeiro cenário, utilizando 36 meses de histórico de vendas e o segundo cenário utilizando 24 meses de histórico de vendas.

A primeira etapa do processo de previsão de demanda, foi selecionar dentre os métodos previamente escolhidos e citados anteriormente quais se encaixam para classificação da série temporal de cada família de produtos em estudo. Esta etapa é bastante importante pois define os modelos baseados na classificação da série e gera valores mais acurados de previsão. Entretanto, com o intuito de gerar aprendizado e comparar resultados foram

executados os algoritmos sem utilizar as informações de propriedades das séries temporais e outras rodadas utilizando essas informações, e os valores retornados de MAPE foram consideravelmente menores nos testes em que foram utilizadas as classificações das séries como entrada para os modelos.

Os resultados de MAPE obtidos para cada uma das famílias estudadas nos dois cenários foi calculado inicialmente com base em uma previsão de demanda para o passado, com o cálculo do erro sendo realizado comparando o valor previsto pelo algoritmo e o valor que foi realizado. Nas tabelas a seguir estão os valores de MAPE obtidos para cada família de produto dentre os algoritmos pré-selecionados com base nas propriedades das séries temporais:

- **Carne Congelada**

Comparação MAPE dos cenários Carne Congelada	Cenário 1	Cenário 2
Suavização Exponencial Tripla	26.41%	23.22%
Regressão Linear Múltipla	19.91%	17.53%

Tabela 5 – Resultados do MAPE da previsão estatística para carne congelada.

Fonte: Esta Pesquisa (2023)

- **Congelados**

Comparação MAPE dos cenários Congelados	Cenário 1	Cenário 2
Suavização Exponencial Tripla	44.53%	45.70%
Regressão Linear Múltipla	33.70%	23.26%

Tabela 6 – Resultados do MAPE da previsão estatística para congelados.

Fonte: Esta Pesquisa (2023)

Comentado [IL85]: Q valores são esses nos quadros? Os resultados estão c o MAPE muito elevado!!!!

Comentado [PM86R85]: Sim!! Como esse MAPE ai é dos 36 meses, tem casos em que as vendas mudaram bruscamente e daí o erro fica alto e termina aumentando a média.

- **Embutidos**

Comparação MAPE dos cenários Embutidos	Cenário 1	Cenário 2
Suavização Exponencial Simples	31.87%	31.76%
Auto – ARIMA/SARIMA	42.92%	39.80%
Média Simples	67.71%	51.73%
Média Móvel Simples (3 meses)	34.33%	35.56%
Regressão Linear Sazonal	36.25%	33.08%
Regressão Linear Múltipla	20.62%	15.08%

Tabela 7 – Resultados do MAPE da previsão estatística para embutidos.

Fonte: Esta Pesquisa (2023)

- **Frango**

Comparação MAPE dos cenários Frango	Cenário 1	Cenário 2
Suavização Exponencial Simples	35.39%	41.70%
Auto – ARIMA/SARIMA	31.93%	36.66%
Média Simples	60.70%	40.55%
Média Móvel Simples (3 meses)	35.49%	45.72%
Regressão Linear Sazonal	45.40%	40.68%
Regressão Linear Múltipla	25.32%	25.10%

Tabela 8 – Resultados do MAPE da previsão estatística para frango.

Fonte: Esta Pesquisa (2023)

- **Margarina e Manteiga**

Comparação MAPE dos cenários Margarina e Manteiga	Cenário 1	Cenário 2
Suavização Exponencial Tripla	220.35%	219.55%
Regressão Linear Múltipla	223.95%	126.22%

Tabela 9 – Resultados do MAPE da previsão estatística para margarina e manteiga.

Fonte: Esta Pesquisa (2023)

- Queijos

Comparação MAPE dos cenários Queijos	Cenário 1	Cenário 2
Suavização Exponencial Simples	44.72%	55.43%
Auto - ARIMA/SARIMA	44.14%	49.08%
Média Simples	46.00%	51.47%
Média Móvel Simples (3 meses)	44.06%	53.90%
Regressão Linear Sazonal	44.82%	49.46%
Regressão Linear Múltipla	35.85%	39.33%

Tabela 10 – Resultados do MAPE da previsão estatística para queijos.

Fonte: Esta Pesquisa (2023)

Ao realizar as rodadas de testes com os dois cenários acima, os algoritmos foram escolhidos da seguinte forma:

- Suavização Exponencial Tripla: 1
- Regressão Linear Múltipla: 11

Analisando os resultados com a gestão da empresa, percebemos que o MAPE estava relativamente alto em todas as famílias de produtos e buscou-se analisar os motivos pelos quais os modelos estavam retornando valores tão altos de erro. Como esses primeiros resultados das previsões foram feitas para o passado, e realizada a comparação entre os valores realizados de vendas e os valores previstos foi realizada uma reunião com os sócios da empresa e analisou-se para cada família de produtos em quais meses do passado o algoritmo retornou valores muito altos para entender os motivos pelos quais o MAPE estava tão alto.

Com essa análise foi possível chegar à conclusão que em meses específicos o algoritmo realizou previsões com erros muito altos e o motivo de forma unânime foi de que o algoritmo não tinha informações acerca do negócio, sendo os exemplos mais comuns de fatos que ocorreram no passado e que geraram essas distorções sendo:

- Campanhas de Marketing
- Problemas com fornecimento

- Aumento da força de vendas (Melhorias nos canais de vendas, adoção de uma nova cidade de atendimento ou contratos de vendas com empresas)

Com base nestes resultados foram realizadas as análises para cada uma das famílias de produtos, definindo qual melhor algoritmo a ser utilizado para a série temporal em cada um dos cenários. Definido o algoritmo para cada série temporal, os valores da previsão estatística foram então gerados em janeiro de 2023, ou seja, utilizando os dados de faturamento dos anos de 2020, 2021 e 2022 para realizar os cálculos para os 12 meses do ano de 2023.

Após a realização das previsões estatísticas citadas, decidiu-se incluir um novo cenário de previsão para o primeiro trimestre de 2023, esse cenário três foi construído através de uma previsão qualitativa em uma reunião presencial com os sócios da empresa e gerentes de vendas, ou seja, a previsão foi realizada com base em um modelo qualitativo baseado na opinião da força de vendas. A reunião consistiu em analisar inicialmente os valores previstos pela previsão estatística dos cenários um e dois, e com base nesses valores e entendimento de mercado, conhecimento da força de vendas, capacidades da cadeia de suprimentos os sócios e gerentes de vendas definiram valores previstos de vendas para cada família de produtos.

Com a construção desse novo cenário de previsão foi definido o acompanhamento dos resultados mês a mês nos três primeiros meses de 2023 com o intuito de entender qual cenário geraria uma melhor previsão, com base nisso o primeiro trimestre do ano de 2023 foi acompanhado pela pesquisa e com os dados estão disponibilizados foi comparado os valores gerados pelos três cenários e os valores realizados a fim de analisar os valores de MAPE obtidos.

Os valores previstos e respectivos erros de forma agregada para a empresa como um todo para cada um dos cenários foi, como explicitado no Gráfico 1 e Tabela 11 abaixo:




Gráfico 1 – Previsão de demanda e valores faturados para o trimestre de 2023.

Fonte: Esta Pesquisa (2023)

Dados	Janeiro	Fevereiro	Março	MAPE
Faturamento Total (Todas as famílias)	276.743	271.551	275.871	
Previsão Cenário 1	253.460	253.551	256.574	7,3%
Erro Absoluto	8,4%	6,6%	7,0%	
Previsão Cenário 2	263.178	260.059	271.085	3,6%
Erro Absoluto	4,9%	4,2%	1,7%	
Previsão Cenário 3	270.550	269.500	275.500	1,0%
Erro Absoluto	2,2%	0,8%	0,1%	

Tabela 11 – Resultados da previsão estatística para empresa no primeiro trimestre de 2023.

Fonte: Esta Pesquisa (2023)

Os resultados obtidos em nível agregado foram bastante satisfatórios, entretanto, uma análise mais detalhada de cada uma das famílias foi realizada para entender o nível de erro em cada uma das famílias e como que os modelos e cenários performaram em um nível mais desagregado e os aprendizados gerados.

- **Carne Congelada**

Carne Congelada	Janeiro	Fevereiro	Março	MAPE
Faturamento Total	67.503	66.385	80.278	
Previsão Cenário 1 (Regressão Linear Múltipla)	77.486	73.134	74.244	10,8%
Erro Absoluto	14,8%	10,2%	7,5%	
Previsão Cenário 2 (Regressão Linear Múltipla)	79.126	68.749	77.915	7,9%
Erro Absoluto	17,2%	3,6%	2,9%	
Previsão Cenário 3	70.000	68.500	78.000	3,2%
Erro Absoluto	3,7%	3,2%	2,8%	

Tabela 12 – Resultados da previsão estatística para carne congelada no primeiro trimestre de 2023.

Fonte: Esta Pesquisa (2023)

- **Congelados**

Congelados	Janeiro	Fevereiro	Março	MAPE
Faturamento Total	13.964	13.874	7.324	
Previsão Cenário 1 (Regressão Linear Múltipla)	14.585	15.518	11.904	26,3%
Erro Absoluto	4,4%	11,8%	62,5%	
Previsão Cenário 2 (Regressão Linear Múltipla)	15.003	17.675	9.829	23,0%
Erro Absoluto	7,4%	27,4%	34,2%	
Previsão Cenário 3	14.500	14.500	9.000	10,4%
Erro Absoluto	3,8%	4,5%	22,9%	

Tabela 13 – Resultados da previsão estatística para congelados no primeiro trimestre de 2023.

Fonte: Esta Pesquisa (2023)

- **Embutidos**

Embutidos	Janeiro	Fevereiro	Março	MAPE
Faturamento Total	31.143	29.358	52.700	
Previsão Cenário 1 (Regressão Linear Múltipla)	33.430	39.352	47.540	17,1%
Erro Absoluto	7,3%	34,0%	9,8%	
Previsão Cenário 2 (Regressão Linear Múltipla)	33.500	37.019	47.902	14,3%
Erro Absoluto	7,6%	26,1%	9,1%	
Previsão Cenário 3	33.000	33.000	50.000	7,8%
Erro Absoluto	6,0%	12,4%	5,1%	

Tabela 14 – Resultados da previsão estatística para embutidos no primeiro trimestre de 2023.

Fonte: Esta Pesquisa (2023)

- **Frango**

Frango	Janeiro	Fevereiro	Março	MAPE
Faturamento Total - Frango	155.880	159.453	126.940	
Previsão Cenário 1 (Regressão Linear Múltipla)	122.081	121.382	117.121	17,8%
Erro Absoluto	21,7%	23,9%	7,7%	
Previsão Cenário 2 (Regressão Linear Múltipla)	128.436	132.226	127.940	11,8%
Erro Absoluto	17,6%	17,1%	0,8%	
Previsão Cenário 3	145.000	150.000	130.000	5,1%
Erro Absoluto	7,0%	5,9%	2,4%	

Tabela 15 – Resultados da previsão estatística para frango no primeiro trimestre de 2023.

Fonte: Esta Pesquisa (2023)

- **Margarina e Manteiga**

Margarina e Manteiga	Janeiro	Fevereiro	Março	MAPE
Faturamento Total	42	1	1	
Previsão Cenário 1 (Suavização Exponencial Tripla)	72	-971	-1.824	93240,9%
Erro Absoluto	72,5%	97175,9%	182474,3%	
Previsão Cenário 2 (Regressão Linear Múltipla)	393	453	-86	18228,9%
Erro Absoluto	836,7%	45192,9%	8657,1%	
Previsão Cenário 3	50	0	0	6,3%
Erro Absoluto	19,0%	0,0%	0,0%	

Comentado [IL87]: Muito alto!!!

Tabela 16 – Resultados da previsão estatística para margarina e manteiga no primeiro trimestre de 2023.

Fonte: Esta Pesquisa (2023)

- Queijos

Queijos	Janeiro	Fevereiro	Março	MAPE
Faturamento Total	8.212	2.480	8.629	
Previsão Cenário 1 (Regressão Linear Múltipla)	5.806	5.135	7.588	49,5%
Erro Absoluto	29,3%	107,1%	12,1%	
Previsão Cenário 2 (Regressão Linear Múltipla)	6.719	3.938	8.585	25,8%
Erro Absoluto	18,2%	58,8%	0,5%	
Previsão Cenário 3	8.000	3.500	8.500	15,1%
Erro Absoluto	2,6%	41,1%	1,5%	

Tabela 17 – Resultados da previsão estatística para queijos no primeiro trimestre de 2023.

Fonte: Esta Pesquisa (2023)

Ao analisar os valores gerados para cada uma das famílias, a primeira constatação feita é que ao realizar a previsão em um nível mais desagregado, neste caso saindo do faturamento geral da empresa para o faturamento por família de produtos, o erro aumenta. Este fato já era esperado; entretanto, o ponto fundamental foi a análise da dificuldade em gerar previsões quantitativas em famílias de produtos que possuem um comportamento inesperado. Novamente, o caso da família de margarina e manteiga, que tem um MAPE superior a 18.000%, este valor ocorreu devido a vendas serem nulas nos meses de fevereiro e março devido a um problema com o fornecimento desses produtos, ou seja, a demanda existia e caso tivesse produto disponível para venda, os clientes teriam comprado, com isso eram esperados montantes de venda com base na série histórica. Mas, devido a um fato inesperado e não previsto pelo modelo, as vendas não se concretizaram. Esse problema foi resolvido com a adoção do cenário três, fazendo uma previsão com a adoção de uma previsão qualitativa. Como constatado também por Meneghini et al. (2018), gerou resultados consideravelmente melhores devido ao fato de que com o incremento da opinião da força de vendas, essa questão de não fornecimento de margarina e manteiga já estava prevista e com isso foram zeradas a previsão de vendas dessa família devido à falta de produtos disponíveis.

Por outro lado, a família de carne congelada retornou um MAPE de 7.9% para o primeiro trimestre de 2023 apenas com as previsões quantitativas, um valor considerado bom pelos administradores e sócios da empresa, o que permite uma confiança maior nas previsões

quantitativas para valores futuros de médio e longo prazo. Entretanto, na análise de curto prazo realizada com base no primeiro trimestre o cenário três retorna um erro consideravelmente melhor, e isso se deve mais uma vez às informações privilegiadas da realidade que os especialistas da empresa possuem.




Gráfico 2 –Previsão de demanda para o segundo, terceiro e quarto trimestre de 2023.

Fonte: Esta Pesquisa (2023)

Previsão	ABR	MAI	JUN	JUL	AGO	SET	OUT	NOV	DEZ
Total Empresa									
Cenário 1	239.962	249.214	255.452	259.091	267.967	277.013	243.324	270.852	276.535
Cenário 2	229.148	242.072	259.991	256.679	265.010	257.635	222.975	266.266	251.271
Carne Congelada									
Cenário 1	72.083	90.970	92.724	85.184	84.563	101.125	114.199	118.792	112.027
Cenário 2	67.875	90.140	91.214	77.905	76.506	90.431	113.724	120.991	110.133
Congelados									
Cenário 1	14.981	10.929	13.956	12.662	10.322	9.926	9.028	17.440	10.109
Cenário 2	19.028	22.209	27.518	25.367	22.073	21.044	18.850	31.986	21.937
Embutidos									
Cenário 1	54.779	59.894	62.587	73.845	75.194	82.681	83.945	95.006	108.324
Cenário 2	54.801	58.861	59.870	66.070	66.752	71.409	70.720	82.625	100.512
Frango									
Cenário 1	92.627	82.067	81.281	81.136	94.457	78.448	32.934	35.630	38.973

Cenário 2	79.763	60.980	73.561	74.600	84.768	66.324	12.211	24.084	9.587
Margarina e Manteiga									
Cenário 1	0	0	0	0	0	0	0	0	0
Cenário 2	854	2.920	2.511	5.159	9.663	2.892	2.260	447	1.014
Queijos									
Cenário 1	5.492	5.354	4.905	6.265	3.430	4.833	3.219	3.983	7.101
Cenário 2	6.827	6.962	5.316	7.578	5.248	5.535	5.210	6.134	8.088

Tabela 18 – Resultados da previsão estatística para empresa para o segundo, terceiro e quarto trimestres de 2023.

Fonte: Esta Pesquisa (2023)

Com base em todo o estudo, foram gerados os valores de previsão de demanda quantitativas para as famílias de produtos e o valor agregado de faturamento para a empresa para os próximos trimestres do ano de 2023, estes valores serão continuamente confrontados com os dados reais da empresa a medida em que ficarem disponíveis.

Bem como os processos mensais de previsão e replanejamento da demanda de forma qualitativa continuarão sendo executados pela empresa. Com o objetivo de gerar uma melhoria contínua no processo de previsão de demanda e melhorar a acuracidade do processo.

Comentado [IL88]: Comentar q esses dados serão confrontados com a realidade, à medida que os dados reais ficarem disponíveis.

4. ESTUDO DESENVOLVIDO

4.1 Conclusões

A experiência de realizar a pesquisa foi de grande importância pois colocou em prática diversos assuntos abordados na graduação, como planejamento de demanda, entendimento da cadeia de suprimentos e principalmente estudos acerca de modelos estatísticos para previsão de demanda.

O processo de previsão de demanda com modelos estatísticos necessita de testes, análises, mudanças em parâmetros e bastante conhecimento sobre os dados que estão sendo utilizados. Durante o estudo ficou bastante claro que pequenas alterações podem gerar resultados consideravelmente melhores. Com base nisso e nos resultados obtidos, que, apesar de provenientes dos dados de uma mesma empresa, e de um mesmo contexto, cada série temporal possui um comportamento drasticamente diferente, resultando em valores de previsão diferentes, com erros e análises que variam de uns para outros, sendo notado isso, inclusive, em séries temporais que receberam a mesma classificação.

Esse fato indica que a criação de um processo de planejamento de demanda com base em modelos estatísticos será consideravelmente diferente para o contexto estudado, mas que, ao desenvolver os modelos e aprofundar-se no estudo, resultados satisfatórios são gerados e que contribuem de forma considerável para o negócio.

Em resumo, o estudo aponta que a adoção de processo de previsão de demanda utilizando modelos estatísticos traz um resultado satisfatório e de grande valia para a empresa, pois possibilita um planejamento a médio prazo guiando outras áreas da empresa, desde compras, marketing, vendas e principalmente a área de gestão que pode construir análises e direcionamentos estratégicos valiosos para o negócio a partir dos dados fornecidos pela previsão.

Entretanto, a principal conclusão retirada do estudo é que apesar da qualidade da previsão estatística gerada, independente da sofisticação dos modelos existem informações que não podem ser previstas pelo modelo, e a junção das previsões quantitativas com uma abordagem de modelo qualitativo permite gerar previsões consideravelmente melhores, pois, a previsão

qualitativa complementa com informações reais do negócio, e expectativas e entendimento de mercado que não possíveis de serem previstas de forma simples pelos modelos.

Sendo assim, ao unir a capacidade estatística de gerar valores relevantes de previsão para a empresa, possibilitando um planejamento de médio prazo (doze meses ou mais), permite o negócio antever problemas futuros e planejar de forma adequada. Entretanto, na execução, em ciclos mais curtos (previsões para o mês seguinte ou três meses de horizonte), a adoção de uma análise qualitativa junto com a força de vendas e especialistas da empresa permite adicionar uma visão mais completa do negócio ao planejamento.

4.2 Limitações e sugestões para trabalhos futuros

A principal limitação do trabalho foi no tocante aos dados. Por se tratar de uma empresa relativamente nova, com poucos anos de mercado e com um crescimento rápido, os dados estavam desorganizados, com base de faturamento em softwares distintos, com códigos de produtos e classificações variadas. Então, o primeiro ponto é que devido a isso, a série temporal retrata fases diferentes da empresa, pois em 2018 atuava de uma forma mais isolada no mercado e, com o passar dos anos, a gama de produtos e atuação no mercado aumentaram, o que gerou mudanças abruptas nas séries, inclusive devido ao fato de nos primeiros anos de operação os dados não estarem tratados e disponíveis da melhor forma.

Como sugestão para trabalhos futuros, o primeiro ponto é a importância de ter disponível uma análise mais completa da empresa, como preços praticados, valores previstos pela equipe de vendas, valores investidos em campanhas de marketing, bem como informações qualitativas acerca dos resultados obtidos no passado (por exemplo, problemas com fornecimento). Essa análise mais completa da empresa e dos cenários permite uma preparação melhor dos dados, inclusive possibilitando um pré-processamento, suavizando picos ou vales nos resultados devidos aos impactos gerados por eventos que não se repetem.

A segunda sugestão é a adoção de variáveis dependentes nos modelos estatísticos. Como citado anteriormente, pode-se utilizar informações como inflação, preços praticados, preço médio do mercado, quantidade de vendedores da empresa, população total dos mercados atendidos pela empresa, quantidade de clientes ativos, todas essas variáveis e outras que façam sentido para a série temporal estudada podem estar presentes em testes para a construção de um modelo mais acurado de previsão.

Por fim, modelos de aprendizagem de máquina podem ser implementados para as previsões. Esses modelos têm uma maior sofisticação e podem gerar resultados melhores, entretanto, deve-se atentar à realização de testes e acompanhamento dos resultados, sendo o acompanhamento e a melhoria contínua partes fundamentais para a obtenção de bons resultados.

5. REFERÊNCIAS BIBLIOGRÁFICAS

- BERTAGLIA. **Logística e gerenciamento da cadeia de suprimentos**. 2. ed. São Paulo: Saraiva, 2009.
- BOWERSOX, D.J.; CLOSS, D.J; COOPER, M.B.;BOWERSOX,J.C. **Gestão Logística da Cadeia de Suprimentos**. 4. ed. Porto Alegre: AMGH, 2014.
- BALLOU, R. H. **Gerenciamento da cadeia de suprimentos - Logística empresarial**. - 5ª ed - São Paulo: Bookman, 2006.
- CECATTO, C.; BELFIORE, P. O uso de métodos de previsão de demanda nas indústrias alimentícias brasileiras. **Gestão e Produção**, v. 22, n. 2, 2015.
- CHOPRA, S.; MEINDL, P. **Gestão da cadeia de suprimentos: estratégia, planejamento e operações**. 6. ed. São Paulo: Pearson Education do Brasil, 2016.
- MOREIRA, D. **Administração da Produção e Operações**. São Paulo: Pioneira Thomson Learning, 2001.
- ALVES, HOEPERS, CORAZZA, SANTOS, CRISTOFOLINI, CRUZ, **Application of statistical method with exponential smoothing double and triple for demand forecasting in the inventory management**, Revista científica eletrônica de engenharia de produção, v. 19, p. 1001 - 1026, 2019.
- ZANELLA, VIEIRA, BARICHELLO, Previsão de demanda: um estudo de caso em uma agroindústria de carnes do oeste catarinense. **GEPROS. Gestão da Produção, Operações e Sistemas**, nº 1, jan-mar/2016, p. 45-57.
- ZAN, SELITTO, Técnicas de previsão de demanda: Um estudo de caso triplo com dados de vendas de materiais eletromecânicos. **GEPROS. Gestão da Produção, Operações e Sistemas**, ano 2, jul-set/2007, p. 95-106.
- CHIBA, G.J.; LUNA, M.M.M. Modelos de séries temporais: a análise da acurácia das previsões da demanda de uma linha de produtos em empresa do setor do vestuário. **GEPROS. Gestão da Produção, Operações e Sistemas**, v. 15, n. 4, p. 219 - 251, 2020.
- CECATTO, BELFIORE. O uso de métodos de previsão de demanda nas indústrias alimentícias brasileiras. **Gestão & Produção**, São Carlos, v. 22, n. 2, p. 404-418, 2015
- VEIGA, VEIGA, DUCLÓS, A acuracidade dos modelos de previsão de demanda como fator crítico para o desempenho financeiro na indústria de alimentos. **FUTURE STUDIES RESEARCH JOURNAL: TRENDS AND STRATEGIES**. v.2, n. 2, p. 87-107, jul-dez, 2010.

- GIL, A.C. **Como elaborar projetos de pesquisa**. 2. ed. SP: Atlas, 1991.
- GALLEGO-GARCÍA, S.; GARCÍA-GARCÍA, M. **Predictive Sales and Operations Planning Based on a Statistical Treatment of Demand to Increase Efficiency: A Supply Chain Simulation Case Study**. Appl. Sci. 2021, 11, 233
- Basson, L.M., Kilbourn, P.J. & Walters, J., 2019, 'Forecast accuracy in demand planning: A fast-moving consumer goods case study', **Journal of Transport and Supply Chain Management** 13(0), a427. <https://doi.org/10.4102/jtscm.v13i0.427>
- Rožanec, J.M.; Kažić, B.; Škrjanc, M.; Fortuna, B.; Mladenović, D. **Automotive OEM Demand Forecasting: A Comparative Study of Forecasting Algorithms and Strategies**. Appl. Sci. 2021, 11, 6787.
- MENECHINI, ANZANELLO, KAHMANN & TORTORELLA. **Ajuste de previsão de demanda quantitativa com base em fatores qualitativos: Estudo de caso em um restaurante fast food**. Revista Eletrônica Sistemas & gestão, v. 13, número 1, 2018, pp 68-80.
- Schmidt, A.; Kabir, M.W.U.; Hoque, M.T. **Machine Learning Based Restaurant Sales Forecasting**. Mach. Learn. Knowl. Extr. 2022, 4, 105–130.
- CARVALHO, Laura Gonçalves. **Metodologia para implementação de sistemas de previsão de demanda: um estudo de caso em um distribuidor de produtos químicos**. 2010. 81 f. Dissertação (Mestrado) - Curso de Engenharia de Produção, Pontifícia Universidade Católica do Rio de Janeiro - Puc-rio, Rio de Janeiro, 2010.
- CROSTON, J. D. Forecasting and stock control for intermittent demands. **Operational Research Quarterly**, vol. 23, nº 3, p. 289-303, 1972.
- LEMOS, F. de O. **Metodologia para Seleção de Métodos de Previsão de Demanda**. Porto Alegre. UFRGS, 2006. 183 p. Dissertação (Mestrado) – Programa de Pós-Graduação em Engenharia de Produção, Escola de Engenharia, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2006.
- LEE, Cheng-Min; KO, Chia-Nan. **Short-term load forecasting using lifting scheme and ARIMA models**. *Expert Systems with Applications*, v. 38, p. 5902-5911, 2011.
- MARTINS, P. G.; LAUGENI, F. P. **Administração da produção**. 2. ed. São Paulo: Saraiva, 2005.
- MAKRIDAKIS, S.; WHEELWRIGHT, S.; HYNDMAN, R. **Forecasting: Methods and Applications** – 3. ed., New York: John Wiley & Sons, 1998.
- MOREIRA, D.A. **Administração da Produção e Operações**. 2.ed. São Paulo: Cengage Learning, 2011.

SAMOHYL, Robert Wayne; SOUZA, Gueibi Peres; MIRANDA, Rodrigo Gabriel de. **Métodos simplificados de previsão empresarial**, Rio de Janeiro, Editora Ciência Moderna Ltda., 2008.

TUBINO, D.F. **Planejamento e Controle da Produção: teoria e prática** – 2.ed. São Paulo: Atlas, 2009.

VERÍSSIMO, Andrey Jonas et al. **Métodos estatísticos de suavização exponencial holt-winters para previsão de demanda em uma empresa do setor metal mecânico**. Revista Gestão Industrial. ISSN 1808-0448 / v. 08, n. 04: p. 154-171, 2012.

GOSSELIN, M. A. (1997). **The effect of strategy and organizational structure on the adoption and implementation of activity-based costing**. *Accounting, organizations, and society*, 22(2), 105-122.

PRAKASH, G.; MOHANTY, R. K. (2013). **An integrated approach to understanding the supply chain agility of dairy industry**. *The IUP Journal of Supply Chain Management*, 10(1), 44-63.