

UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ

FELIPE AUGUSTO CARNIETTO

**APLICAÇÃO DE TÉCNICAS DE PREVISÃO DE DEMANDA EM UMA LOJA DE
DEPARTAMENTO**

LONDRINA

2025

FELIPE AUGUSTO CARNIETTO

**APLICAÇÃO DE TÉCNICAS DE PREVISÃO DE DEMANDA EM UMA LOJA DE
DEPARTAMENTO**

Application of demand forecasting techniques in a departament store

Trabalho de Conclusão de Curso de Graduação apresentado como requisito para obtenção do título de Bacharel em Engenharia de Produção, da Universidade Tecnológica Federal do Paraná (UTFPR).

Orientador(a): Prof. Dr. Pedro Rochavetz de Lara Andrade.

LONDRINA

2025



Esta licença permite remixe, adaptação e criação a partir do trabalho, para fins não comerciais, desde que sejam atribuídos créditos ao(s) autor(es) e que licenciem as novas criações sob termos idênticos. Conteúdos elaborados por terceiros, citados e referenciados nesta obra não são cobertos pela licença.

FELIPE AUGUSTO CARNIETTO

**APLICAÇÃO DE TÉCNICAS DE PREVISÃO DE DEMANDA EM UMA LOJA DE
DEPARTAMENTO**

Trabalho de Conclusão de Curso de Graduação
apresentado como requisito para obtenção do título
de Bacharel em Engenharia de Produção, da
Universidade Tecnológica Federal do Paraná
(UTFPR).

28 de novembro de 2025

Pedro Rochavetz de Lara Andrade
Doutorado
Universidade Tecnológica Federal do Paraná

Rogério Tondato
Doutorado
Universidade Tecnológica Federal do Paraná

Bruno Samways dos Santos
Doutorado
Universidade Tecnológica Federal do Paraná

LONDRINA

2025

AGRADECIMENTOS

Primeiramente, agradeço meus pais, Maria do Carmo e Nilson por serem meus principais alicerces durante essa jornada acadêmica, me apoiando financeiramente e emocionalmente. Apesar de todos os contra tempos vividos durante esse período, nunca desistiram de me apoiar. Agradeço meu irmão, Nilson Junior, por sempre estar ao meu lado, aconselhando e mostrando os caminhos para vencer esse desafio tão sonhado. Agradeço também minha avó, que hoje não se faz mais presente, porém teve uma importante participação positiva durante esses meus anos como universitário.

Um agradecimento especial à minha futura esposa, Rafaella Mologni, que durante todos esses anos me apoiou e sempre buscou mostrar o lado bom das coisas, me fortalecendo cada vez mais para os momentos de dificuldades.

Agradeço a todos meus amigos que fizeram parte dessa longa jornada, principalmente aos meus amigos da república Toca da Raposa, por compartilharmos alegrias, tristezas, conhecimentos, derrotas e vitórias. Hoje trago comigo cada boa lembrança de todos.

Deixo também meu “muito obrigado” a todos os professores da UTFPR que me passaram seus conhecimentos, parte que se fez extremamente importante para meu desenvolvimento pessoal e profissional. Agradeço especialmente meu orientador Pedro Rochavetz, por todo ensinamento, paciência e motivação durante essa pesquisa.

RESUMO

Em ambientes de alta competitividade, especialmente no varejo, onde as margens de lucro são estreitas, o estudo de técnicas de previsão de demanda assume uma grande importância. Elas contribuem para que as organizações tomem decisões acertadas sobre a disponibilidade e distribuição de produtos, facilitando um planejamento eficaz e contribuindo para melhores resultados. Neste contexto, o presente trabalho teve como finalidade aplicar diferentes técnicas de previsão de demanda sobre dados históricos de vendas de eletrodomésticos portáteis, em uma rede de loja de departamento do setor de cosméticos. Sobre isso, analisa-se a viabilidade da aplicação das técnicas, bem como comparam-se os resultados obtidos. Para tanto, foi aplicada a Curva ABC a fim de classificar e selecionar os produtos mais relevantes para o estudo, juntamente com uma análise prévia sobre o comportamento dos dados históricos de vendas dos produtos selecionados. A partir disso, foram escolhidas as técnicas aplicadas sobre os dados: Média Móvel, Suavização Exponencial Simples, Suavização Exponencial com Tendência e Sazonalidade e SARIMA. Após a obtenção dos resultados, foram adotados métodos de avaliação a fim de comparar e analisar a viabilidade das ferramentas utilizadas. Conclui-se com este trabalho a viabilidade de aplicação dos métodos de previsão de demanda a partir de dados históricos de vendas, juntamente com a comparação de performance entre os diferentes produtos selecionados, e ainda, foram analisados os erros de previsão entre as previsões e os resultados reais, mais recentes, já obtidos pela empresa em estudo. Por fim, comenta-se sobre o comportamento dos dados, que podem ser mais regulares em relação a tendências e/ou sazonalidade, ou mais irregular e aleatório interferindo de forma significativa nos resultados das previsões.

Palavras-chave: Técnicas. Previsão de demanda. Loja de departamento. Cosméticos.

ABSTRACT

In highly competitive environments, particularly in the retail sector where profit margins are narrow, the study of demand forecasting techniques assumes significant importance. Such techniques assist organizations in making informed decisions regarding product availability and distribution, thereby enabling effective planning and contributing to improved outcomes. In this context, the present study aimed to apply various demand forecasting techniques to historical sales data of portable home appliances from a department store chain operating in the cosmetics sector. The research examines the feasibility of applying these techniques and compares the results obtained. To this end, the ABC Curve was utilized to classify and select the most relevant products for analysis, accompanied by a preliminary assessment of the behavior of the historical sales data for the selected items. Based on this analysis, the following techniques were applied: Moving Average, Simple Exponential Smoothing, Exponential Smoothing with Trend and Seasonality and SARIMA. After generating the forecasts, evaluation metrics were employed to compare and assess the effectiveness of each forecasting method. This study concludes that the application of demand forecasting methods based on historical sales data is feasible and provides a comparative analysis of the performance across different selected products. Furthermore, forecast errors were analyzed by comparing predictions to the most recent actual results obtained by the company under study. Lastly, the behavior of the data was discussed, highlighting that certain products may exhibit more regular patterns in terms of trend and/or seasonality, while others may present irregular or random patterns, which can significantly influence forecasting accuracy.

Keywords: Techniques. Demand forecasting. Department store. Cosmetics.

LISTA DE ILUSTRAÇÕES

Figura 1 - Abordagens para métodos de tratamento de informações em previsões.....	24
Figura 2 - Neutral Networks for Time-Series Forecasting.....	34
Figura 3 - Departamento elétricos e categorias.....	38
Figura 4 - Série histórica de vendas produto 1.....	41
Figura 5 - Série histórica de vendas produto 2.....	42
Figura 6 - Série histórica de vendas produto 3.....	43
Figura 7 - Série histórica de vendas produto 4.....	44
Figura 8 - Série histórica de vendas produto 5.....	45
Figura 9 - Pseudocódigo aplicado aos dados para previsões por média móvel	47
Figura 10 - Pseudocódigo aplicado aos dados para previsões por SES	48
Figura 11 - Pseudocódigo aplicado aos dados para previsões por Holt-Winters	49
Figura 12 - Pseudocódigo aplicado aos dados para previsões por SARIMA ...	51
Figura 13 - Resultado da previsão para o produto 1 aplicando-se média móvel	52
Figura 14 - Resultado da previsão para o produto 2 aplicando-se média móvel	53
Figura 15 - Resultado da previsão para o produto 3 aplicando-se média móvel	54
Figura 16 - Resultado da previsão para o produto 4 aplicando-se média móvel	55
Figura 17 - Resultado da previsão para o produto 5 aplicando-se média móvel	56
Figura 18 - Resultado da previsão para o produto 1 aplicando-se SES	57
Figura 19 - Resultado da previsão para o produto 2 aplicando-se SES	58
Figura 20 - Resultado da previsão para o produto 3 aplicando-se SES	59
Figura 21 - Resultado da previsão para o produto 4 aplicando-se SES	60
Figura 22 - Resultado da previsão para o produto 5 aplicando-se SES	61
Figura 23 - Resultado da previsão para o produto 1 aplicando-se Holt-Winters	62
Figura 24 - Resultado da previsão para o produto 2 aplicando-se Holt-Winters	63
Figura 25 - Resultado da previsão para o produto 3 aplicando-se Holt-Winters	64

Figura 26 - Resultado da previsão para o produto 4 aplicando-se Holt-Winters	65
Figura 27 - Resultado da previsão para o produto 5 aplicando-se Holt-Winters	66
Figura 28 - Resultado da previsão para o produto 1 aplicando-se o método SARIMA	67
Figura 29 - Resultado da previsão para o produto 2 aplicando-se o método SARIMA	68
Figura 30 - Resultado da previsão para o produto 3 aplicando-se o método SARIMA	69
Figura 31 - Resultado da previsão para o produto 4 aplicando-se o método SARIMA	70
Figura 32 - Resultado da previsão para o produto 5 aplicando-se o método SARIMA	71

LISTA DE TABELAS

Tabela 1 - Vertentes das fórmulas das técnicas de suavização exponencial	Err
o! Indicador não definido.6	
Tabela 2 - Demonstrativo da classificação ABC da categoria em estudo.....	39
Tabela 3 - Previsão VS Realizado: primeira semana de maio de 2025	72
Tabela 4 - Valores obtidos pela métrica: MAE	73
Tabela 5 - Valores obtidos pela métrica: RMSE.....	73

SUMÁRIO

1 INTRODUÇÃO	13
1.1 Problema	15
1.2 Justificativa	15
1.3 Objetivos	16
1.3.1 Objetivos específicos	16
2 REFERENCIAL TEÓRICO	17
2.1 Gestão de estoque	17
2.1.1 Estoque	17
2.1.2 Gerenciamento e controle de estoque	18
2.1.3 Curva ABC	20
2.2 Previsão de demanda	21
2.2.1 Definição de previsão de demanda	21
2.2.2 Métodos de previsão de demanda	23
<u>2.2.2.1 Média Móvel</u>	<u>24</u>
<u>2.2.2.2 Regressão</u>	<u>25</u>
<u>2.2.2.3 Suavização exponencial</u>	<u>25</u>
<u>2.2.2.4 Processo autorregressivo integrado de média móvel (ARIMA)</u>	<u>27</u>
<u>2.2.2.5 Processo sazonal autorregressivo integrado de média móvel (SARIMA)</u>	<u>28</u>
2.2.3 Métodos de avaliação	29
<u>2.2.3.1 Erro médio</u>	<u>30</u>
<u>2.2.3.2 Erro absoluto médio</u>	<u>30</u>
<u>2.2.3.3 Erro percentual absoluto médio</u>	<u>31</u>
<u>2.2.2.4 Erro quadrático médio</u>	<u>31</u>
<u>2.2.2.5 Raiz do erro quadrático médio</u>	<u>31</u>
2.3 Pesquisa operacional no varejo	32
2.4 Redes Neurais Artificiais	33
3 MÉTODOS E TÉCNICAS DE PESQUISA	35
4 DESENVOLVIMENTO	37
4.1 Empresa alvo	37
4.2 Coleta e seleção dos dados	38
4.3 Análise exploratória dos dados	40
4.3.1 Produto 1	40
4.3.2 Produto 2	41

4.3.3 Produto 3.....	42
4.3.4 Produto 4.....	43
4.3.5 Produto 5.....	44
4.4 Aplicação das técnicas de previsão	45
4.4.1 Média Móvel.....	46
4.4.2 Suavização exponencial simples (SES).....	47
4.4.3 Suavização exponencial com tendência e sazonalidade (Holt-Winters)	49
4.4.4 SARIMA.....	49
4.5 Resultados das previsões	51
4.5.1 Média móvel.....	51
<u>4.5.1.1 Produto 1.....</u>	<u>51</u>
<u>4.5.1.2 Produto 2.....</u>	<u>52</u>
<u>4.5.1.3 Produto 3.....</u>	<u>53</u>
<u>4.5.1.4 Produto 4.....</u>	<u>54</u>
<u>4.5.1.5 Produto 5.....</u>	<u>55</u>
4.5.2 Suavização exponencial simples (SES).....	56
<u>4.5.2.1 Produto 1.....</u>	<u>56</u>
<u>4.5.2.2 Produto 2.....</u>	<u>57</u>
<u>4.5.2.3 Produto 3.....</u>	<u>58</u>
<u>4.5.2.4 Produto 4.....</u>	<u>59</u>
<u>4.5.2.5 Produto 5.....</u>	<u>60</u>
4.5.3 Suavização exponencial com tendência e sazonalidade (Holt-Winters)	61
<u>4.5.3.1 Produto 1.....</u>	<u>61</u>
<u>4.5.3.2 Produto 2.....</u>	<u>62</u>
<u>4.5.3.3 Produto 3.....</u>	<u>63</u>
<u>4.5.3.4 Produto 4.....</u>	<u>64</u>
<u>4.5.3.5 Produto 5.....</u>	<u>65</u>
4.5.4 SARIMA (<i>Seasonal Autoregressive Intregrated Moving Average</i>)	66
<u>4.5.4.1 Produto 1.....</u>	<u>66</u>
<u>4.5.4.2 Produto 2.....</u>	<u>67</u>
<u>4.5.4.3 Produto 3.....</u>	<u>68</u>
<u>4.5.4.4 Produto 4.....</u>	<u>69</u>
<u>4.5.4.5 Produto 5.....</u>	<u>70</u>
4.6 Discussão dos resultados	71
5 CONCLUSÃO	75

6 REFERÊNCIAS.....	78
---------------------------	-----------

1 INTRODUÇÃO

Ao observar o cenário no mundo empresarial, nota-se uma intensificação da competitividade, exigindo das organizações um planejamento e coordenação eficazes para alcançar altos níveis de qualidade e serviço. No setor de varejo, essa competitividade é acentuada por margens de lucro estreitas, tornando essencial a tomada de decisões acertadas sobre a disponibilidade de produtos e serviços, para garantir bons resultados para as organizações. Neste contexto, estudos relacionados à previsão de demanda podem embasar a tomada de decisões acertadas, tanto acerca das compras de produtos, como da distribuição deles entre as lojas.

No setor varejista, a atividade de previsão de demanda desempenha um papel estratégico para o planejamento de estoques e otimização da rentabilidade operacional. Estimativas imprecisas comprometem a gestão de estoque: subestimar a demanda pode ocasionar faltas de produto (rupturas de estoque), gerando perda de vendas e impacto negativo na experiência do cliente, que pode optar em migrar para concorrentes. Por outro lado, superestimar a demanda resulta em excesso de estoque, aumento de custos com armazenagem, risco de obsolescência e vencimentos de produtos. Entende-se que seja essencial que o capital de giro das empresas seja alocado de forma eficiente, em alinhamento com processos operacionais otimizados e decisões baseados em previsões confiáveis (Andrade; Cunha, 2022).

De acordo com Franco Junior (2013) a previsão de séries temporais é fundamental em diversos setores como, mercado de finanças, gestão de estoque, previsão de vendas, entre outros. Essas previsões são vitais para diversos processos de tomada de decisão, geralmente sendo alcançadas através de modelos que estimam valores futuros com base em dados históricos da série e outras variáveis. A definição de um modelo de previsão envolve a escolha das variáveis pertinentes, da técnica de previsão apropriadas e de suas configurações. É crucial entender o sistema que a série representa e ter conhecimento do modelo de previsão selecionado.

Segundo Halmenschlager (2022) a previsão de demanda contribui para prever os itens necessários e a determinar a quantidade de materiais para futuras aquisições. Essa precisão aprimorada nas atividades de compra, busca aumentar o nível de

serviço das organizações, reduzindo a insatisfação dos usuários e minimizando gastos e aquisições desnecessárias.

Ackermann (2022), pontua a classificação dos métodos de previsão de demanda em quantitativos e qualitativos e relata aplicação das técnicas associados ao consumo e à produção de bens e serviços. Ainda segundo o autor, métodos quantitativos são procedimentos padronizados que produzem resultados objetivos por meio de modelos matemáticos e por outro lado, os métodos qualitativos não envolvem manipulação de dados e utilizam apenas julgamentos para elaborar a previsão.

Dentro desse domínio, entende-se que a previsão de demanda tem sido impulsionada pelo acesso a grandes volumes e variedades de dados. De acordo com Sousa (2024), esses fatores têm viabilizado a tomada de decisão orientada por dados, na qual as decisões empresariais estratégicas são fundamentadas em análises quantitativas em vez de intuição. Nesse contexto, essa prática se mostra especialmente relevante, pois permite identificar padrões de consumo e comportamentos de compra com maior precisão. Empresas que adotam essa cultura orientada por dados tendem a apresentar maior eficiência e produtividade sem seus processos decisórios.

As previsões de demanda estão naturalmente sujeitas a falhas, sobretudo quando se projeta para horizontes de longo prazo, nos quais a acurácia tende a diminuir devido ao aumento da incerteza. Nesse contexto, torna-se essencial garantir a qualidade dos dados utilizados e adotar critérios técnicos na seleção do modelo de previsão. A definição da metodologia deve considerar aspectos como o comportamento histórico da demanda, presença de sazonalidade ou tendência, e a complexidade computacional envolvida, de modo a identificar a técnica que melhor se adapta às características do problema dentro do contexto operacional e estratégico da organização (Ballou, 2007).

É indiscutível a existência de um grande número de publicações sobre métodos de previsão de demanda, assim como a diversidade de técnicas e modelos disponíveis nesta área de pesquisa. Considerando que as previsões não são perfeitas e podem apresentar erros, Armstrong (2001) sugere que, para mitigar os efeitos dos erros de previsão em ambientes incertos e altamente instáveis, uma alternativa seria combinar diferentes técnicas, de maneira apropriadas.

1.1 Problema

Diante de um cenário cada vez mais competitivo, empresas que utilizam de estratégias e técnicas defasadas ou até mesmo do empirismo são penalizadas por conta da tomada de decisões de baixa qualidade. Mesmo nos tempos atuais, com informações abundantes e grande avanço tecnológico, prever o futuro de forma precisa é algo improvável.

É inviável para as organizações se planejarem acerca da compra e distribuição de materiais, sem ao menos uma estimativa da demanda futura. Em consideração a um futuro incerto, as previsões se resumem em tentativas para alcançar resultados que se aproximem ao máximo da realidade. Dessa forma, são propostos modelos estatísticos de previsão que procuram nas tendências passadas as respostas para eventos futuros, auxiliando nas previsões e nos processos de tomadas de decisões. Ainda neste contexto, a escolha da técnica mais adequada para a previsão de demanda de cada produto pode afetar muito a qualidade dos resultados, bem como a qualidade do gerenciamento do estoque e do atendimento ao cliente.

A partir das argumentações apresentadas, levanta-se a seguinte questão de pesquisa: Qual técnica de previsão de demanda se adequa melhor aos dados históricos, para prever a demanda de eletrodomésticos portáteis em uma loja de departamento?

1.2 Justificativa

Tomar decisões é fato cotidiano que tem grande importâncias dentro das empresas. No contexto atual, o processo de globalização tem forçado as organizações a buscarem maior competitividade, como maneira de sobressaírem no meio empresarial e isso exige a capacidade de tomar decisões rápidas e precisas.

Nessa condição, a previsão de demanda tornou-se um dos principais aspectos na gestão empresarial, destacando técnicas cruciais para enfrentar as possíveis variações da demanda e, conseqüentemente, evitar prejuízos. Quando bem utilizada, a previsão permite que a organização tenha um controle mais eficaz de suas operações e processos, atendendo de forma mais eficiente à demanda por produtos ou serviços.

A utilização de múltiplos métodos de previsão de demanda tem se mostrado cada vez mais necessária, especialmente em cenários onde a complexidade e

quantidade de informações disponíveis exigem maior poder analítico. A combinação de diferentes técnicas, sejam elas estatística ou baseadas em julgamento de especialistas, permite incorporar uma variedade maior de dados e conhecimentos ao processo de previsão, aumentando sua confiabilidade. Essa abordagem torna-se ainda mais eficaz quando os métodos utilizados trazem informações complementares e não correlacionadas, resultando em ganhos de acurácia em relação as previsões individuais (ARMSTRONG, 2001; CLEMEN, 1989; WRIGHT et al. 1996).

Nesse sentido e através das técnicas de previsão de demanda, que são o objetivo de estudo deste trabalho, será possível extrair dos resultados e dados para comparação entre os modelos selecionados. E espera-se concluir a eficiência, bem como pontos positivos e negativos dos métodos e técnicas.

Na perspectiva da engenharia de produção esse trabalho contribui para a área de gestão da produção e operações, retratando a aplicação de alguns conceitos de maneira prática e trazendo discussões sobre a comparação entre as técnicas utilizadas.

1.3 Objetivos

Este trabalho tem como objetivo aplicar as seguintes técnicas de previsão de demanda: Média Móvel, Suavização Exponencial Simples, Suavização Exponencial com Tendência e Sazonalidade (Holt-Winters) e SARIMA, sobre dados históricos de vendas de eletrodomésticos portáteis, em uma loja de departamento do setor de cosméticos. Além disso, analisar a viabilidade e comparar os resultados das diferentes técnicas utilizadas.

1.3.1 Objetivos específicos

- Selecionar os produtos a serem analisados;
- Analisar a viabilidade das técnicas escolhidas;
- Aplicar e testar diferentes técnicas de previsão de demanda aos dados da empresa;
- Comparar os resultados obtidos com os valores reais ocorridos e entre as técnicas utilizadas;
- Discussão da adequação dos modelos de previsão de demanda quantitativos.

2 REFERENCIAL TEÓRICO

Neste capítulo é apresentado um referencial teórico abordando os principais assuntos que norteiam o presente estudo. A gestão de estoque é abordada na Seção 2.1, e a Seção 2.2 apresenta o conceito geral de previsão de demanda, bem como algumas das principais técnicas. A Seção 2.3 trata de pesquisa operacional e suas técnicas aplicadas à previsão de demanda.

2.1 Gestão de estoque

Nesta seção, a gestão de estoque será estudada, sendo que inicialmente define-se o conceito de estoque, na seção 2.1.1, e na Seção 2.1.2, aborda-se o gerenciamento e controle de estoque.

2.1.1 Estoque

Sobre o ponto de vista de Chiavenato (2022) estoque é a disposição de materiais em diferentes etapas do processo na cadeia de suprimentos, podendo ser no início, como a matéria prima; no meio, como materiais em processamento ou semiacabados; e no final, que seriam os produtos acabados.

De acordo com Moreira (2008), *apud* Aguir (2023) estoque são itens físicos que estão guardados, por algum intervalo de tempo. No caso de produtos acabados, estes estão aguardando a venda ou despacho, enquanto matérias-primas e componentes aguardam por utilização na produção.

Para Dias (2023, p.7) “sem estoque é impossível uma empresa trabalhar, pois ele funciona como um amortecedor entre vários estágios da produção até a venda final do produto”. Seguindo esta afirmação, culturalmente é inviável para a grande maioria das organizações trabalharem sem estoque, seja ele de qual tipo for.

Segundo Chopra (2003) estoque é um fator-chave da cadeia de suprimentos e para um varejista grande quantidade de estoque pode torná-lo mais responsivo. Ou seja, ao investir seu capital, as organizações desse setor aumentam suas chances de atender as necessidades dos clientes no ponto de venda.

Em contrapartida, ainda segundo Chopra (2003) um grande estoque, aumentará os custos do varejista. Visto que o estoque é um dos principais geradores

de custo em uma empresa. Isso se dá, uma vez que ele é um ativo investido que está aguardando para ser utilizado em alguma etapa específica dentro do processo até que seja consumido pelo cliente no final da cadeia e retorne como lucro.

2.1.2 Gerenciamento e controle de estoque

A fim de tratar da maneira mais eficiente possível esse *trade-off*, entre ser uma empresa responsiva à demanda dos seus clientes, buscar atendê-los de forma mais assertiva e no momento desejado pelos mesmos ou balancear até que ponto o investimento em estoque se torna rentável e não um custo de alto risco para as organizações, a gestão e o controle de estoques surgem como conceitos muito importantes.

A gestão de estoque é uma ferramenta organizacional, através do qual se planeja, administra e coordena esses recursos de ativos investidos pela empresa. De acordo com Ching (2010, p. 17):

O controle de estoque exerce influência muito grande na rentabilidade da empresa. Os estoques absorvem capital que poderia estar sendo investido de outras maneiras, desviam fundos de outros usos potenciais e têm o mesmo custo de capital que qualquer outro projeto de investimento da empresa. Aumentar a rotatividade do estoque libera ativo e economiza o custo de manutenção de inventário.

Segundo Pozo (2019, p. 36) “controle de estoque é em função da necessidade de estipular os diversos níveis de materiais e produtos que a organização deve manter dentro dos parâmetros econômicos.” Por materiais e produtos entende-se desde a matéria-prima utilizada pelo fabricante, até os produtos acabados disponibilizados aos consumidores no ponto de venda. Destaca-se também que dentro de todo esse processo não apenas os estoques extremos devem ser gerenciados, materiais auxiliares, materiais de manutenção, materiais/peças em processos, necessitam de ter suas disponibilidades planejadas para que as atividades não sejam interrompidas.

Pode-se dizer que grande parte das organizações, que se baseiam em modelos tradicionais de operações, seja ela industrial, atacadista ou varejista, realiza processos de reabastecimento de matéria-prima e/ou produtos acabados (Bowersox *et al.*, 2014). Seguindo essa linha de pensamento, entende-se que o gerenciamento de estoque abrange muitos elos pertencente a uma cadeia de suprimentos, para que o produto chegue até o consumidor final.

Conforme apresentado por Simchi-Levi *et al.*, (2008) *apud* Barros (2021) a gestão de estoque dentro da cadeia de suprimentos engloba um conjunto de

estratégias utilizadas para alinhar de maneira eficiente os fornecedores, indústrias, atacados e varejos, garantindo que os produtos serão produzidos e distribuídos na quantidade, local e tempo certos, com o objetivo de amenizar os custos do sistema sem prejudicar os níveis de serviços necessários.

Ao se pensar em uma ideologia mais moderna e buscar atribuir ao melhor cenário possível, segundo a visão de Jacobs *et al.* (2012) os inovadores em logística discutem sobre a eliminação, ou uma redução significativa dos estoques nas cadeias produtivas. Afinal, organizações altamente eficientes e sem folgas não necessitariam de estoque de segurança. Possivelmente essa utopia é bastante atrativa: a abolição do estoque poderia resultar em uma redução expressiva nos custos logísticos e uma simplificação nos atendimentos dos pedidos. No entanto, essa visão ainda requer alto nível de expertise, e muitas organizações ainda não atualizaram adequadamente suas redes e tecnologias para eliminar a necessidade de manter pelo menos um estoque mínimo.

Segundo Kella & Agrogiannis (2016) *apud* Barros (2021) a gestão e controle de estoque desempenham um papel fundamental no sucesso dos negócios em um ambiente globalizado e modernizado. A forma como as organizações administram suas redes de suprimentos e estudam a maneira mais eficaz de alocar seus recursos é fundamental para garantir a rentabilidade a longo prazo e o crescimento empresarial sustentável.

De acordo com Krajewsk *et al.* (2009) *apud* Jeronino et al. (2020) a gestão de estoque faz-se necessária para lidar com o dilema de manter ou não níveis de estoques além da demanda, visto que o excesso pode diminuir a rentabilidade da empresa, uma vez que o capital está investido em materiais / produtos sem retorno financeiro até dado momento, enquanto a falta de estoque reduz a confiança do cliente para todos os elos da cadeia.

A respeito de artifícios associados ao controle de estoque e apresentando o trabalho de Grant (2013), existem três métodos de gestão de estoque: informais, estatísticos e de planejamento de necessidades. Os dois primeiros são adequados para situações em que a demanda é independente, como produtos de saúde e beleza em lojas de departamentos. Por outro lado, o último é mais apropriado para situações em que a demanda é dependente, como matérias-primas para fabricação de um produto único, como automóveis e dispositivos eletrônicos. A demanda dependente é crucial no início da cadeia de suprimentos, onde os fornecedores se baseiam em

pedidos de compras dos clientes para determinar o estoque necessário. O perfil de demanda de um varejista, em geral, é associado à demanda independente.

A fim de auxiliar nas tomadas de decisões no gerenciamento de estoque faz-se necessário a

utilização de ferramentas que facilitem esse processo. De acordo com Tristão (2021, p. 219):

Mediante o importante papel dos estoques nas organizações, torna-se necessária a utilização de ferramentas que auxiliem sua gestão, de modo a otimizar os recursos de capital investidos, de modo que as empresas continuem seu processo produtivo de maneira ininterrupta.

2.1.3 Curva ABC

Uma ferramenta relativamente acessível, muito utilizada e que se mostra muito eficaz é a Classificação ABC. Segundo Galindo (2012) *apud* Zanchettin (2018), a Curva ABC baseada no Princípio de Pareto, trata-se de um método quantitativo e consiste na premissa de que uma alta quantidade de efeitos (aproximadamente 80% das consequências), se origina de uma baixa quantidade de causas (aproximadamente 20%).

Trazendo o conceito e afinando para organizações onde o foco é baseado em compra e venda, “80% das vendas de uma operação respondem por apenas 20% de todos os itens estocas” Slack *et al.* (2020, p. 512). Seguindo essa premissa, o controle de estoque pela curva ABC, ainda segundo a visão dos autores, pode ser classificado da seguinte maneira:

- Itens classe A: São aqueles 20% dos itens que apresentam maior valor e correspondem a 80% do valor total do estoque.
- Itens classe B: Representado por aproximadamente 30% dos itens, que representam 15% do valor total. Entende-se por aqueles itens de valores intermediários.
- Itens classe C: Maior representatividade dos itens, cerca de 50% do total de tipos estocados, porém representam em torno de 5% do valor total. São itens de baixo valor.

Conforme apresentado por Carvalho (2019) *apud* Araújo *et al.* (2016), o gerenciamento de estoque pela metodologia da curva ABC, permite visualizar e

segmentar os estoques, monitorando o consumo/vendas em relação ao valor monetário ou à quantidade dos itens que tiveram saída e que compõem o estoque, durante um período de tempo que se deseja analisar.

Ainda sobre a visão complementada do autor Lauria (2007) e Schvirck (2010) *apud* Araújo (2016), o efeito da utilização dessa ferramenta é a busca pela otimização da aplicação dos recursos financeiros ou de materiais, evitando-se desperdícios ou aquisições desnecessárias. Amenizando tais incorreções, verifica-se ser uma etapa muito útil no planejamento de um programa de ação para aperfeiçoar o desempenho dos estoques, trazendo mais rentabilidade para as organizações, por conta da redução do capital investido em estoques como os custos operacionais.

2.2 Previsão de demanda

Nesta seção, definições sobre previsão de demanda serão apresentadas, na Seção 2.2.1. Em seguida, na Seção 2.2.2, serão abordadas técnicas de previsão de demanda. Por fim, na Seção 2.2.3 será discorrido sobre os métodos de avaliações.

2.2.1 Definição de previsão de demanda

Na visão de Corrêa (2019) uma das responsabilidades cruciais das organizações é buscar harmonizar de maneira eficaz a oferta e procura dos clientes ou usuários, em relação aos produtos/serviços ofertados. Isso é indispensável, para assegurar que os clientes fiquem altamente satisfeitos, se tornem leais e contínuos, e indiquem os produtos/serviços a outros potenciais clientes, atuando como propagandistas gratuitos.

De acordo com Martins *et al.* (2005) *apud* Nunes (2019) entende-se previsão de demanda por um método sistemático de estimativa de dados futuros com base em modelos estatísticos, matemáticos ou econométricos ou até mesmo em modelos subjetivos sustentados por um sistema de trabalho definido e pré-estabelecido. Podendo ainda ser expandida como um processo que se baseia no pressuposto que a demanda de um período anterior, por um produto pode, em parte, explicar sua procura no futuro. Essa metodologia envolve identificar e compreender os elementos

que influenciaram essa demanda passada, utilizando dessas informações para buscar projetar o comportamento futuro.

As previsões de demanda são técnicas importantes a serem adotadas pelas organizações, pois orientam o processo de produção e comercialização de seus produtos/serviços, uma vez que auxiliam no planejamento com um certo grau a mais de precisão sobre as quantidades desses produtos/serviços que serão produzidos e vendidos. Esta estimativa, que pode ser expressa em unidades físicas ou em valor monetário, representa a quantidade esperada de um produto/serviço que será vendido durante um período de tempo específico (geralmente um ano, subdividido em meses). Essa análise preditiva pode abranger todo o mercado ou todo o portfólio de produtos da empresa, assim como um segmento específico ou categorias dependentes (Chiavenato, 2022).

Conforme apresentado por Ballou (2007, p. 242) “a previsão dos níveis de demanda é vital para a empresa como um todo, à medida que proporciona a entrada básica para o planejamento e controle de todas as áreas funcionais”. Ainda sobre a visão do autor, as demandas podem ser divididas em: Demanda Espacial X Demanda Temporal; Demanda Irregular x Demanda Regular; e Demanda Dependente X Demanda Independente.

- Demanda Espacial X Demanda Temporal: A logística envolve tanto aspectos espaciais quanto temporais, por isso é importante saber e entender onde e quando surgem a demanda. A localização desempenha um papel crucial no planejamento de centros de distribuições/armazéns também no equilíbrio de estoques e na alocação de recursos de transportes. Os métodos de previsão devem refletir as diferenças geográficas que afetam os padrões de procura. Enquanto as preocupações temporais são comuns nas previsões, uma vez que a demanda varia a longo do tempo devido a fatores como crescimentos, sazonalidade e flutuações. Esses métodos que lidam com essas variações são chamados de séries temporais.

- Demanda Irregular X Demanda Regular: Os produtos são agrupados de forma específica para diferenciar os níveis de serviço ou para uma gestão mais assertiva. Esses grupos formam padrões de demanda variados ao longo do tempo, divididos em tendências, sazonalidades e variações aleatórias. Em situações de demanda regular, as variações são relativamente baixas e a previsão bem-sucedida geralmente é alcançada por meio de métodos conhecidos. No entanto, quando a demanda é intermitente, devido ao baixo volume e incerteza sobre a ocorrência e nível

de demanda, a série temporal é considerada irregular. Isso ocorre principalmente em produtos em transição ou com pouca procura.

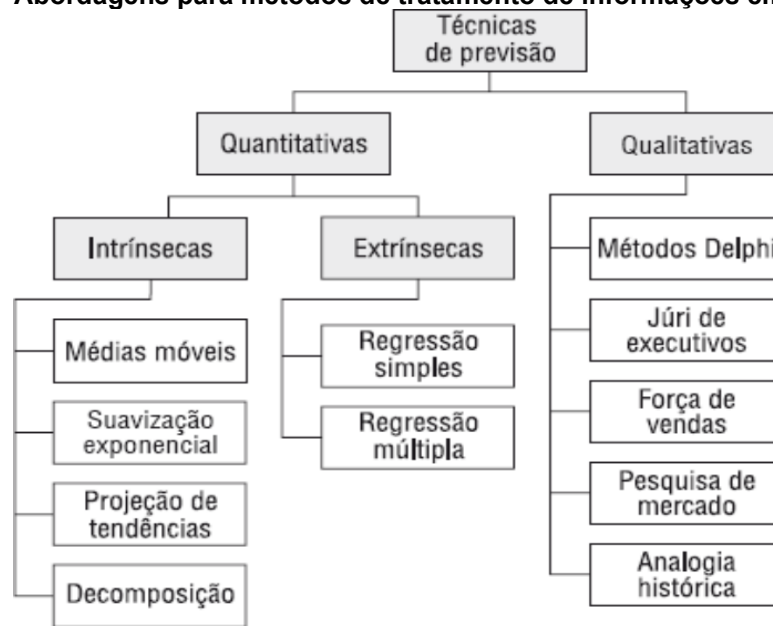
- Demanda Dependente X Demanda Independente: A demanda pode variar dependendo da estratégia de cada organização. Em um cenário, a demanda é determinada por programas de produção, por exemplo, ou seja, sendo conhecida antecipadamente, caracterizando-a como dependente. Neste caso, a previsão é substituída pela compreensão dessas influências, resultando em previsões mais precisas. Por outro lado, quando a demanda é gerada por vários clientes, através de aquisições individuais e imparciais de apenas uma parte do volume total oferecido pelas organizações, trata-se de uma demanda independente. Para isso, os métodos estatísticos de precisão são mais eficazes devido à sua natureza aleatória.

2.2.2 Métodos de previsão de demanda

Como discorrido por Jacobs; Chase (2012, p.455) “as previsões podem ser classificadas em quatro tipos básicos: qualitativa, análise de séries temporais, relações causais e simulação”. Com base nessa linha de pensamento, os métodos qualitativos fundamentam-se de decisões baseadas em estimativas e suposições, em grande parte das vezes, em decisões gerenciais. Já a análise de séries temporais baseia-se no pressuposto de que os números apresentados sobre a demanda passada podem ser tratados para prever a procura futura. Enquanto as previsões causais são expressas com base em métodos de regressão linear que sugerem que a demanda está associada com algum aspecto externo do ambiente. Por fim, as técnicas de simulação reconhecem que o encarregado pelas análises preditivas, considerem um conjunto de premissas acerca da condição da previsão.

Segundo Corrêa (2019), as técnicas de previsão de demanda são divididas em dois tipos de abordagens, qualitativa (com base em fatores individuais, pertinentes e relativos) e quantitativos (buscam padrões em séries passadas que são extrapolados para o futuro de acordo com alguma técnica).

Figura 1 – Abordagens para métodos de tratamento de informações em previsões



Fonte: CORRÊA (2019, p. 232)

2.2.2.1 Média Móvel

A primeira técnica a ser abordada é a média móvel e como apresentado por Tubino (2017), esse método de previsão de demanda utiliza dados de um certo número de períodos, predeterminados, geralmente os mais atuais, para gerar sua previsão. Se a demanda não aumentar ou diminuir rapidamente e não for sazonal, as médias móveis podem ser úteis para eliminar flutuações inesperadas nas previsões (Jacobs *et al.*, 2009).

A formula para uma média móvel simples é:

$$F_t = \frac{A_{t-1} + A_{t-2} + A_{t-3} + \dots + A_{t-n}}{n} \quad (1)$$

Onde:

F_t : previsão para o período

n : número de períodos da média

A_{t-n} : demandas reais dos n períodos atrás.

A fórmula para uma média móvel ponderada é:

$$F_t = w_1A_{t-1} + w_2A_{t-2} + \dots + w_nA_{t-n} \quad (2)$$

Onde:

w_n : Peso a ser atribuído à demanda real para o período t-n.

2.2.2.2 Regressão

A regressão são técnicas que envolvem várias possibilidades para o formato das funções que a compõem e conforme Ballou (2007), é uma técnica que estabelece uma relação entre a demanda e outras variáveis, que resultam ou definem seu nível. É de se considerar, através da regressão simples, que a variável dependente (em técnicas de previsão, é associado a demanda) está ligada a somente uma variável independente ou variável causal. Destacando-se as mais utilizadas:

$$Y = a + b \times X \quad (4)$$

$$Y = a \times b^x \quad (5)$$

$$Y = a + b \times X + c \times X^2 \quad (6)$$

Onde:

Y: Variável dependente (demanda)

X: Variável independente

a; b: parâmetros, ou seja, valores numéricos constantes.

A eq. 4 representa uma regressão linear simples, enquanto a eq. 5 trata-se de uma regressão exponencial e por fim, a eq. 6 caracterizada por uma regressão parabólica.

2.2.2.3 Suavização exponencial

Tratando-se dos modelos de suavização exponencial e segundo Pellegrini (2000), essas técnicas são geralmente empregadas à previsão de demanda, por conta de sua fácil aplicação e precisão confiável. Cada ponto da série temporal recebe um

peso específico, atribuindo mais peso aos novos dados. Essa abordagem resulta em uma distribuição ponderada que decai de acordo com a defasagem dos números.

Sobre a perspectiva de Koehler et al. (2001) *apud* Ribeiro (2016) essa técnica subdivide-se em três vertentes: suavização exponencial simples, suavização exponencial com tendência (modelo de Holt) e suavização exponencial com tendência e sazonalidade (modelo de Holt Winters).

Tabela 1: Vertentes das fórmulas das técnicas de suavização exponencial

Suavização Exponencial Simples	$F_t = B_t = \alpha \times D_t + (1 - \alpha) \times B_{t-1}$
Suavização Exponencial com Tendência (modelo de Holt)	$B_t = \alpha \times D_t + (1 - \alpha) \times (B_{t-1} + T_{t-1})$ $T_t = \beta \times (B_t - B_{t-1}) + (1 - \beta) \times T_{t-1}$ $F_t(1 + k) = B_t + k \times T_t, \quad k = 1, 2, \dots$
Suavização Exponencial com Tendência e Sazonalidade (modelo de Holt Winters)	$B_t = \alpha \times \frac{D_t}{I_{t-L}} + (1 - \alpha) \times (B_{t-1} + T_{t-1})$ $T_t = \beta \times (B_t - B_{t-1}) + (1 - \beta) \times T_{t-1}$ $I_t = \gamma \times \frac{D_t}{B_t} + (1 - \gamma) \times I_{t-1}$ $F(t + k) = (B_t + k \times T_t) \times I_{t-L+k}, \quad k = 1, 2, \dots$

Fonte: Autoria própria (2025)

Onde:

F_t = previsão para o período t

B_t = base para o período t

α = constante de suavização para base (entre 0 e 1)

D_t = demanda do período t

T_t = tendência no período t

β = constante de suavização para tendência (entre 0 e 1)

$F_t(1 + k)$ = previsão para um horizonte de k períodos a frente do instante t

I_t = índice de sazonalidade do período t

γ = constante de suavização para sazonalidade (entre 0 e 1)

L = extensão do ciclo sazonal

Sintetizando a visão de Ribeiro (2016), a suavização exponencial e suas variáveis, compreendem de técnicas de previsão que ajustam a demanda com base em um valor inicial, levando em consideração novas informações ao longo do tempo. Na sua forma mais simples, uma média ponderada é aplicada aos dados históricos, enquanto a suavização exponencial com tendência adiciona uma variável que reflete o crescimento da procura, ou até mesmo o declínio. Por fim, na suavização exponencial com tendência e sazonalidade, além da tendência, é necessário retirar os efeitos sazonais e levar em consideração a previsão. Para todas as abordagens, as estimativas são ajustadas à medida que novas informações são adicionadas.

2.2.2.4 Processo autorregressivo integrado de média móvel (ARIMA)

Entre as abordagens mais utilizadas na modelagem de séries temporais paramétricas está o método desenvolvido por Box e Jenkins, ARIMA (processo autorregressivo integrado de média móvel), que se fundamenta no ajuste de estruturas compostas por componentes autorregressivos, de diferenciação (integração) e de médias móveis. Esse tipo de modelagem, representado pela notação (p, d, q) , permite capturar padrões complexos presentes nos dados, como tendências e dependências temporais. Segundo Morettin *et al.* (2018), essa metodologia é amplamente empregada por sua capacidade de adaptar-se a diferentes comportamentos históricos por meio da combinação dos seus parâmetros.

Amaral (2019) *apud* Barros (2021) explicam os componentes do método de tal forma:

AR – *AutoRegressive*: avalia a autocorrelação entre séries temporais e elimina essa influência; (p: ordem da parte regressiva).

I – *Integrated*: caso necessário transformar a série temporal em estacionária, aplica-se uma diferenciação na mesma. Geralmente, uma ou duas diferenciações são ideias para corrigir a sequência; (d: grau de diferenciação).

MA – *Moving Average*: Estima-se os erros entre os períodos e elimina-se seus efeitos; (q: ordem da média móvel)

Interpreta-se esses parâmetros (p, d, q) de tal maneira:

$p = 1, 2$: uma observação específica pode ser esclarecida por uma ou duas observações prévias e por um componente residual (erro)

$d = 0, 1, 2$: onde não se aplica diferenciação ou aplica-se diferenciação de primeira ou segunda ordem.

$q = 1, 2$: o erro de uma observação em específico pode ser esclarecido pelo erro de 1 ou duas observações prévias.

Segundo Michel (2022) e Barros (2021) modelos ARIMA, podem ser apresentados de forma estacionária ou não estacionária, das seguintes formas, respectivamente:

$$Y_t = c + \sum_{i=1}^p \varphi_i \times Y_{t-i} + \sum_{i=1}^q \theta_i \times \varepsilon_{t-i} + \varepsilon_t \quad (7)$$

$$\Delta^d Y_t = c + \sum_{i=1}^p \varphi_i \times \Delta^d Y_{t-1} + \sum_{i=1}^q \theta_i \times \varepsilon_{t-i} + \varepsilon_t \quad (8)$$

Onde:

Y_t = série temporal no instante t

c = um valor constante

p = ordem da parte autorregressiva

q = ordem da parte da média móvel

d = ordem de diferenciação

φ = parâmetro estimulador da parte autorregressiva

θ = parâmetro estimador da parte da média móvel

ε = erro residual

Δ^d = diferenciação para tornar a série estacionária

2.2.2.5 Processo sazonal autorregressivo integrado de média móvel (SARIMA)

Quando se observa a presença de padrões sazonais em séries temporais, torna-se necessário incorporar o modelo SARIMA, de previsão. Uma forma robusta de lidar com essa complexidade é por meio da extensão dos modelos tradicionais, que além de componentes autorregressivos, de integração e médias móveis, também consideram efeitos sazonais em diferentes períodos. De acordo com Barros *et al.*

(2018), essa abordagem permite estimar valores futuros com base não apenas nas observações mais recentes, mas também em repetições cíclicas que ocorrem em intervalos regulares, o que aumenta a acurácia da previsão em contextos onde a sazonalidade é significativa.

Entendem-se que o modelo SARIMA é uma extensão do modelo ARIMA, e a notação utilizada passa de (p, d, q) para $(p, d, q) \times (P, D, Q)$ onde os últimos parâmetros condiz com as ordens da parte autorregressiva, da diferenciação e da média móvel para o componente sazonal da série temporal.

O método SARIMA está estruturado em duas etapas: a primeira leva em conta a captura da tendência e sazonalidade e a segunda, a captura da autocorrelação. Neste modelo, faz-se necessário separar os dados utilizados para distinguir a tendência e a sazonalidade dos dados utilizados (MICHEL, 2022).

Segundo Barros (2021), o modelo completo do SARIMA é descrito de tal forma:

$$\nabla^D \Delta^d Y_t = c + \sum_{i=1}^p (\varphi_i \times \nabla^D \Delta^d Y_{t-i}) + \sum_{i=1}^q (\theta_i \times \varepsilon_{t-i}) + \sum_{i=1}^P (\phi_i \times \nabla^D \Delta^d Y_{t-iS}) + \sum_{i=1}^Q (\theta_i \times \varepsilon_{t-iS}) + \varepsilon_t \quad (9)$$

Onde:

∇^D = diferenciação do componente sazonal

P = ordem da parte sazonal autorregressiva

D = ordem da diferenciação do componente sazonal

Q = ordem da parte sazonal da média móvel

ϕ = parâmetro estimador da parte sazonal autorregressiva

θ = parâmetro estimador da parte sazonal da média móvel

S = duração do ciclo sazonal

2.2.3 Métodos de avaliação

Conforme apresentado por Barros (2021), medir o desempenho de modelos preditivos é importante para calibrá-los convenientemente para assim aumentar sua precisão e como eles podem ser usados para determinar margens de segurança. No

entanto, são disponibilizadas na literatura, diversas formas de medir tal erro, sendo cada uma com suas vantagens e desvantagens.

Sobre o ponto de vista de Zan *et al.* (2007) *apud* Beneventi (2017), não importa quão boa seja a técnica de previsão usada, erros sempre acontecerão. Previsões externas de mercado, sempre influenciarão, como publicidade, volatilidade do mercado e ações dos concorrentes, entre outros, podem fazer com que as previsões superem as expectativas. Portanto, é preciso estar atento ao mercado e estar preparado para possíveis desvios nos valores previstos.

2.2.3.1 Erro médio

O Erro Médio (*Mean Error* – ME) é uma métrica amplamente utilizada na avaliação de modelos de previsão por sua capacidade de indicar a presença de viés sistemático nas estimativas. Ao calcular a média aritmética simples dos erros – diferença entre valores previstos e reais – a métrica evidencia se o modelo tende a superestimar ou subestimar os resultados ao longo do tempo. Como os desvios positivos e negativos se anulam, o valor final pode revelar a existência de influências externas ou padrões não capturados adequadamente, funcionando como um diagnóstico inicial da qualidade do modelo preditivo (MONTGOMERY, 1976).

$$ME = \frac{\sum_{i=1}^n (P_{real,i} - P_{previsto,i})}{n} \quad (10)$$

2.2.3.2 Erro absoluto médio

O Erro Absoluto Médio (*Mean Absolute Error* – MAE) é uma métrica bastante utilizada para medir a precisão de modelos de previsão, pois considera a magnitude dos erros de forma mais objetiva. Segundo Barros (2021), ao calcular a média dos valores absolutos das diferenças entre os resultados previstos e observados, essa abordagem evita o cancelamento entre erros positivos e negativos, proporcionando uma visão mais realista do desempenho do modelo. Por essa razão, o MAE é útil para mensurar o quanto, em média, as previsões se distanciam dos valores reais, independentemente da direção do erro.

$$MAE = \frac{\sum_{i=1}^n |P_{real,i} - P_{previsto,i}|}{n} \quad (11)$$

2.2.3.3 Erro percentual absoluto médio

Uma métrica amplamente adotada na avaliação de desempenho de previsão é o Erro Percentual Absoluto Médio (*Mean Absolute Percentage Error – MAPE*), especialmente por sua vantagem de ser independente das escalas dos dados. Essa medida expressa o erro em termos percentuais, tornando possível comparar a acurácia de previsões entre séries com diferentes magnitudes. Como apresentado por Montgomery (1976), o cálculo é feito a partir da média das diferenças absolutas entre os valores reais e os previstos, divididas pelos valores reais. Como todos os elementos da série temporal possuem o mesmo peso, os resultados individuais exercem pouca influência insolada, o que torna o MAPE uma métrica prática e robusta para análises comparativas.

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{P_{real,i} - P_{previsto,i}}{P_{real,i}} \right| \times 100 \quad (12)$$

2.2.2.4 Erro quadrático médio

O Erro Quadrático Médio (*Mean Squared Error – MSE*) e conforme Beneventi (2017), essa métrica consiste na média dos quadrados dos desvios entre os valores previstos e observados. Ao elevar os erros ao quadrado, a métrica penaliza discrepâncias maiores de forma mais intensa, aumentando a sensibilidade a outliers e a variações causadas por fatores externos.

$$MSE = \frac{1}{n} \sum_{i=1}^n (P_{previsto,i} - P_{real,i})^2 \quad (13)$$

2.2.2.5 Raiz do erro quadrático médio

A Raiz do Erro Quadrático Médio (*Root Mean Squared Error – RMSE*) é obtida a partir da raiz quadrada do MSE, permitindo que o resultado esteja na mesma unidade dos dados analisados. Essa característica facilita a interpretação dos erros,

ao mesmo tempo em que mantém a penalização maior para desvios mais acentuados (MONTGOMERY, 1976).

$$RMSE = \sqrt{MSE} \quad (14)$$

2.3 Pesquisa operacional no varejo

A pesquisa operacional envolve múltiplas ferramentas valiosas que podem ser utilizadas no varejo, ajudando na otimização de processos e na tomada de decisões estratégicas. Segundo Hillier *et al.* (2013), as técnicas de pesquisa operacional permitem que o setor em questão, resolvam uma variedade de problemas complexos, desde a gestão de estoques até a programação da força de trabalho, utilizando de métodos matemáticos e estatísticos para maximizar eficiência e lucratividade.

Virgilito (2018) destaca que a pesquisa operacional pode ser aplicada na otimização de layouts de lojas, garantindo que o espaço seja utilizado da melhor maneira possível para impulsionar as vendas e melhorar a experiência do cliente. Através da aplicação de modelos matemáticos, os varejistas podem determinar o posicionamento ideal dos produtos e otimizar os fluxos de tráfego dentro das lojas.

Por outro lado, Silva (2023) explora o uso da pesquisa operacional na logística, um dos pilares do varejo. Ele detalha como técnicas como programação linear e otimização em redes podem ser utilizadas para otimizar rotas de entrega e gerenciar cadeias de suprimentos de forma mais eficiente, resultando em redução de custos e tempos de entrega mais rápidos.

Conforme apresentado por Andrade (2015), a importância dos modelos de análise de decisão na pesquisa operacional, permitem aos gestores de redes varejistas avaliar diversas opções estratégicas sob incertezas. Esses modelos ajudam na escolha de estratégias de precificação, promoções e outras decisões de marketing que podem afetar diretamente o desempenho das vendas.

Na visão de Loesch *et al.* (2009), teoria dos jogos e a otimização multicritérios podem ser utilizadas para enfrentar a concorrência e aperfeiçoar a experiência do cliente, ajustando estrategicamente os serviços e produtos oferecidos pelas empresas.

Por fim, a pesquisa operacional não são apenas ferramentas de *back-end* para logística e gerenciamento de estoque, mas também uma parte integrante da estratégia e da tomada de decisões em todas as áreas do negócio de varejo. As diversas técnicas disponíveis na literatura são essenciais para a compreensão das complexidades do mercado e auxiliadoras no desenvolvimento de soluções inovadoras que atendam às demandas dos consumidores.

2.4 Redes Neurais Artificiais

O interesse em RNA (Redes Neurais Artificiais), muitas vezes referidas como “redes neurais”, foi impulsionado desde o início pela compreensão de que o cérebro humano funciona de maneira fundamentalmente diferente de um computador convencional. O cérebro é um sistema de processamento de informações muito complexo, caracterizado por sua natureza não linear e a capacidade de trabalhar em paralelo. Sua capacidade de organizar seus componentes básicos, os neurônios, permite realizar tarefas como recolhimento de padrões, percepção e controle motor com muito mais eficiência do que computadores digitais (Haykin, 2007).

Como afirmado por Remus *et al.* (2001), com dados suficientes, as redes neurais são adequadas para realizar análises preditivas. Essas técnicas se destacam no reconhecimento e previsão de padrões com base no agrupamento dos mesmos. A questão principal é em quais situações as redes neurais tem melhor desempenho do que os modelos tradicionais. Alguns pesquisadores indicam que as redes neurais têm diversas vantagens sobre os métodos estatísticos tradicionais.


Sobre o ponto de vista de Frank *et al.* (2003) *apud* Almeida (2006), na literatura, são apresentados métodos estatísticos de séries temporais, muito utilizados na previsão de demanda. No entanto, como baseiam as previsões de vendas apenas nos seus valores históricos, estes modelos falham quando as tendências de vendas se baseiam em outras variáveis externas, tais como flutuações de preços, publicidades e efeitos dos meios de comunicação. Técnicas mais flexíveis, como redes neurais, permitem melhores análises preditivas.

Seguindo essa linha de raciocínio e como bem apresentando por Remus *et al.* (2001), algumas séries da competição M; em 1982, liderado por Spuros Mkridakis, pesquisadores de todo mundo realizaram comparações entre vários métodos de previsão, portanto os dados da Competição M têm sido muito utilizados desde então.

Algumas dessas séries da Competição M mostraram não linearidade e descontinuidades nos dados de estimativa nos modelos de previsão (Armstrong e Collopy, 1992; Carbone e Makridakis, 1986; Collopy e Armstrong, 1992; Hill, O'Connor e Remus, 1996). Por exemplo, nas series mensais de Hill, O'Connor e Remus (1996), apenas 57% das séries eram lineares; os 43% restantes continham não linearidade ou descontinuidades, ou ambas. Foi comparado o desempenho de modelos de previsão de séries lineares, não lineares e interrompidas. Os pesquisadores descobriram que não linearidades e descontinuidades nos dados de estimativa do modelo afetavam a precisão da previsão das redes neurais. Especificamente, embora as redes neurais geralmente tenham um bom desempenho para todas as séries mensais, elas pareciam ter um desempenho melhor para séries com descontinuidades nos dados estimados.

As redes neurais podem ser exemplificadas de tal forma que muitos neurônios se conectam para formar uma rede, essa rede consiste em uma camada de entrada (*input layer*), uma cada de saída (*output layer*) e possivelmente uma ou mais camadas intermediárias. Estas últimas são chamadas de camadas ocultas (*hidden layer*). Cada camada consiste em vários neurônios e esses neurônios estão conectados próximos. De tal forma que estas redes contemplem muitos neurônios não lineares interagindo, essa técnica pode submeter fenômenos bastantes complexos.

Figura 2 - Neural Networks for Time-Series Forecasting
A neural network



Fonte: Remus (2001).

3 MÉTODOS E TÉCNICAS DE PESQUISA

Quanto a estrutura do trabalho, o texto foi dividido em 5 etapas. Na primeira, denominada introdução, foram apresentados os seguintes tópicos da pesquisa: contextualização introdutória, problema de partida, justificativa e objetivos gerais e específicos. Na segunda parte, foi elaborado o referencial teórico com relação ao tema e suas importâncias, juntamente com variáveis que correspondem com o mesmo. Na terceira etapa foi apresentada a estruturação do trabalho, os métodos e as técnicas de pesquisa. Já na etapa quatro do trabalho, a empresa alvo foi apresentada, os dados selecionados foram expostos, juntamente com resultados obtidos. Foi comparado dados reais com os dados obtidos com as aplicações das técnicas e por fim, dentro do mesmo capítulo, foi apresentado métodos de avaliação das técnicas. Na última etapa do trabalho, foram apresentadas as considerações finais, as limitações deste trabalho, seguido pelas referências bibliográficas.

Quanto à natureza da pesquisa, o presente trabalho teve uma abordagem quantitativa, pois foi levantado os dados referentes as vendas da categoria de eletrodomésticos portáteis, a partir disso a seleção dos produtos em específicos que foram analisados e sobre as vendas desses produtos foram aplicadas as técnicas escolhidas. De acordo com Fonseca (2002) *apud* Gerhardt e Silveira (2009, p.33) “A pesquisa quantitativa recorre à linguagem matemática para descrever as causas de um fenômeno, as relações entre variáveis, etc.”. Sobre isso, através da análise dos resultados obtidos pelas técnicas aplicadas, comparar os dados e interpretar qual técnica de previsão de demanda se adequa melhor aos dados históricos, para prever a demanda de eletrodomésticos portáteis em uma loja de departamento.

Quanto ao objetivo da pesquisa, entende-se como de forma explicativa, pois foi realizado um levantamento de dados e sobre esses dados foram aplicadas diferentes técnicas. De acordo com o resultado de cada técnica, buscou-se compreender a viabilidade de cada uma sobre os dados de estudo, além da comparação de resultados obtidos, com os dados reais apresentado pela empresa em estudo. De acordo com Prodanov e Ernani (2013) o principal objetivo da pesquisa explicativa é aprofundar a compreensão da realidade, manipulando e controlando variáveis para identificar qual variável independente ou fator é a causa da variável dependente no fenômeno estudado, e então analisá-lo em detalhe.

Quanto ao método de pesquisa o trabalho foi enquadrado na tipologia de Modelagem, uma vez que a partir da seleção dos produtos foram aplicadas as técnicas de previsão de demanda: média móvel, suavização exponencial simples, suavização exponencial com tendência e sazonalidade (Holt-Winters) e SARIMA, sobre os dados históricos de vendas. De acordo com Miguel (2012), a modelagem faz o uso de técnicas matemáticas para descrever o funcionamento de um sistema ou parte de um sistema produtivo.

Para tanto, a organização metodológica desta pesquisa seguirá a seguinte sequência:

- I. Selecionar a categoria de produtos dentro do portfólio geral da empresa;
- II. Aplicar a técnica de Curva ABC, a fim de segmentar os produtos que foram utilizados para o estudo do trabalho e plotar os gráficos sobre os dados do histórico de vendas como forma de analisar o comportamento dos dados e afinar ainda mais a quantidade dos produtos que seguiram no estudo;
- III. Executar as técnicas de previsão de demanda: Média Móvel, Suavização Exponencial Simples, Suavização Exponencial com Tendência e Sazonalidade (Holt-Winters) e SARIMA sobre os dados dos produtos selecionados;
- IV. Obter os resultados dos métodos de avaliação através do Erro Absoluto Médio e Raiz do Erro Quadrático Médio;
- V. Comparar a previsão de demanda obtida por cada técnica com os dados reais já realizados pela empresa no período estipulado;
- VI. Analisar e comparar os resultados obtidos através das métricas de avaliação.
- VII. Concluir sobre os desafios propostos.

4 DESENVOLVIMENTO

Nesta seção foi apresentada a empresa alvo desse trabalho, como foram feitas a coleta e seleção dos dados. A partir dos dados selecionados, foi realizada uma análise exploratória e apresentado o comportamento das séries históricas dos produtos escolhidos para o estudo. Ainda nesta seção foi relatado o desenvolvimento da aplicação das técnicas, em seguida foi mostrado os resultados das previsões e por fim, discutido os resultados.

4.1 Empresa alvo

A empresa foco do trabalho é caracterizada como loja de departamentos, sediada na cidade de Londrina e atuante no mercado desde o ano de 2002. Inserida no setor varejista, mais especificamente de cosméticos, higiene, beleza e eletrodomésticos portáteis. O grupo é composto por 29 lojas, divididas em 3 estados: Paraná, Santa Catarina e São Paulo. Há a disposição de um centro de distribuição, focado em produtos importantes que compõem o mix das lojas. Atualmente o grupo interage com mais de 100 fornecedores, e o portfólio das lojas está segmentado em aproximadamente 40 categorias de produtos, totalizando em mais de 30.000 *SKUs* ativos na empresa. Considerando a vasta gama de *SKUs*, este estudo está voltado para uma categoria específica do mix da empresa: elétricos (secadores, modeladores, máquinas de corte, escovas modeladoras, chapas e pranchas). Entende-se que a categoria selecionada é justificada pelo alto valor agregado dos produtos e por trazer boas percepções sobre o comportamento de vendas desses itens.



Fonte: [ikesaki.com.br/elétrico](https://www.ikesaki.com.br/elétrico), 2025.

Nota: Essa imagem é ilustrativa da categoria escolhida e não se trata da empresa escolhida para o estudo.

4.2 Coleta e seleção dos dados

Para a realização deste estudo, os dados utilizados foram extraídos do banco de dados da empresa em análise, que adota o sistema de gestão empresarial (ERP) Consinco, da TOTVS, amplamente utilizado no setor varejista, especialmente por redes de supermercados. Os dados extraídos dizem respeito ao histórico de vendas da categoria de elétricos (eletroportáteis), com foco nos produtos comercializados ao longo dos últimos cinco anos.

A escolha por um período de cinco anos teve como objetivo fornecer uma base robusta e consistente para a aplicação das técnicas de previsão, ao mesmo tempo que possibilitou a análise de padrões sazonais, tendências e flutuações nos dados de vendas. Os dados foram organizados com frequência semanal, considerando duas variáveis principais: unidades vendidas e faturamento. Essa ideia de granular os dados, permitiu uma visão mais detalhada do comportamento da demanda.

Para evitar distorções causadas por produtos com maior tempo de cadastro, que naturalmente acumulam maiores volumes de vendas, foi calculada uma média sobre o faturamento dos itens ao longo desse período, considerando as vendas de cada ano. Essa média serviu como critério para normalizar os dados e garantir uma

seleção mais justa entre produtos mais antigos e mais recente comercializados na rede.

Como etapa prévia da seleção final dos itens, foi aplicada a Curva ABC sobre o portfólio de 113 *SKUs* ativos da categoria, com base no faturamento médio. Conforme demonstrado na tabela 3, a classe A concentrou 25% dos itens (28 produtos), os quais representam 80% do faturamento da categoria, demonstrando alta concentração de valor conforme o princípio de Pareto. A classe B concentrou 23% dos itens (26 produtos), enquanto a classe C acumulou 52% (59 produtos), representando 15% e 5% do faturamento, respectivamente.

Tabela 2: Demonstrativo da classificação ABC da categoria em estudo

Classificação ABC	Quantidade de Itens	Representatividade Itens	Representatividade Faturamento
A	28	25%	80%
B	26	23%	15%
C	59	52%	5%
TOTAL	113	100%	100%

Fonte: Autoria própria (2025)

Dessa forma, com o objetivo de facilitar a aplicação das técnicas, a análise comparativa dos resultados e a discussão dos modelos, foram selecionados cinco produtos representativos da Classe A com um histórico saudável de vendas, sendo 3 secadores e 2 escovas modeladoras. Essa escolha levou em consideração não apenas o faturamento médio, mas também a completude e consistência das séries históricas semanais, evitando produtos com registros espalhados ou inconsistentes. Para a aplicação das técnicas de previsão, foi considerado o período compreendido entre o início de 2022 e o início de 2025, garantindo uma janela temporal suficientemente ampla para capturar padrões sazonais, tendências e comportamentos de mercado relevantes.

É importante ressaltar que, embora o estudo tenha se concentrado em cinco *SKUs*, a metodologia desenvolvida pode ser replicados para qualquer outro item do portfólio da empresa. Todas as etapas dessa primeira fase do trabalho, incluindo extração, tratamento dos dados e aplicação da Curva ABC, foram realizados utilizando a ferramenta *Microsoft Excel*.


4.3 Análise exploratória dos dados

Nesta etapa do trabalho, realizou-se uma análise exploratória das séries temporais semanais dos cinco produtos selecionados. A análise visou compreender o comportamento das vendas ao longo do tempo, identificar padrões como tendências, sazonalidades, picos ou irregularidades, e assim fundamentar a escolha e aplicação das técnicas de previsão.

As séries analisadas referem-se ao período de janeiro de 2022 até maio de 2025, totalizando aproximadamente 180 semanas de observação. Os dados serão expressos em quantidade vendida por semana, e os gráficos foram gerados com o auxílio da linguagem *Python*.

4.3.1 Produto 1


Este item apresentou um comportamento de vendas com alta concentração no primeiro semestre de 2022, seguido de oscilações frequentes e picos eventuais. A série não apresenta uma tendência clara de crescimento ou queda, mas mostra grandes variações semanais, com eventuais picos isolados. A sazonalidade não é evidente, o que pode dificultar a previsão por métodos que dependem desse padrão, conforme apresentado na figura 4.

Figura 4 –Série histórica de vendas produto 1

Fonte: Autoria própria (2025)

4.3.2 Produto 2


A série do produto 2 demonstra um padrão bastante irregular, com diversos períodos de baixa ou nenhuma venda, intercalados com picos significativos, sobretudo no final de 2023 e início de 2024. Há sinais de irregularidades, o que caracteriza uma demanda de baixa previsibilidade. Ainda assim, observa-se uma leve tendência de aumento na frequência dos picos a partir do segundo semestre de 2023, é possível visualizar esses pontos na figura 5, apresentada abaixo.

Figura 5 –Série histórica de vendas produto 2

Fonte: Autoria própria (2025)

4.3.3 Produto 3


Este produto apresenta uma série com alta variabilidade e alguns sinais de sazonalidade anual, especialmente no final dos anos e nos meses de maio de 2022, 2023 e 2024, o que sugere influência de datas promocionais ou períodos sazonais. A sequência de vendas semanais é relativamente estável em termos de presença, com vendas recorrentes, o que torna este um bom candidato para modelos que capturam sazonalidade e tendência. O histórico de vendas do produto está apresentando na figura 6.

Figura 6 –Série histórica de vendas produto 3

Fonte: Autoria própria (2025)

4.3.4 Produto 4

O produto 4 apresentou uma frequência constante de vendas em níveis baixos ao longo do tempo, com um pico expressivo no final de 2023. Apesar do pico, a série é relativamente estável, sem sinais claros de sazonalidade ou tendência significativa. O comportamento pode indicar um produto com demanda moderada e previsível, exceto por eventos pontuais, conforme apresentado na figura 7.


Figura 7 –Série histórica de vendas produto 4

Fonte: Autoria própria (2025)

4.3.5 Produto 5

O produto 5 apresentou vendas crescentes e picos intensos, especialmente entre o segundo semestre de 2023 e o primeiro trimestre de 2024, seguidos de queda gradual. A série é demonstrada na figura 8 e apresenta sinais de sazonalidade e comportamento cíclico, com certa regularidade nos picos, indicando boa adaptabilidade a modelos com componente sazonais.

Figura 8 –Série histórica de vendas produto 5



Fonte: Autoria própria (2025)

4.4 Aplicação das técnicas de previsão

A partir da análise exploratória apresentada na seção anterior, foram identificadas distintas características entre os produtos selecionados, como variabilidade na demanda, presença ou ausência de sazonalidade e diferentes níveis de recorrência nas vendas. Considerando essa diversidade de comportamentos, optou-se por aplicar múltiplas técnicas de previsão de demanda, de modo a comparar o desempenho de abordagens estatísticas tradicionais e métodos baseados em aprendizado de máquina.

As técnicas selecionadas para esse estudo foram: média móvel, suavização exponencial simples (SES), suavização exponencial com tendência e sazonalidade (Holt-Winters) e SARIMA.

Cada técnicas foi implementada utilizando a linguagem de programação Python, por meio de bibliotecas como *statsmodels*, *scikit-learn*, *matplotlib*, entre outras. A série histórica de vendas disponível era composta por dados de 2022, 2023, 2024 e 2025, com o objetivo de gerar previsões para os cinco produtos analisados, no horizonte de janeiro a abril de 2025, com foco principal no resultado na primeira

semana de maio de 2025. Em todas as técnicas utilizadas neste estudo, os dados foram divididos em dois conjuntos:

- Treino: compostos pelas semanas dos anos de 2022, 2023 e 2024.
- Teste: correspondente às semanas de janeiro a abril de 2025.

Essa divisão permite avaliar a capacidade preditiva dos modelos em dados não vistos previamente, simulando uma situação real de previsão futura. Durante o processo, os modelos foram ajustados com base no conjunto de treino e, em seguida, utilizados para prever valores do período de teste. As previsões geradas foram então comparadas com os valores reais efetivamente observados, permitindo mensurar a acurácia dos modelos.

Para cada técnica, foram calculadas as métricas de erro MAE (erro absoluto médio) e RMSE (raiz do erro quadrático médio). A escolha dessas métricas se justifica por sua ampla utilização em problemas de previsão de séries temporais. Enquanto o MAE fornece uma medida direta da média dos erros absolutos, o RMSE penaliza com maior intensidade os erros mais discrepantes, oferecendo uma visão mais sensível à variação dos resíduos. Essa combinação permite avaliar não apenas a precisão média das previsões, mas também a presença de desvios acentuados. Além disso, foi destacada a previsão para a primeira semana de maio de 2025, como um ponto de verificação relevante para a comparação entre os métodos.

4.4.1 Média Móvel

A técnica da média móvel foi aplicada como uma abordagem inicial e de fácil implementação para previsão da demanda semanal dos produtos analisados. Trata-se de um método estatístico que calcula a média de um número fixo de períodos anteriores, suavizando flutuações aleatórias e revelando tendências ou padrões de curto prazo.

Neste estudo, utilizou-se uma janela móvel de 3 semanas, ou seja, a previsão para a semana seguinte foi baseada na média das três semanas imediatamente anteriores. O modelo foi implementado de forma recursiva, o que significa que, a cada

nova previsão realizada, o valor real daquela semana foi incorporado ao conjunto de treino, permitindo a atualização contínua da base de dados.

O procedimento adotado consistiu, inicialmente, no carregamento e organização dos dados semanais, com a conversão da coluna de datas para o formato *datetime* e sua definição como índice da série temporal. Em seguida, os dados foram divididos em dois subconjuntos: um conjunto de treinamento, compreendendo as semanas de 2022, 2023 e 2024, e um conjunto de teste, correspondente às semanas de janeiro a abril de 2025. Para cada ponto do período de teste, foi calculada a média dos três valores imediatamente anteriores, e esse valor foi registrado como previsão. Após cada previsão, o valor real observado foi incorporado à série, permitindo a atualização contínua do modelo. Ao final do processo, foi realizada a previsão específica para a primeira semana de maio de 2025, utilizando como base as três semanas anteriores. Por fim, o desempenho do modelo foi avaliado por meio das métricas MAE e RMSE, e os resultados foram armazenados para comparação com as demais técnicas. O pseudocódigo utilizado para previsões por média móvel está apresentado na figura 9, a seguir.

Figura 9 – pseudocódigo aplicado aos dados para previsões por média móvel

```
## Média Móvel ##
# Importar as bibliotecas
# Carregar os dados do arquivo CSV, com a série histórica de vendas do produto
# Converter coluna "semana" para datetime
# Definir coluna "semana" como índice do DataFrame
# Inferir a frequência dos dados (semanal)
# Definindo os dados em treino e teste
# dados para treino 2022/2023/2024
# dados para teste: janeiro a abril de 2025
# Calcular a média móvel das três últimas semanas anteriores
# Armazenar a previsão
# Atualizar a série com o valor real para manter a recursividade
# Armazenar as previsões em uma série temporal
# Avaliar o modelo com métricas de erro (MAE e RMSE)
# Plotar os dados reais e previstos
```

Fonte: Autoria própria (2025)

4.4.2 Suavização exponencial simples (SES)

A técnica de suavização exponencial simples (SES), é amplamente utilizada em séries temporais com padrão relativamente estável, sendo adequada para casos em que não há presença de tendência nem de sazonalidade. Diferente da média móvel, que atribui pesos iguais aos valores passados, o SES aplica pesos

exponencialmente decrescentes, ou seja, dá maior importância às observações mais recentes. Essa característica permite uma resposta mais rápida a alterações no comportamento da série.

Neste trabalho, o modelo foi implementado de forma recursiva, com o objetivo de simular um ambiente real de previsão contínua, onde novos dados se tornam disponíveis a cada período. A cada semana prevista, o valor real observado foi incorporado à base de treino e teste, atualizando o modelo antes de realizar a próxima previsão.

A aplicação do modelo seguiu os mesmos princípios utilizados na técnica de média móvel, ou seja, os dados foram organizados em frequência semanal e divididos em conjuntos de treino (2022 a 2024) e teste (janeiro a abril de 2025). A principal diferença em relação à média móvel está na forma de cálculo da previsão, que utiliza uma suavização exponencial controlada por um fator de amortecimento (*alfa*), esse parâmetro define o peso das últimas observações mais recentes em relação às anteriores. No presente trabalho, esse valor foi estimado automaticamente pelo próprio modelo, que ajustam o alfa com base na minimização do erro de previsão durante o treinamento. A previsão para a primeira semana de maio de 2025 foi registrada separadamente, e o desempenho do modelo foi avaliado com base nas métricas MAE e RMSE. O pseudocódigo utilizado para previsões por suavização exponencial simples está apresentado na figura 10, a seguir.

Figura 10 – pseudocódigo aplicado aos dados para previsões por SES

```
## Suavização Exponencial Simples ##
# Importar as bibliotecas
# Carregar os dados do arquivo CSV, com a série histórica de vendas do produto
# Converter coluna "semana" para datetime
# Definir coluna "semana" como índice do DataFrame
# Inferir a frequência dos dados (semanal)
# Definindo os dados em treino e teste
  # dados para treino 2022/2023/2024
  # dados para teste: janeiro a abril de 2025
# Ajustar o modelo de suavização exponencial simples com os dados atuais
# Realizar previsão um passo à frente
# Armazenar resultado
# Incorporar o valor real da semana para atualização recursiva
# Construir a série com os valores previstos
# Avaliar o modelo com métricas de erro (MAE e RMSE)
# Plotar os dados reais e previstos
```

Fonte: Autoria própria (2025)

4.4.3 Suavização exponencial com tendência e sazonalidade (Holt-Winters)

O método de Holt-Winters é uma extensão do modelo de Holt, incluindo um terceiro componente, a sazonalidade. Com isso, o modelo se torna mais robusto para séries temporais que apresentam padrões sazonais regulares ao longo do tempo, além de variações de tendência e nível.

Assim como nos modelos anteriores, os dados foram organizados em frequência semanal e divididos entre treino e teste, com previsões recursivas. Durante a calibração do modelo, os três parâmetros de suavização – *alfa* (nível), *beta* (tendência) e *gamma* (sazonalidade) – foram ajustados automaticamente por meio dos recursos de otimização da biblioteca utilizada no código. Além disso, foi definida uma periodicidade sazonal de 52 semanas, considerando a frequência semanal dos dados e possibilidade de sazonalidade anual. A previsão para primeira semana de maio de 2025 foi registrada e o desempenho do modelo foi avaliado com base nas métricas MAE e RMSE, conforme as demais técnicas utilizadas nesse trabalho. O pseudocódigo utilizado para previsões por suavização exponencial com tendência e sazonalidade está apresentado na figura 11, a seguir.

Figura 11 – pseudocódigo aplicado aos dados para previsões por Holt-Winters

```
## Suavização Exponencial com Tendência e Sazonalidade##
# Importar as bibliotecas
# Carregar os dados do arquivo CSV, com a série histórica de vendas do produto
# Converter coluna "semana" para datetime
# Definir coluna "semana" como índice do DataFrame
# Inferir a frequência dos dados (semanal)
# Definindo os dados em treino e teste
# dados para treino 2022/2023/2024
# dados para teste: janeiro a abril de 2025
# Treinar o modelo de Holt-winters com tendência e sazonalidade aditivas
# Prever o resultado da próxima semana
# Garantir que o valor previsto seja ≥ 0
# Adicionar valor real à base para atualizar a previsão recursiva
# Construir série com as previsões
# Avaliar o modelo com métricas de erro (MAE e RMSE)
# Plotar os dados reais e previstos
```

Fonte: Autoria própria (2025)

4.4.4 SARIMA

O modelo SARIMA (*Seasonal Autorregressive Integrated Moving Average*) é uma generalização do modelo ARIMA, que incorpora componentes sazonais além dos termos autorregressivos, de média móvel e de diferenciação. É especialmente indicado para séries temporais que apresentam padrões sazonais e tendências,

permitindo uma modelagem flexível com base em parâmetros ajustáveis para cada uma dessas características. Para este trabalho, os dados semanais foram preparados e divididos entre os conjuntos de treinamento e teste, mantendo a mesma estrutura aplicada nas técnicas anteriores. A modelagem do SARIMA exigiu definição de sete parâmetros:

- (p, d, q) para os componentes não sazonais (autorregressivo, diferença e média móvel);
- (P, D, Q, s) para os componentes sazonais (com $s = 52$, considerando a sazonalidade anual semanal).

A escolha dos melhores parâmetros foi realizada por meio de uma busca em grade, com iteração sobre múltiplas combinações possíveis, restringindo o intervalo de valores para evitar sobre ajuste. A seleção final baseou-se na minimização de critérios de penalização estatística, como o AIC (*Akaike Information Criterion*), que equilibra ajuste do modelo e complexidade.

Com os parâmetros ótimos definidos, o modelo foi ajustado ao conjunto de treinamento, e as previsões foram realizadas de forma direta para o período de teste. A previsão da primeira semana de maio de 2025 foi registrada separadamente, e as previsões geradas foram comparadas com os valores reais observados. O desempenho do modelo foi avaliado com base nas métricas MAE e RMSE. O pseudocódigo utilizado para previsões pelo modelo SARIMA está apresentado na figura 12, a seguir.

Figura 12 – pseudocódigo aplicado aos dados para previsões pelo modelo SARIMA

```

## SARIMA ##
# Importar as bibliotecas
# Função para determinar a melhor ordem sazonal
# Carregar os dados do arquivo CSV, com a série histórica de vendas do produto
# Converter coluna "semana" para datetime
# Definir coluna "semana" como índice do DataFrame
# Inferir a frequência dos dados (semanal)
# Definindo os dados em treino e teste
# dados para treino 2022/2023/2024
# dados para teste: janeiro a abril de 2025
# Definir os intervalos das ordens não sazonal (p, d, q) e sazonal (P, D, Q, S)
# p = q = range(0, 4)
# d = [0, 1, 2]
# P = Q = range(0, 2)
# D = range(0, 2)
# S = [13, 26, 52]
# Realizar a busca em grade
# Ajustar o modelo SARIMA com os melhores parâmetros
# Gerar as previsões para o período de teste (janeiro a abril de 2025)
# Comparar valores previstos com os valores reais no período de teste
# Gerar previsão para a primeira semana de maio de 2025
# Plotar os resultados
# Comparar valor previsto x valor real obtido no período
# Calcular as métricas (MAE e RMSE)
# Exibir os resultados das métricas

```

Fonte: Autoria própria (2025)

4.5 Resultados das previsões

Nesta seção, foram apresentados os resultados obtidos para cada produto, considerando o desempenho das técnicas aplicadas no período de teste (janeiro a abril de 2025). Os gráficos a seguir mostram a série histórica semanal de vendas, as previsões geradas por cada modelo e, em destaque, a previsão para primeira semana de maio de 2025, principal ponto do estudo.

4.5.1 Média móvel


A seguir, serão apresentados os resultados da técnica de Média Móvel.

4.5.1.1 Produto 1

O gráfico do Produto 1, mostra que a técnica aplicada captou parcialmente a tendência geral da série, porém apresentou oscilações abaixo do valor real observado. A previsão para a primeira semana de maio foram 2 unidades, enquanto o valor real de vendas nessa semana foram 5 unidades. Isso indica uma subestimação, por conta

de variações bruscas. As métricas associadas foram MAE = 2.46 e RMSE = 3.09. A seguir, na figura 13, pode-se visualizar tais resultados.

Figura 13 – Resultado da previsão para o produto 1 aplicando-se média móvel




Previsão para a primeira semana de maio de 2025 (Média Móvel): 2
 Valor real para a primeira semana de maio de 2025: 5

Fonte: Autoria própria (2025)

4.5.1.2 Produto 2

Para o produto 2, o modelo apresentou desempenho razoavelmente próximo ao comportamento da série. A previsão para a primeira semana de maio foi de 3 unidades, enquanto o valor real registrado foram 4 unidades vendidas nessa semana. A diferença foi pequena, o que demonstra boa aderência. AS métricas de desempenham foram MAE = 1.59 e RMSE = 2.16, indicando consistência neste caso. A seguir, na figura 14, pode-se visualizar tais resultados.

Figura 14 – Resultado da previsão para o produto 2 aplicando-se média móvel
Previsão de Vendas (Média Móvel)




Previsão para a primeira semana de maio de 2025 (Média Móvel): 3
 Valor real para a primeira semana de maio de 2025: 4

Fonte: Autoria própria (2025)

4.5.1.3 Produto 3

Neste produto, observa-se que o modelo gerou uma previsão significativamente acima do valor real, 14 unidades previstas para a primeira semana de maio, contra 2 unidades, de fato vendidas nesta semana do estudo. Esse desvio foi refletido também nas métricas, com MAE = 15.67 e RMSE = 25.50, indicando que a técnica de Média Móvel não foi adequada para capturar a variabilidade da série, que parece apresentar maior instabilidade. A seguir, na figura 15, pode-se visualizar tais resultados.

Figura 15 – Resultado da previsão para o produto 3 aplicando-se média móvel
Previsão de Vendas (Média Móvel)




Previsão para a primeira semana de maio de 2025 (Média Móvel): 14
Valor real para a primeira semana de maio de 2025: 2

Fonte: Autoria própria (2025)

4.5.1.4 Produto 4

O gráfico referente ao produto 4, revela uma leve superestimação de demanda para a primeira semana de maio, com 6 unidades previstas frente a 3 unidades verdadeiramente vendidas. Apesar disso, o modelo conseguiu acompanhar o padrão geral da série no período de teste. As métricas foram MAE = 2.37 e RMSE = 2.70, o que indica um desempenho relativamente equilibrado. A seguir, na figura 16, pode-se visualizar tais resultados.

Figura 16 – Resultado da previsão para o produto 4 aplicando-se média móvel
Previsão de Vendas (Média Móvel)




Previsão para a primeira semana de maio de 2025 (Média Móvel): 6
Valor real para a primeira semana de maio de 2025: 3

Fonte: Autoria própria (2025)

4.5.1.5 Produto 5

A previsão para o produto 5 foi de 4 unidades para a primeira semana do mês de maio, enquanto o valor real obtido de vendas, foram 5 unidades. O modelo demonstrou uma boa aproximação da realidade, com MAE = 5.17 e RMSE = 6.15, embora o erro absoluto médio seja um pouco elevado, possivelmente reflexo de variações bruscas na série ao longo do tempo. A seguir, na figura 17, pode-se visualizar tais resultados.

Figura 17 – Resultado da previsão para o produto 5 aplicando-se média móvel
Previsão de Vendas (Média Móvel)



Previsão para a primeira semana de maio de 2025 (Média Móvel): 4
Valor real para a primeira semana de maio de 2025: 5

Fonte: Autoria própria (2025)


4.5.2 Suavização exponencial simples (SES)

A seguir, serão apresentados os resultados da técnica de Suavização Exponencial Simples (SES).

4.5.2.1 Produto 1

No produto 1, a previsão gerada para a primeira semana de maio de 2025 foi de 2 unidades, frente a um valor real de 5 unidades vendidas, o que demonstra uma leve subestimação do modelo. O erro médio absoluto (MAE) foi de 2.26, enquanto a raiz do erro quadrático médio (RMSE) ficou em 2.83, indicando desempenho satisfatório no acompanhamento das flutuações da série. A seguir, na figura 18, pode-se visualizar tais resultados.

Figura 18 – Resultado da previsão para o produto 1 aplicando-se SES
Previsão de Vendas (Suavização Exponencial Simples)



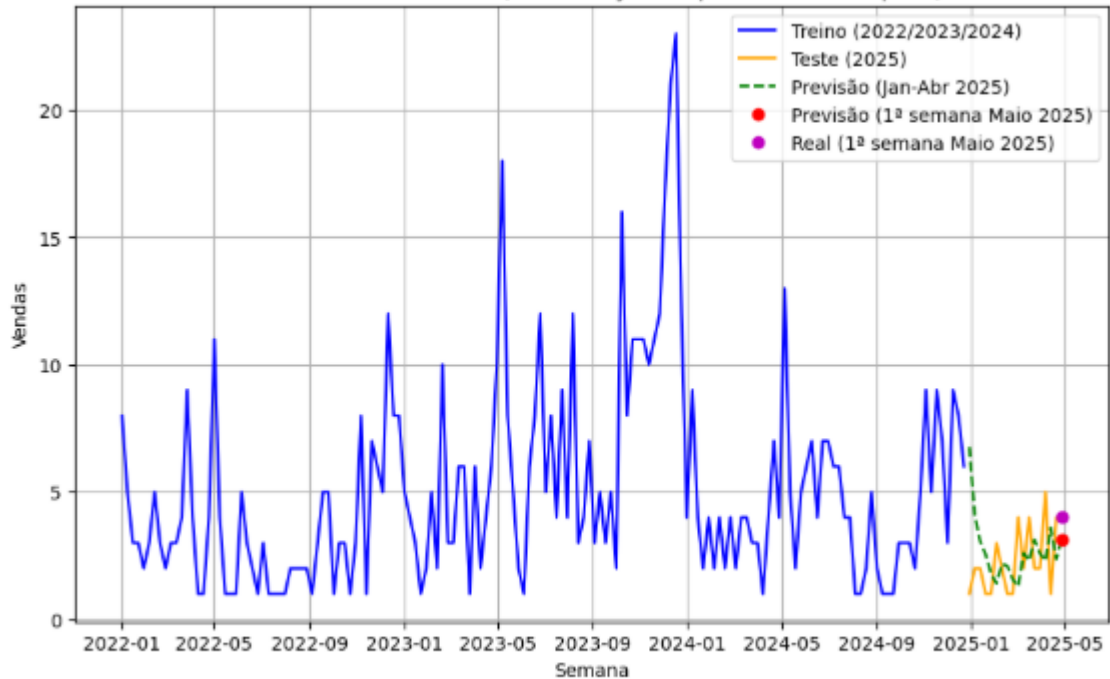
Previsão para a primeira semana de maio de 2025 (SES): 2
 Valor real para a primeira semana de maio de 2025: Vendas 5

Fonte: Autoria própria (2025)

4.5.2.2 Produto 2

Para o produto 2, a previsão gerada para a primeira semana de maio foi de 3 unidades, contra um valor real de vendas de 4 unidades. O modelo apresentou um bom ajuste as variações observadas durante o período de teste, resultando em MAE de 1.62 e RMSE de 2.85, o que representa um desempenho consistente e com baixo erro. A seguir, na figura 19, pode-se visualizar tais resultados.

Figura 19 – Resultado da previsão para o produto 2 aplicando-se SES
Previsão de Vendas (Suavização Exponencial Simples)




Previsão para a primeira semana de maio de 2025 (SES): 3
 Valor real para a primeira semana de maio de 2025: Vendas 4

Fonte: Autoria própria (2025)

4.5.2.3 Produto 3

O produto 3 apresentou maior dificuldade de modelagem com a técnica SES. A previsão para a primeira semana de maio foi de 22 unidades, enquanto o valor de fato obtido, foi de apenas 2 unidades, resultando em um desvio expressivo. Isso se refletiu nos valores de erro, MAE = 13.46 e RMSE = 22.46, apontando que o modelo teve dificuldades em lidar com picos e quedas mais abruptas dessa série. A seguir, na figura 20, pode-se visualizar tais resultados.

Figura 20 – Resultado da previsão para o produto 3 aplicando-se SES
Previsão de Vendas (Suavização Exponencial Simples)




Previsão para a primeira semana de maio de 2025 (SES): 22
 Valor real para a primeira semana de maio de 2025: Vendas 2

Fonte: Autoria própria (2025)

4.5.2.4 Produto 4

No caso do produto 4, a previsão realizada foi de 5 unidades para a primeira semana de maio, porém a quantidade verdadeiramente vendida desse produto, foram 3 unidades. A diferença foi pequena, e os valores de erro permaneceram controlados, MAE = 2.25 e RMSE = 2.56, evidenciando um bom desempenho da técnica neste caso. A seguir, na figura 21, pode-se visualizar tais resultados.

Figura 21 – Resultado da previsão para o produto 4 aplicando-se SES
Previsão de Vendas (Suavização Exponencial Simples)




Previsão para a primeira semana de maio de 2025 (SES): 5
 Valor real para a primeira semana de maio de 2025: Vendas 3

Fonte: Autoria própria (2025)

4.5.2.5 Produto 5

Para o produto 5, o modelo obteve um acerto exato na previsão para primeira semana de maio de 2025, com 5 unidades previstas e também 5 unidades registrada. Ainda assim, ao longo do período de teste, ocorreram algumas discrepâncias, refletidas em um MAE = 4.33 e RMSE = 5.38. A seguir, na figura 22, pode-se visualizar tais resultados.

Figura 22 – Resultado da previsão para o produto 5 aplicando-se SES
Previsão de Vendas (Suavização Exponencial Simples)



Previsão para a primeira semana de maio de 2025 (SES): 5
 Valor real para a primeira semana de maio de 2025: Vendas 5

Fonte: Autoria própria (2025)


4.5.3 Suavização exponencial com tendência e sazonalidade (Holt-Winters)

A seguir, serão apresentados os resultados da técnica de Suavização exponencial com tendência e sazonalidade (Holt-Winters).

4.5.3.1 Produto 1

O primeiro produto apresentou uma previsão abaixo do valor real para a primeira semana de maio, com uma previsão de 1 unidade contra 5 unidades efetivamente vendidas. As métricas de erro MAE = 3.79 e RMSE = 4.84 indicam uma performance moderada, com variação perceptível no período de teste. A seguir, na figura 23, pode-se visualizar tais resultados.

Figura 23 – Resultado da previsão para o produto 1 aplicando-se Holt-Winters
Previsão de Vendas (Holt-Winters Recursivo)




Previsão para a primeira semana de maio de 2025 (Holt-Winters): 1
 Valor real para a primeira semana de maio de 2025: 5

Fonte: Autoria própria (2025)

4.5.3.2 Produto 2

No caso do produto 2, o modelo gerou uma previsão de 7 unidades para a primeira semana de maio, próximo ao valor real de 4 unidades. As métricas de erro foram relativamente baixas, $MAE = 1.58$ e $RMSE = 2.01$, demonstrando que o modelo teve um bom desempenho ao capturar a sazonalidade e o padrão de vendas. A seguir, na figura 24, pode-se visualizar tais resultados.

Figura 24 – Resultado da previsão para o produto 2 aplicando-se Holt-Winters
Previsão de Vendas (Holt-Winters Recursivo)




Previsão para a primeira semana de maio de 2025 (Holt-Winters): 7
 Valor real para a primeira semana de maio de 2025: 4

Fonte: Autoria própria (2025)

4.5.3.3 Produto 3

Para o produto 3, o modelo superestimou significativamente a demanda, com uma previsão de 35 unidades para a primeira semana de maio, frente a apenas 2 unidades vendidas. Isso resultou em erros elevados, MAE = 13.88 e RMSE = 22.10, sugerindo dificuldade em lidar com os picos isolados e a variabilidade da série. A seguir, na figura 25, pode-se visualizar tais resultados.

Figura 25 – Resultado da previsão para o produto 3 aplicando-se Holt-Winters
Previsão de Vendas (Holt-Winters Recursivo)




Previsão para a primeira semana de maio de 2025 (Holt-Winters): 35
 Valor real para a primeira semana de maio de 2025: 2

Fonte: Autoria própria (2025)

4.5.3.4 Produto 4

O produto 4 teve desempenho mais estável, com uma previsão de 6 unidades na primeira semana de maio, contra 3 unidades reais. As métricas de erro, $MAE = 1.68$ e $RMSE = 2.16$ refletem um ajuste razoável e consistente durante o período de teste. A seguir, na figura 26, pode-se visualizar tais resultados.

Figura 26 – Resultado da previsão para o produto 4 aplicando-se Holt-Winters
Previsão de Vendas (Holt-Winters Recursivo)




Fonte: Autoria própria (2025)

4.5.3.5 Produto 5

O produto 5 apresentou uma previsão de 12 unidades para a primeira semana de maio, enquanto o valor obtido foi de 5 unidades. Apesar dessa diferença, o modelo teve um desempenho intermediário, com MAE = 8.21 e RMSE = 10.47, sugerindo que conseguiu acompanhar as flutuações da série, embora com variações de picos. A seguir, na figura 27, pode-se visualizar tais resultados.

Figura 27 – Resultado da previsão para o produto 5 aplicando-se Holt-Winters
Previsão de Vendas (Holt-Winters Recursivo)



Fonte: Autoria própria (2025)


4.5.4 SARIMA (*Seasonal Autoregressive Integrated Moving Average*)

A seguir, serão apresentados os resultados da técnica de previsão, SARIMA.

4.5.4.1 Produto 1

Para o primeiro produto, o modelo previu 7 unidades para a primeira semana de maio, enquanto o valor real registrado foi de 5 unidades. Apesar da proximidade, o modelo apresentou variações em outras semanas do período de teste, o que resultou em um erro médio absoluto MAE = 4,42 e um erro quadrático médio RMSE = 5,39. A seguir, na figura 28, pode-se visualizar tais resultados.

Figura 28 – Resultado da previsão para o produto 1 aplicando-se o método SARIMA
Previsão de Vendas (SARIMA)




Previsão para a primeira semana de maio de 2025: 7.0
Valor real para a primeira semana de maio de 2025: 5

Fonte: Autoria própria (2025)

4.5.4.2 Produto 2

No caso do produto 2, a previsão foi de 3 unidades para a primeira semana de maio, com um valor real de vendas de 4 unidades, revelando uma boa aproximação. O modelo se ajustou bem ao padrão da série no período de teste, alcançando os menores erros entre os produtos, com um MAE = 2.09 e RMSE = 2.48. A seguir, na figura 29, pode-se visualizar tais resultados.

Figura 29 – Resultado da previsão para o produto 2 aplicando-se o método SARIMA
Previsão de Vendas (SARIMA)




Previsão para a primeira semana de maio de 2025: 3.0
Valor real para a primeira semana de maio de 2025: 4

Fonte: Autoria própria (2025)

4.5.4.3 Produto 3

Para o produto 3, houve uma discrepância significativa entre o previsto e o realizado, enquanto o modelo previu 22 unidades para a primeira semana de maio, o valor real obtido foi de apenas 2 unidades. Essa superestimação afetou negativamente o desempenho, refletindo em MAE = 13.68 e RMSE = 23.04, indicando que o modelo teve dificuldade em capturar quedas abruptas na demanda. A seguir, na figura 30, pode-se visualizar tais resultados.

Figura 30 – Resultado da previsão para o produto 3 aplicando-se o método SARIMA
Previsão de Vendas (SARIMA)




Previsão para a primeira semana de maio de 2025: 22.8
Valor real para a primeira semana de maio de 2025: 2

Fonte: Autoria própria (2025)

4.5.4.4 Produto 4

No caso do produto 4, a previsão foi de 5 unidades na primeira semana de maio, com o valor real sendo 3 unidades vendidas nesta semana do estudo. Essa leve diferença, associada a uma boa performance geral no reste, resultou em MAE = 3.63 e RMSE = 4.16, valores que demonstram um desempenho satisfatório do modelo. A seguir, na figura 31, pode-se visualizar tais resultados.

Figura 31 – Resultado da previsão para o produto 4 aplicando-se o método SARIMA
Previsão de Vendas (SARIMA)




Fonte: Autoria própria (2025)

4.5.4.5 Produto 5

Por fim, o produto 5 teve uma previsão de 0 unidade para a primeira semana de maio, contra um valor de fato de vendas de 5 unidades, o que indica uma subestimação significativa. Com isso, o modelo obteve MAE = 13.10 e RMSE = 11.92, sendo os piores desempenho entre os cinco produtos testados, evidenciando limitações na captura da sazonalidade e da volatilidade da série. A seguir, na figura 32, pode-se visualizar tais resultados.

Figura 32 – Resultado da previsão para o produto 5 aplicando-se o método SARIMA
Previsão de Vendas (SARIMA)



Previsão para a primeira semana de maio de 2025: 0.0
Valor real para a primeira semana de maio de 2025: 5

Fonte: Autoria própria (2025)

4.6 Discussão dos resultados

Após a aplicação das quatro técnicas de previsão, média móvel, suavização exponencial simples (SES), suavização exponencial com tendência e sazonalidade (Holt-Winters) e SARIMA, para os cinco produtos analisados, foi possível identificar diferenças relevantes no desempenho de cada modelo em função das características apresentadas em cada série temporal.

Um primeiro aspecto observado está na capacidade dos modelos de prever corretamente o valor da primeira semana de maio de 2025, que foi utilizado como referência de comparação entre os modelos preditivos. Dentre os vinte cenários (cinco produtos x quatro técnicas), apenas um modelo, para um produto, acertou corretamente o valor observado: produto 5, técnica de suavização exponencial simples. Isso demonstra que, mesmo séries conhecidas, ou seja, com um bom histórico de dados, a previsão da demanda é dificilmente garantida, conforme apresentado resumidamente na tabela 3 a seguir.

Tabela 3 - Previsão VS Realizado: primeira semana de maio de 2025

Previsto x Realizado										
Produto / Técnica	Produto 1		Produto 2		Produto 3		Produto 4		Prouto 5	
	Previsto	Real	Previsto	Real	Previsto	Real	Previsto	Real	Previsto	Real
Média Móvel	2	5	3	4	14	2	6	3	4	5
SES	2	5	3	4	22	2	5	3	5	5
Holt-Winters	1	5	7	4	35	2	6	3	12	5
SARIMA	7	5	3	4	22	2	5	3	0	5

Fonte: Aatoria própria (2025)

A análise de métricas de erros complementa a avaliação de acurácia. O erro absoluto médio (MAE) e o erro quadrático médio (RMSE), revelam que os modelos apresentaram desempenhos distintos entre os produtos. Quando tais métricas foram analisadas, nota-se que o produto 2 obteve os menores erros, ou seja, a menor média, tanto para a métrica MAE quanto para a métrica RMSE. É possível considerar que a série temporal desse produto apresenta uma certa tendência observável, picos de vendas nos meses de maio e dezembro e quedas após esses períodos. No caso do produto que apresentou as piores métricas de erro, foi o produto 3. Observa-se que as médias para as métricas MAE e RMSE para esse produto são muito elevadas, superior a duas vezes o produto com a segunda pior média, o produto 5. Esses valores destoados podem ser justificados por outliers, visivelmente mostrados no histórico de dados dos produtos.

O modelo de suavização exponencial com tendência e sazonalidade (Holt-Winters), destacou-se ao apresentar os menores erros absolutos e quadráticos. Para o produto 2 e produto 4, o modelo apresentou resultados consistentes, apesar de superestimar as previsões, quando comparada com o valor real obtido. Esse desempenho sugere que a técnica lida bem com séries que apresentam tendência suave e certo grau de sazonalidade regular, como foi observado nestes produtos. O possível motivo do erro de previsão, pode estar na questão da disponibilidade de estoque nas lojas naquela semana.

Já o modelo SARIMA, apesar de ser mais robusto e apropriado para séries com comportamento sazonal e ruídos, apresentou desempenho irregular. Embora tenha alcançado bons resultados nos produtos 2 e 4, com baixos erros, falhou em capturar padrões de queda brusca em séries mais instáveis. Esse comportamento indica que o SARIMA, embora tecnicamente sofisticado, é sensível a oscilações fora do padrão ou mudanças abruptas na série.

O método de média móvel, por sua vez, teve desempenho limitado em séries com maior volatilidade. Por exemplo, apresentou os maiores erros entre todos os modelos no produto 3 (MAE = 15.67 e RMSE = 25.50), evidenciando que a simplicidade do modelo pode não ser suficiente para capturar flutuações complexas.

A suavização exponencial simples (SES) apresentou desempenho equilibrado, com valores das métricas de erros, consistentemente baixos para alguns produtos. Sua estrutura baseada em um único parâmetro de suavização, mostrou-se eficaz para séries estáveis, mas limitada quando confrontada com padrões de sazonalidade mais complexas. A seguir, na tabela 4 e 5, é possível observar os valores dos erros obtidos por cada métrica, MAE e RMSE, juntamente com suas respectivas médias: por produto e por técnicas.

Tabela 4 - Valores obtidos pela métrica: MAE

Métrica: MAE						
Técnica / Produto	Produto 1	Produto 2	Produto 3	Produto 4	Prouto 5	Média Técnica
Média Móvel	2.46	1.59	15.67	2.37	5.17	5.45
SES	2.26	1.62	13.46	2.25	4.33	4.78
Holt-Winters	3.79	1.58	13.88	1.68	8.21	5.83
SARIMA	4.42	2.03	13.68	3.63	10.13	6.78
Média Produto	3.23	1.71	14.17	2.48	6.96	

Fonte: Autoria própria (2025)

Tabela 5 - Valores obtidos pela métrica: RMSE

Métrica: RMSE						
Técnica / Produto	Produto 1	Produto 2	Produto 3	Produto 4	Prouto 5	Média Técnica
Média Móvel	3.09	2.16	25.50	2.70	6.15	7.92
SES	2.83	2.05	22.46	2.56	5.38	7.06
Holt-Winters	4.84	2.01	22.1	2.16	10.47	8.32
SARIMA	5.31	2.47	23.05	4.16	11.92	9.38
Média Produto	4.02	2.17	23.28	2.90	8.48	

Fonte: Autoria própria (2025)

Em uma visão geral, o modelo de suavização exponencial mostrou o melhor equilíbrio entre simplicidade e performance, uma vez que o modelo acertou uma previsão e obteve a menor média de erros entre os produtos, quando comparada com as demais técnicas. O modelo de Holt-Winters, teve resultados satisfatórios para séries mais suaves, especialmente nos produtos com tendencia e leve sazonalidade.

Já a média móvel, embora simples, mostrou-se frágil diante de séries com maiores oscilações. Por fim, o SARIMA demonstrou potencial, mas sua performance variou significativamente conforme a complexidade da séries.

Conforme apresentado, os resultados evidenciam a necessidade de adequação entre modelo e padrão da série temporal. Não há um modelo universalmente superior, cada técnicas possui pontos forte e limitações, sendo a escolha ideal aquela que melhor se adapta à estrutura e à volatilidade dos dados disponíveis.

5 CONCLUSÃO

Este trabalho teve como objetivo analisar e comparar o desempenho de diferentes técnicas de previsão de demanda aplicadas a séries temporais semanais de vendas de cinco produtos distintos, em lojas de departamento, mais especificamente produtos da categoria de eletroportáteis. Os métodos avaliados foram: média móvel, suavização exponencial simples (SES), Holt-Winters e SARIMA. Todos os modelos foram implementados utilizando a linguagem Python e aplicados ao horizonte de previsão entre janeiro e abril de 2025, com atenção especial para previsão pontual da primeira semana de maio, utilizada como referência para comparações.

Em decorrer do estudo, notou-se que as séries temporais analisadas apresentaram comportamentos bastantes distintos entre si. Visivelmente, todas as séries apresentaram muitos picos e vales, evidenciando que quando as lojas bem abastecidas e possivelmente produtos com rebaixe de preço, podem fazer com que as vendas aumentem de forma significativa. Por outro lado, os vales presentes nas séries, diz respeito a possível falta de produtos em algumas lojas, após um pico de demanda fora do padrão. De fato, alguns produtos revelaram padrões mais suaves e regulares, outros apresentaram grande volatilidade, o que ampliou a complexidade da tarefa de modelagem e previsão. Essa diversidade de comportamentos foi determinante para o desempenho das técnicas, visto que cada modelo possui pressupostos e capacidades diferentes para capturar padrões de tendência, sazonalidade e ruído.

Neste trabalho, a estratégia da divisão dos dados em conjuntos de treino e teste foi fundamental para validar a capacidade preditiva dos modelos. O conjunto de treino, formado pelos dados de 2022 a 2024, permitiu que os modelos aprendessem os padrões históricos de cada série. Já o conjunto de teste, correspondente ao início de 2025, possibilitou avaliar se essas previsões se mantinham precisas ao serem aplicadas em um período futuro, o que não havia sido utilizado na etapa de modelagem. A utilização das métricas de erro, ofereceu uma base sólida para comparar o desempenho quantitativo entre as técnicas, complementando a análise visual dos gráficos de previsão. Além disso, a observação das previsões específicas para a primeira semana de maio permitiu identificar o grau de aprovação prática de

cada modelo quando comparada a realidade de vendas, fortalecendo as análises qualitativas.

De modo geral, a suavização exponencial simples se destacou pelo bom desempenho diante da simplicidade de sua estrutura, registrando os menores erros médio entre os produtos e acertando a previsão pontual em um dos casos. O modelo de Holt-Winters também apresentou resultados consistentes, especialmente em séries que apresentavam comportamento mais regular, com tendência e leve padrão sazonal. As técnicas de média móvel, apesar de sua aplicação simples e intuitiva, mostrou-se menos eficaz em séries com flutuações mais intensas, evidenciando limitações em cenários mais dinâmicos. Por fim, o SARIMA, embora seja um modelo estatisticamente mais complexo, apresentou variações importantes de desempenho conforme a complexidade e o nível de ruído das séries analisadas, o que comprometeu sua precisão em alguns produtos.

Conclui-se, portanto, que a utilização de mais de uma técnica de previsão de demanda, mostra-se extremamente essencial e coerente para análises e comparações de resultados, permitindo um leque maior de opções de escolha. A decisão do modelo de previsão deve estar diretamente alinhada às características do comportamento da série temporal. Modelos mais simples podem ser altamente eficazes em séries regulares, enquanto modelos mais complexos devem ser aplicados com cautela, exigindo maior atenção ao ajuste de parâmetros e à estabilidade dos dados. Ainda, destaca-se a importância de manter um processo contínuo de validação e reavaliação dos modelos adotados, considerando que o ambiente de vendas pode sofrer alterações constantes provocadas por fatores sazonais, ações promocionais, mudanças de mercado ou comportamento do consumidor, gerando a falta de estoque e impactando diretamente na constância da série.

A presente pesquisa abre oportunidade para trabalhos futuros, de modo que a incorporação de variáveis externas como, preços, campanhas promocionais ou eventos sazonais, poderiam enriquecer o poder explicativo das previsões. Além disso, abre espaço para a aplicação de modelos mais avançados baseados em aprendizado de máquina, capazes de capturar relações não lineares e realizar ajustes mais dinâmicos. Um ponto de melhoria importante refere-se ao tratamento das séries temporais antes da modelagem, especialmente no que diz respeito à identificação e correção de outliers, como picos pontuais de vendas que podem distorcer a performance dos modelos. A aplicação de técnicas de limpeza e normalização dos

dados pode contribuir para aumentar a robustez das previsões e reduzir erros indesejados. Em suma, a aplicação prática das técnicas abordadas demonstrou que métodos estatísticos, quando bem selecionados e validados, podem ser ferramentas valiosas para o planejamento comercial e a tomada de decisões mais assertivas no contexto varejista.

6 REFERÊNCIAS

ACKERMANN, Andres, E. F., et al. **Métodos de previsão de demanda: uma revisão da literatura**. Innovar. vol 32(85). p. 83-89. Disponível em: <https://doi.org/10.15446/innovar.v32n85.100979>. Acesso em: 03 ago. 2024

AGUIAR, Evanilson Da Costa. Análise de gestão de estoque em uma empresa de varejo de pequeno porte em Itacoatiara-AM por meio da curva ABC. **Trabalho conclusão de curso – UFMA**. Itacoatiara, 2023. 34 p. Disponível em: https://riu.ufam.edu.br/bitstream/prefix/6779/5/TCC_EvanilsodaCostaAguiar.pdf. Acesso em: 13 abr. 2024.

ALMEIDA, Fernando Carvalho de et al. Previsão de vendas no varejo por meio de redes neurais. **Revista de Administração**, v. 41, n. 3, 2006. p. 1. Disponível <https://www.revistas.usp.br/rausp/article/view/44404>. Acesso em: 28 abr. 2024.

ANDRADE, Eduardo Leopoldino de. **Introdução à pesquisa operacional: métodos e modelos para análise de decisões**. [recurso eletrônico]. 5. ed. Rio de Janeiro: LTC, 2015.

ARAÚJO, Monique Gomes de. et al. Aplicação do ciclo PDCA na elaboração de um plano estratégico e implementação da Curva ABC como ferramenta de suporte para o gerenciamento de estoques de uma distribuidora de alimentos hospitalares. **Revista Espacios**, v. 37, n.13, 2016. p. 1. Disponível em: <https://www.revistaespacios.com/a16v37n13/16371301.html>. Acesso em: 21 abr. 2024.

BALLOU, Ronald H. **Gerenciamento da cadeia de suprimentos/logística empresarial**. [recurso eletrônico]. 5. ed. Porto Alegre: Bookman, 2007. p. 239-270.

BARROS, Anna Carolina. et al. **Análise de séries temporais em R: curso introdutório**. [recurso eletrônico]. 1. ed. Rio de Janeiro: Elsevier: FGV IBRE, 2018. p. 129-149.

BARROS, Renan da Silva. Revisão dos modelos de previsão de demanda e controle de estoques em uma empresa varejista. **Trabalho de formatura – Poli-USP**. São Paulo 2021. 110 p. Disponível em: <https://bdta.abcd.usp.br/item/003095837> Acesso em: 14 abr. 2024.

BENEVENTI, Bruno Rafael Falavigna. Previsão de demanda: Estudo de caso em uma indústria alimentícia do estado de São Paulo. **Dissertação apresentada como requisito parcial à obtenção do título de Mestre em Engenharia de Produção-UNIARA**. Araraquara-SP, 2017. 141 p. Disponível em: <https://www.uniara.com.br/arquivos/file/ppg/engenharia-producao/producao-intelectual/dissertacoes/2017/bruno-rafael-falavigna-beneventi.pdf>. Acesso em: 28 abr. 2024.

BOWERSOX, Donald J. et al. **Gestão logística da cadeia de suprimentos**. [recurso eletrônico]. 4. ed. Porto Alegre: AMGH, 2014. p. 85-103. p. 159-199.

CHIAVENATO, Idalberto. **Gestão de materiais: uma abordagem introdutória.** [recurso eletrônico]. 4. ed. Barueri: Atlas, 2022. 153 p.

CHING, Hong Yuh. **Gestão de estoques na cadeia de logística integrada – Supply Chain.** [recurso eletrônico]. 4. ed. São Paulo: Atlas, 2010. p. 14-38.

CHOPRA, Sunil; MEINDL, Peter. **Gerenciamento da cadeia de suprimentos – estratégia, planejamento e operações.** 1. ed: Pearson, 2003.

CORRÊA, Henrique Luiz. **Administração de cadeias de suprimentos e logística: integração na era da Indústria 4.0.** [recurso eletrônico]. 2. ed. São Paulo: Atlas, 2019. p. 213-248.

DIAS, Marco Aurélio P. **Administração de materiais: princípios, conceitos e gestão.** [recurso eletrônico]. 7. ed. Barueri: Atlas, 2023. 393 p.

FRANCO JUNIOR, E. F. Modelo para previsão de demanda ativa e reativa utilizando técnicas de seleção de entradas e redes neurais artificiais. **Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Faculdade de Engenharia Elétrica e de Computação da Universidade Estadual de Campinas - UNICAMP.** Campinas, 2013. 137 p. Disponível em: <https://doi.org/10.47749/T/UNICAMP.2013.916907>. Acesso em: 03 ago. 2024

GERHARD, Tatiana Engel; SILVEIRA, Denise Tolfo. **Métodos de pesquisa.** Porto Alegre: UFRGS, 2009. p. 33.

GRANT, David B. **Gestão de logística e cadeia de suprimentos.** [recurso eletrônico]. 1. ed. São Paulo: Saraiva, 2013. p. 123-146

HALMENSCHLAGER, D. M. Aplicação de técnicas de previsão de demanda e gestão de estoques em um hospital público de ensino superior. **Dissertação submetida ao Programa de Pós-Graduação Mestrado Profissional em Engenharia de Produção da Universidade Federal do Rio Grande do Sul - UFRGS.** Porto Alegre, 2022. 82 p. Disponível em: <https://lume.ufrgs.br/handle/10183/241926>. Acesso em: 03 ago. 2024.

HAYKIN, Simon. **Redes neurais: princípios e prática.** [recurso eletrônico]. 2. ed. Porto Alegre: Bookman, 2007. p. 27-74.

HILLIER, Frederick S. et. al. **Introdução à pesquisa operacional.** [recurso eletrônico]. 9. ed. Porto Alegre: AMGH, 2013.

JACOBS, F. Robert. et al. **Administração de operações e da cadeia de suprimentos.** [recurso eletrônico]. 13. ed. Porto Alegre: AMGH, 2012. p. 452-491. p. 518-553.

JERONIMO, André et al. Planejamento e controle de estoques: um fator competitivo em micro e pequenas empresa. **XL Encontro Nacional de Engenharia de Produção.** Foz do Iguaçu, 2020. 13 p. Disponível em: https://abepro.org.br/biblioteca/TN_STO_343_1758_39863.pdf. Acesso em: 14 abr. 2024.

LOESCH, Claudio et. al. **Pesquisa operacional: fundamentos e modelos**. [recurso eletrônico]. 1. ed. São Paulo, 2009.

MICHEL, Júlia de Souza Silva. Previsão de demanda no mercado online brasileiro: Estudo comparativo entre dois modelos lineares. **Dissertação apresentada como requisito parcial à obtenção do título de Mestre em Gestão de Organizações, Liderança e Decisão - UFPR**. Curitiba, 2022. 80 p. Disponível em: https://bdtd.ibict.br/vufind/Record/UFPR_239de2823d8886edc8d39542565ee37a. Acesso em: 21 abr. 2024.

MIGUEL, Paulo Augusto Cauchick, et al. **Metodologia de pesquisa para engenharia e gestão de operações** [recurso eletrônico]. Rio de Janeiro: Elsevier: ABEPRO, 2012. p. 65-66.

MONTGOMERY, D. C. et al. **Forecasting and time series analysis**. New York: McGraw-Hill, 1976.

MORETTIN, Pedro A. et al. **Análise de séries temporais**. [recurso eletrônico]. 3. ed. São Paulo: Blucher, 2018. p. 111-142.

NUNES, Vagner Teodoro. Aplicação de técnicas de previsão de demanda e gestão de estoques em uma empresa misturadora de fertilizantes. **Dissertação submetida ao Programa de Pós-Graduação Mestrado Profissional em Engenharia de Produção – UFRGS**. Porto Alegre, 2019. 72 p. Disponível em: <https://lume.ufrgs.br/handle/10183/200093>. Acesso em: 21 abr. 2024.

PELLEGRINI, Fernando Rezende. Metodologia para implementação de sistemas de previsão de demanda. **Dissertação submetida ao Programa de Pós-Graduação Mestrado Profissional em Engenharia de Produção – UFRGS**. Porto Alegre, 2000. 130 p. Disponível em: <http://www.producao.ufrgs.br/arquivos/publicacoes/Fernando%20R%20Pellegrini.pdf>. Acesso em: 21 abr. 2024.

POZO, Hamilton. **Logística e gerenciamento da cadeia de suprimentos: uma introdução**. [recurso eletrônico]. 2. ed. São Paulo: Atlas, 2019. p. 36.

PRODANOV, Cleber Cristiano; FREITAS, Ernani Cesar de. **Metodologia do Trabalho Científico: métodos e técnicas da pesquisa e do trabalho acadêmico**. 2. ed. Novo Hamburgo: Feevale, 2013. p. 52-60.

REMUS, William. et. al. **Neural Networks for Time-Series Forecasting**. In: **Armstrong, J.S. (eds) Principles of Forecasting. International Series in Operations Research & Management Science**. vol. 30. Boston: Springer Science + Business Media New York, 2001.

RIBEIRO, Guilherme Fernando. Classificação de métodos de previsão de demanda para novos produtos: Estudo no sistema brasileiro de franquias. **Dissertação apresentada como requisito parcial à obtenção do título de Mestre em Engenharia de Produção - UTFPR**. Ponta Grossa, 2016. 171 p. Disponível em: https://riut.utfpr.edu.br/jspui/bitstream/1/2299/1/PG_PPGEP_M_Ribeiro%2c%20Guilherme%20Fernando_2016.pdf. Acesso em: 21 abr. 2024.

SILVA, Adriano Maniçoba da. **Pesquisa operacional aplicada à logística**. [recurso eletrônico]. 1. ed. Rio de Janeiro: Alta Books, 2023.

SLACK, Nigel. **Administração da produção**. [recurso eletrônico]. 8. ed. São Paulo: Atlas, 2020. p. 512.

TRISTÃO, Pamela Amado et al. Gestão de estoque de uma empresa do ramo de entretenimento: proposta de uma curva ABC. **REMIPE – Revista de micro e pequenas empresas e empreendedorismo da Fatec Osasco**, v. 7, n.2, set. 2021. Disponível em:

<https://remipe.fatecosasco.edu.br/index.php/remipe/article/view/275/229>. Acesso em: 20 abr. 2024.

TUBINO, Dalvio Ferrari. **Planejamento e controle da produção: teoria e prática**. [recurso eletrônico]. 3. ed. São Paulo: Atlas, 2017. p. 25-56.

VIRGILLITO, Salvatore Benito. **Pesquisa operacional**. [recurso eletrônico]. 1. ed. São Paulo: Saraiva Educação, 2018.

ZANCHETTIN, Fabio. Seleção de amostras de auditoria: lei de Benford e curva ABC. **Trabalho de conclusão final apresentando ao programa de pós-graduação mestrado profissional em administração pública em rede nacional – UFMS**. Mato Grosso do Sul, 2018. 77 p. Disponível em:

<https://sigpos.ufms.br/portal/trabalho-arquivos/download/8004>. Acesso em: 21 abr. 2024.



**Presidência da República
Casa Civil
Subchefia para Assuntos Jurídicos**

LEI Nº 9.610, DE 19 DE FEVEREIRO DE 1998¹.

Altera, atualiza e consolida a legislação sobre direitos autorais e dá outras providências.

O PRESIDENTE DA REPÚBLICA Faço saber que o Congresso Nacional decreta e eu sanciono a seguinte Lei:

Título I - Disposições Preliminares

Art. 1º Esta Lei regula os direitos autorais, entendendo-se sob esta denominação os direitos de autor e os que lhes são conexos.

Art. 2º Os estrangeiros domiciliados no exterior gozarão da proteção assegurada nos acordos, convenções e tratados em vigor no Brasil.

Parágrafo único. Aplica-se o disposto nesta Lei aos nacionais ou pessoas domiciliadas em país que assegure aos brasileiros ou pessoas domiciliadas no Brasil a reciprocidade na proteção aos direitos autorais ou equivalentes.

Art. 3º Os direitos autorais reputam-se, para os efeitos legais, bens móveis.

Art. 4º Interpretam-se restritivamente os negócios jurídicos sobre os direitos autorais.

Art. 5º Para os efeitos desta Lei, considera-se:

I - publicação - o oferecimento de obra literária, artística ou científica ao conhecimento do público, com o consentimento do autor, ou de qualquer outro titular de direito de autor, por qualquer forma ou processo;

II - transmissão ou emissão - a difusão de sons ou de sons e imagens, por meio de ondas radioelétricas; sinais de satélite; fio, cabo ou outro condutor; meios óticos ou qualquer outro processo eletromagnético;

III - retransmissão - a emissão simultânea da transmissão de uma empresa por outra;

IV - distribuição - a colocação à disposição do público do original ou cópia de obras literárias, artísticas ou científicas, interpretações ou execuções fixadas e fonogramas, mediante a venda, locação ou qualquer outra forma de transferência de propriedade ou posse;

V - comunicação ao público - ato mediante o qual a obra é colocada ao alcance do público, por qualquer meio ou procedimento e que não consista na distribuição de exemplares;

VI - reprodução - a cópia de um ou vários exemplares de uma obra literária, artística ou científica ou de um fonograma, de qualquer forma tangível, incluindo qualquer armazenamento permanente ou temporário por meios eletrônicos ou qualquer outro meio de fixação que venha a ser desenvolvido;

VII - contrafação - a reprodução não autorizada;

VIII - obra:

a) em co-autoria - quando é criada em comum, por dois ou mais autores;

b) anônima - quando não se indica o nome do autor, por sua vontade ou por ser desconhecido;

c) pseudônima - quando o autor se oculta sob nome suposto;

d) inédita - a que não haja sido objeto de publicação;

e) póstuma - a que se publique após a morte do autor;

f) originária - a criação primígena;

g) derivada - a que, constituindo criação intelectual nova, resulta da transformação de obra originária;

h) coletiva - a criada por iniciativa, organização e responsabilidade de uma pessoa física ou jurídica, que a publica sob seu nome ou marca e que é constituída pela participação de diferentes autores, cujas contribuições se fundem numa criação autônoma;

i) audiovisual - a que resulta da fixação de imagens com ou sem som, que tenha a finalidade de criar, por meio de sua reprodução, a impressão de movimento, independentemente dos processos de sua captação, do suporte usado inicial ou posteriormente para fixá-lo, bem como dos meios utilizados para sua veiculação;

IX - fonograma - toda fixação de sons de uma execução ou interpretação ou de outros sons, ou de uma representação de sons que não seja uma fixação incluída em uma obra audiovisual;

X - editor - a pessoa física ou jurídica à qual se atribui o direito exclusivo de reprodução da obra e o dever de divulgá-la, nos limites previstos no contrato de edição;

XI - produtor - a pessoa física ou jurídica que toma a iniciativa e tem a responsabilidade econômica da primeira fixação do fonograma ou da obra audiovisual, qualquer que seja a natureza do suporte utilizado;

XII - radiodifusão - a transmissão sem fio, inclusive por satélites, de sons ou imagens e sons ou das representações desses, para recepção ao público e a transmissão de sinais codificados, quando os meios de decodificação sejam oferecidos ao público pelo organismo de radiodifusão ou com seu consentimento;

XIII - artistas intérpretes ou executantes - todos os atores, cantores, músicos, bailarinos ou outras pessoas que representem um papel, cantem, recitem, declamem, interpretem ou executem em qualquer forma obras literárias ou artísticas ou expressões do folclore.

Art. 6º Não serão de domínio da União, dos Estados, do Distrito Federal ou dos Municípios as obras por eles simplesmente subvencionadas.

¹ Disponível em: http://www.planalto.gov.br/ccivil_03/leis/19610.htm.