

UNIVERSIDADE DO PLANALTO CATARINENSE – UNIPLAC  
UNIVERSIDADE DO CONTESTADO – UNC  
UNIVERSIDADE DO EXTREMO SUL CATARINENSE – UNESC  
UNIVERSIDADE DA REGIÃO DE JOINVILLE – UNIVILLE  
PROGRAMA DE PÓS-GRADUAÇÃO EM SISTEMAS PRODUTIVOS - PPGSP

**MATHEUS LEANDRO FERREIRA**

**INTELIGÊNCIA ARTIFICIAL APLICADA NA PREVISÃO DE DEMANDA EM SUPERMERCADOS**

CRICIÚMA/SC  
2024

**MATHEUS LEANDRO FERREIRA**

## **INTELIGÊNCIA ARTIFICIAL APLICADA NA PREVISÃO DE DEMANDA EM SUPERMERCADOS**

Dissertação de Mestrado, vinculada ao Programa de Pós-graduação em Sistemas Produtivos – PPGSP em forma associativa entre UNIPLAC, UNC, UNESC e UNIVILLE, como requisito parcial para obtenção do título de Mestre(a) em Sistemas Produtivos.

**Orientador(a):** Prof. Dr. Rogério Antônio Casagrande

**Coorientador(a):** Prof(a) Dr(a) Mari Aurora Favero Reis

CRICIÚMA/SC

2024

Ficha Catalográfica

F383i Ferreira, Matheus Leandro  
Inteligência artificial aplicada na previsão de demanda em supermercados / Matheus leandro Ferreira ; orientador Dr. Rogério Antônio Casagrande ; coorientadora Dra. Mari Aurora Favero Reis. – 2024.  
74 f. ; 30 cm.

Dissertação (Mestrado em Sistemas Produtivos) – Programa de Pós-Graduação em Sistemas Produtivos em forma associativa entre a Universidade do Planalto Catarinense ; Universidade do Contestado ; Universidade do Extremo Sul Catarinense ; Universidade da Região de Joinville. Lages, SC, 2024.

1. Previsão de demanda. 2. Controle de estoque. 3. Machine learning. 4. Supermercados. 5. Eficiência operacional. I. Casagrande, Rogério Antônio (orientador). II. Reis, Mari Aurora Favero (coorientadora). III. Universidade do Planalto Catarinense. IV. Universidade do Contestado. V. Universidade do Extremo Sul Catarinense VI. Universidade da Região de Joinville. VII. Programa de Pós-Graduação em Sistemas Produtivos. VIII. Título.

CDD 658.5

Catálogo na fonte – Biblioteca Central

**FOLHA DE APROVAÇÃO**  
**MATHEUS LEANDRO FERREIRA**

**INTELIGÊNCIA ARTIFICIAL APLICADA NA PREVISÃO DE DEMANDA EM SUPERMERCADOS**

A Comissão Examinadora, abaixo assinada, aprova a **Dissertação** apresentada no Programa de Pós-Graduação em Sistemas Produtivos – PPGSP, Linha de Pesquisa Gestão e Conhecimento em Sistemas Produtivos, em forma associativa entre a Universidade do Planalto Catarinense – UNIPLAC, a Universidade do Contestado – UNC, a Universidade do Extremo Sul Catarinense – UNESC e a Universidade da Região de Joinville - UNIVILLE, como requisito parcial para obtenção do título de **Mestre em Sistemas Produtivos**.

Banca Examinadora

Documento assinado digitalmente  
 **ROGERIO ANTONIO CASAGRANDE**  
Data: 17/12/2024 15:48:59-0300  
Verifique em <https://validar.iti.gov.br>

---

Prof. Dr. Rogério Antônio Casagrande – PPGSP / UNESC  
Presidente da Banca / Orientador

Documento assinado digitalmente  
 **MARI AURORA FAVERO REIS**  
Data: 17/12/2024 16:45:54-0300  
Verifique em <https://validar.iti.gov.br>

---

Prof. Dra. Mari Aurora Favero Reis – PPGSP / UNC  
Coorientadora

Documento assinado digitalmente  
 **Cristian Cechinel**  
Data: 17/12/2024 16:14:22-0300  
CPF: \*\*\*.628.449-\*\*  
Verifique as assinaturas em <https://v.ufsc.br>

---

Prof. Dr. Cristian Cechinel - PPGTIC/UFSC  
Membro externo da banca

Documento assinado digitalmente  
 **MARCELO LEANDRO DE BORBA**  
Data: 17/12/2024 16:21:30-0300  
Verifique em <https://validar.iti.gov.br>

---

Prof. Dr. Marcelo Leandro de Borba – PPGSP / UNIVILLE  
Membro interno da banca

Lages, SC, 17 de dezembro de 2024

## DEDICATÓRIA

A caminhada acadêmica é, em muitos sentidos, um esforço compartilhado. Cada etapa, desafio e conquista traz consigo a presença de pessoas que, direta ou indiretamente, contribuíram para que este momento fosse possível. Dedico este trabalho àqueles que sempre acreditaram e me incentivaram a persistir, especialmente minha esposa Vanessa Rocha Alexandre e meus filhos Lucas e Giovanna, que foram minha fonte de energia e inspiração ao longo dessa jornada. Aos meus pais, Marilea de Oliveira Ferreira e Manoel Edson Ferreira, que me ensinaram o valor do esforço e da dedicação. Que este trabalho seja uma homenagem a todos que fizeram parte deste sonho.

## AGRADECIMENTOS

Primeiramente, à minha família, que sempre foi a base sólida de apoio incondicional e incentivo constante. Aos meus pais, Marilea de Oliveira Ferreira e Manoel Edson Ferreira, que sempre estiveram ao meu lado, incentivando cada passo e motivando minha busca pelo conhecimento e aperfeiçoamento. À minha esposa, Vanessa Rocha Alexandre, e aos meus filhos, Lucas e Giovanna Ferreira, por sua paciência e compreensão em todos os momentos de ausência, oferecendo amor e apoio, fundamentais para a conclusão desta jornada. Às minhas irmãs, Milla Lucia Ferreira e Alessandra Ferreira Guimarães, que, com seus exemplos e inspirações, reforçaram minha determinação na carreira acadêmica e como professor na Universidade do Extremo Sul Catarinense (Unesc).

Quero expressar minha gratidão ao Bernardo Effiting pela oportunidade de desenvolver estudos aplicados na área de automação para supermercados, possibilitando uma aplicação prática e enriquecedora para minha pesquisa. Ao meu parceiro na empresa, Josué Diniz Lourenço, cuja expertise e parceria foram essenciais para o sucesso do projeto.

Aos meus orientadores, Prof. Dr. Rogério Antônio Casagrande e Profa. Dra. Mari Aurora Favero Reis, minha profunda gratidão pela orientação cuidadosa e sábia ao longo deste processo. Suas dedicações, conhecimentos e constantes incentivos foram indispensáveis para a concretização deste trabalho. Também agradeço aos membros da banca examinadora dos seminários do programa PPGSP: Prof. Dr. Silvio Parodi Oliveira Camilo, Profa. Dr. Fernanda Cristina Silva Ferreira, Prof. Dr. Vilson Menegon Bristot e Prof. Dr. Adriano Michael Bernardin, cujas contribuições e observações enriqueceram profundamente minha dissertação. Em nome deles, expresso meu reconhecimento a todos os mestres e doutores do programa, que, com sua excelência, contribuíram para o meu desenvolvimento acadêmico.

Por fim, meus sinceros agradecimentos aos coordenadores do PPGSP, Dra. Cristina Keiko Yamaguchi e Prof. Dr. Kristian Madeira, cuja liderança e compromisso foram essenciais para que este projeto se tornasse realidade. Agradeço também às instituições associadas ao programa – Universidade do Planalto Catarinense (UNIPLAC), Universidade do Contestado (UNC), Universidade do Extremo Sul Catarinense (UNESC) e Universidade da Região de Joinville (UNIVILLE) – e à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), pelo suporte e incentivo ao desenvolvimento científico.

## RESUMO

FERREIRA, Matheus Leandro. **INTELIGÊNCIA ARTIFICIAL APLICADA NA PREVISÃO DE DEMANDA EM SUPERMERCADOS** (2024), 130 f. Dissertação (Mestrado em Sistemas Produtivos). Programa de Pós-graduação em Sistemas Produtivos – PPGSP em forma associativa entre a Universidade do Planalto Catarinense – UNIPLAC, da Universidade do Contestado – UNC, da Universidade do Extremo Sul Catarinense – UNESC e da Universidade da Região de Joinville – UNIVILLE, Lages, 2024.

A previsão de demanda é essencial na gestão de estoques, especialmente no setor varejista, onde a precisão é fundamental para equilibrar oferta e demanda. Em supermercados, a diversidade de produtos e a variabilidade nas preferências do consumidor tornam o controle de inventário um desafio constante. O objetivo central é investigar a eficácia de diferentes métodos de previsão de demanda aplicados com inteligência artificial na gestão de estoques em supermercados, buscando identificar a abordagem mais precisa e eficiente. Este estudo explora métodos quantitativos, aplicados com inteligência artificial para previsão de demanda, com a aplicação de técnicas de Média Móvel Simples, Ponderada e Exponencial, além de projeções de tendências e modelos avançados de Machine Learning. O estudo é realizado com dados de vendas de um supermercado específico no Sul de Santa Catarina, abordando demandas variáveis. A pesquisa segue uma abordagem quantitativa e dedutiva, combinando análises estatísticas com a aplicação de técnicas de Machine Learning. A coleta de dados incluiu séries históricas de vendas do supermercado, categorização de produtos com a Curva ABC e implementação de modelos preditivos treinados para simular o reabastecimento de produtos. A análise comparativa entre métodos foi baseada em métricas como o Desvio Médio Absoluto e o Erro Médio Quadrático. Os métodos ponderados apresentaram maior precisão em cenários de alta variabilidade de demanda. Além disso, os modelos de Machine Learning mostraram-se eficazes para previsão em contextos de alta complexidade. A integração dos modelos aumentou a precisão das previsões, favorecendo a otimização do reabastecimento e redução de custos, com impacto positivo na eficiência operacional. O estudo contribui para a gestão de estoques no setor varejista ao identificar métodos preditivos que podem melhorar o controle de inventário, reduzir desperdícios e atender melhor a demanda. As limitações incluem a dependência de dados históricos e a necessidade de um alto poder computacional para treinar os modelos de Machine Learning. Como desdobramento, sugere-se a expansão para outros setores do varejo e a inclusão de variáveis econômicas e comportamentais para melhorar ainda mais as previsões.

**Palavras-chave:** Previsão de demanda; Gestão de estoques; Machine Learning; Supermercados; Eficiência operacional.

## ABSTRACT

FERREIRA, Matheus Leandro. . **INTELIGÊNCIA ARTIFICIAL APLICADA NA PREVISÃO DE DEMANDA EM SUPERMERCADOS** (2024), 130 f. Dissertação (Mestrado em Sistemas Produtivos). Programa de Pós-graduação em Sistemas Produtivos – PPGSP em forma associativa entre a Universidade do Planalto Catarinense – UNIPLAC, da Universidade do Contestado – UNC, da Universidade do Extremo Sul Catarinense – UNESC e da Universidade da Região de Joinville – UNIVILLE, Lages, 2024.

Demand forecasting is essential in inventory management, particularly in the retail sector, where accuracy is critical to balancing supply and demand. In supermarkets, the wide range of products and variability in consumer preferences make inventory control a constant challenge. This study investigates the effectiveness of various demand forecasting methods using artificial intelligence to improve inventory management in supermarkets, aiming to identify the most accurate and efficient approach. It covers quantitative methods, including Simple, Weighted, and Exponential Moving Averages, trend projections, and advanced Machine Learning models. The study uses sales data from a specific supermarket in Southern Santa Catarina to address variable demand patterns. Adopting a quantitative and deductive approach, the research combines statistical analyses with Machine Learning techniques. Data collection involved historical sales series, product categorization via the ABC Curve, and the implementation of predictive models trained to simulate product replenishment. A comparative analysis between methods was conducted using metrics such as Mean Absolute Deviation and Mean Squared Error. Weighted methods demonstrated greater accuracy in high-demand variability scenarios, while Machine Learning models proved effective in forecasting within complex environments. The integration of these models enhanced forecast accuracy, supporting optimized replenishment and cost reduction, with a positive impact on operational efficiency and customer satisfaction. This study contributes to retail inventory management by identifying predictive methods that can improve inventory control, reduce waste, and better align supply with demand. Limitations include dependency on historical data and the substantial computational resources required for training Machine Learning models. Future research may explore applications in other retail sectors and incorporate economic and behavioral variables to further enhance prediction accuracy.

**Keywords:** Demand forecasting; Inventory management; Machine Learning; Supermarkets; Operational efficiency.

## LISTA DE FIGURAS

Figura 1 <i>Representação da interdisciplinaridade sobre o tema</i> .....	19
Figura 2 <i>Gráfico de Ilustração da curva ABC</i> .....	26
Figura 3 <i>Métodos de Previsão de demanda</i> .....	29
Figura 4 <i>Fluxograma para Implementação de LLM</i> .....	35
Figura 5 <i>Design da Metodologia da pesquisa</i> .....	37
Figura 6 <i>Fluxograma das etapas da pesquisa</i> .....	40
Figura 7 <i>Demanda Real do Produto OLEO DE SOJA COAMO PET 900ML em 2023</i> .....	51
Figura 8 <i>Comparativo em relação a demanda real</i> .....	56
Figura 9 <i>Fluxograma para os processos de tratamento dos dados</i> .....	57

## LISTA DE TABELAS

Tabela 1 <i>Classificação da Curva ABC</i> .....	24
Tabela 2 <i>Classificação ABC de Produtos</i> .....	25
Tabela 3 <i>Teoria de Pareto aplicado nos Departamentos</i> .....	47
Tabela 4 <i>Vendas anuais agrupadas por departamento</i> .....	48
Tabela 5 <i>Teoria de Pareto aplicado nos produtos do departamento mercearia seca</i> .....	49
Tabela 6 <i>Visão do desempenho mensal de vendas em 2023</i> .....	50
Tabela 8 <i>Aplicação da Média Móvel Ponderada no ano de 2023</i> .....	52
Tabela 9 <i>Aplicação da Média Móvel Exponencial no ano de 2023</i> .....	53
Tabela 10 <i>Aplicação da Projeção de Tendências no ano de 2023</i> .....	54
Tabela 11 <i>Comparativo dos métodos de projeção no ano de 2023 em relação a demanda real</i> .....	55
Tabela 12 <i>Métricas DMA e EMQ</i> .....	61
Tabela 13 <i>Resultado da análise comparativa entre previsão real x sugerida</i> .....	63
Tabela 14 <i>Detalhamento estatístico com quatro métodos diferentes</i> .....	64

## LISTA DE ABREVIATURAS E SIGLAS

ABC Curva para Classificação de Estoque

BI Business Intelligence

DMA Desvio Médio Absoluto

EMQ Erro Médio Quadrático

GPT Generative Pre-trained Transformer

LLM Large Language Model

ML Machine Learning

## SUMÁRIO

<b>1 INTRODUÇÃO</b> .....	<b>13</b>
1.1 PROBLEMA.....	14
1.2 OBJETIVOS.....	15
<b>1.2.1 Objetivo geral</b> .....	15
<b>1.2.2 Objetivos específicos</b> .....	15
1.3 JUSTIFICATIVA .....	16
<b>1.3.1 Inserção social da pesquisa</b> .....	17
1.4 CARACTERIZAÇÃO INTERDISCIPLINAR E ADERÊNCIA AO PROGRAMA .....	18
1.5 ESTRUTURA GERAL DO DOCUMENTO .....	20
<b>2 PANORAMA TEÓRICO</b> .....	<b>22</b>
2.1 MERCADO VAREJISTA .....	22
2.2 GESTÃO DE ESTOQUE .....	23
2.3 CURVA ABC DE PRODUTOS .....	24
2.4 GESTÃO DE DEMANDA.....	26
2.4.1 Previsão de Demanda .....	28
2.4.2 Métodos de Previsão de Demanda.....	28
2.4.3 Média Móvel Simples.....	29
2.4.4 Média Móvel Ponderada .....	30
2.4.5 Média Móvel Exponencial.....	30
2.4.5 Projeção de Tendencias .....	31
2.5 Aplicação de Modelos de Linguagem na Previsão de Demanda .....	32
2.5.1 Relevância dos LLM na Previsão de Demanda.....	33
2.5.2 Metodologia para Implementação de LLM .....	34
<b>3 METODOLOGIA DA PESQUISA</b> .....	<b>37</b>
3.1 ABORDAGEM, OBJETIVOS, PROCEDIMENTOS E TÉCNICAS DE PESQUISA.....	37
3.2 DELIMITAÇÃO DO ESTUDO .....	38
A seguir são apresentadas a descrição do local e população em estudo, bem como as etapas para a elaboração da pesquisa.....	38
<b>3.2.1 Descrição do local e população em estudo</b> .....	39
<b>3.2.2 Etapas da pesquisa</b> .....	39
3.3 PROCESSO DE COLETA DE DADOS .....	41
3.3.1 Seleção do departamento.....	41
3.3.2 Coleta dos dados históricos de vendas.....	42

3.3.3 Tratamento e organização dos dados.....	42
3.3.4 Classificação dos Produtos com Curva ABC.....	42
3.3.5 Métodos de previsão de demanda .....	42
3.3.6 Treinamento da Inteligência Artificial .....	42
3.3.7 Análise comparativa.....	43
3.4 PROCESSO DE ANÁLISE DE DADOS .....	43
3.4.1 Compreensão Inicial dos Dados.....	43
3.4.2 Identificação de Padrões e Correlações.....	44
3.4.3 Modelagem Estatística e Predição.....	44
3.4.4 Análise de Sensibilidade.....	44
3.4.5 Comparação das Previsões dos Modelos .....	44
3.4.6 Implementação e Testes do Plugin GPT-4 .....	44
<b>4 RESULTADOS E DISCUSSÃO .....</b>	<b>46</b>
4.1 ACHADOS CIENTÍFICOS .....	<b>Erro! Indicador não definido.</b>
4.1.1 Escolha do departamento.....	46
4.1.2 históricos de vendas .....	48
4.1.3 Seleção do Produto estudado.....	49
4.1.4 Detalhamento dos Métodos de previsão de demanda .....	51
4.1.5 Treinamento da Inteligência Artificial .....	57
4.1.6 Comparação das Previsões dos Modelos .....	60
4.1.7 Implementação e Testes do Plugin GPT-4 .....	62
4.2 APLICABILIDADE DO ESTUDO.....	65
<b>5 CONSIDERAÇÕES FINAIS OU CONCLUSÕES.....</b>	<b>67</b>
<b>REFERÊNCIAS .....</b>	<b>69</b>

## 1 INTRODUÇÃO

Em um ambiente empresarial, cada vez mais competitivo e globalizado, a capacidade de responder de maneira ágil e eficiente às demandas do mercado torna-se um diferencial estratégico para empresas do setor varejista. Neste cenário, a gestão de estoques assume uma posição de destaque, atuando como um elo crítico entre a satisfação do cliente e a sustentabilidade financeira da empresa. A complexidade desta gestão é acentuada no contexto de supermercados, onde a diversidade de produtos e a rapidez das mudanças de preferências dos consumidores exigem um equilíbrio preciso entre oferta e demanda (Xi & Sha, 2014).

A previsão de demanda é marcada por desafios inerentes à sua natureza incerta. Supermercados, em particular, enfrentam dificuldades adicionais devido à vasta gama de produtos e à influência de fatores sazonais e promocionais, que podem alterar significativamente os padrões de compra. As tecnologias tradicionais de previsão de demanda muitas vezes falham em capturar a complexidade e variabilidade das demandas no varejo, sugerindo a necessidade de abordagens mais sofisticadas e adaptativas (Zhu et al., 2015)

Avanços em inteligência artificial e aprendizado de máquina oferecem novas perspectivas para a previsão de demanda no varejo. A exploração do uso de dados de compra dos clientes para a classificação e previsão de demanda indica que modelos baseados em classificação podem levar a uma gestão de estoques mais eficiente ao adaptar as decisões de inventário às tendências de consumo identificadas (Bala & Xavier, 2013).

A gestão eficaz de estoques em supermercados não se limita apenas à precisão das previsões de demanda, mas também à capacidade de integrar essas previsões em sistemas de planejamento e reposição de estoques que sejam flexíveis e responsivos. A complexidade de gerenciar produtos com demanda intermitente, onde picos de demanda são seguidos por períodos de demanda zero ou baixa, apresenta um desafio particular. Sillanpää e Liesiö (2018) demonstram que modelar a demanda do consumidor com distribuições, em vez de usar estimativas pontuais, resulta em uma melhoria significativa na precisão das previsões de pedidos de reposição para produtos com demanda baixa e intermitente. Este avanço metodológico oferece uma nova perspectiva para otimizar a gestão de estoques em supermercados, enfatizando a importância de abordagens de previsão mais sofisticadas e adaptativas.

A aplicação de diferentes modelos de *Machine Learning* (ML) para a previsão de demanda na gestão da cadeia de suprimentos tem sido objeto de análise comparativa recente. Modelos como o *Perceptron* Multicamadas (MLP), Redes Neurais Convolucionais (CNN) e Redes de Memória de Longo e Curto Prazo (LSTM) têm sido explorados por sua capacidade de lidar com a complexidade e a temporalidade dos dados de demanda. Essa análise comparativa revela a eficiência desses modelos

avançados em contextos específicos de previsão de demanda, destacando a importância de selecionar a abordagem mais adequada com base nas características específicas dos dados e dos objetivos de previsão (Singha & Panse, 2022).

Além disso, a revisão da literatura sobre o uso de *Machine Learning* em previsão de demanda mostra a diversidade de técnicas disponíveis, desde análises de séries temporais até métodos baseados em regressão e modelos supervisionados e não supervisionados. Esta revisão também destaca o desempenho comparativo dessas técnicas, com modelos como LSTM mostrando resultados notáveis, embora com um tempo de computação mais elevado. A exploração de métodos de regressão e modelos híbridos surge como campos promissores para pesquisas futuras, oferecendo novas direções para aprimorar a precisão da previsão de demanda (Farzana & Prakash, 2020).

Portanto, a necessidade de métodos de previsão de demanda mais precisos e adaptáveis é evidente, assim como a importância de integrar essas previsões em um sistema de gestão de estoques eficiente. Este estudo busca contribuir para essa área, oferecendo uma análise comparativa de diferentes métodos de previsão de demanda para identificar o mais assertivo. Em seguida, uma inteligência artificial foi treinada utilizando esses métodos, com explicações detalhadas sobre sua aplicação, para proporcionar a previsão mais precisa possível aos demais produtos do departamento estudado. Espera-se que isso não apenas avance o conhecimento acadêmico sobre previsão de demanda e gestão de estoques, mas também ofereça dados práticos para o setor varejista, potencialmente resultando em melhorias significativas na eficiência operacional, redução de custos e aumento da satisfação do cliente.

## 1.1 PROBLEMA

No dinâmico contexto empresarial atual, a gestão eficiente de estoques se destaca como um elemento crucial para empresas, especialmente no setor varejista, que buscam manter sua competitividade. A complexidade desta gestão é amplificada no ambiente de supermercados, onde a diversidade de produtos e a rápida mudança nas preferências dos consumidores exigem um equilíbrio preciso entre oferta e demanda. A previsão de demanda, servindo como base para a gestão de estoques, enfrenta desafios significativos devido à sua natureza incerta, impactando diretamente a situação empresarial (Emmett, 2005; Krajewski et al., 2007; Muller, 2003; Stevenson, 2017). Uma previsão precisa é essencial para um planejamento eficaz do inventário, favorecendo as operações empresariais (Xi & Sha, 2014).

Apesar da ampla discussão na literatura sobre a importância e as múltiplas funções dos estoques no âmbito empresarial, identifica-se uma lacuna significativa relacionada à falta de uma abordagem clara e consensual para conceituar e analisar os problemas inerentes à gestão de

estoques. Essa lacuna se manifesta particularmente na ausência de um método abrangente e amplamente aceito para a identificação e análise dos desafios de gerenciamento de estoques, apesar da existência de abordagens específicas focadas em problemas isolados, como a previsão de demanda e a otimização da cadeia de suprimentos (Costantino et al., 2014; Masoud & Mason, 2016)

A falta de um método claro para lidar com os problemas de gerenciamento de estoques pode resultar em ineficiências significativas, prejuízos financeiros e insatisfação dos clientes. A gestão de estoques desempenha um papel crucial na manutenção do equilíbrio entre oferta e demanda, na satisfação do cliente e na redução de custos operacionais. Portanto, a abordagem científica e o uso do método científico são fundamentais para abordar essas lacunas de pesquisa, permitindo o desenvolvimento de sistemas automatizados baseados em métodos estatísticos e técnicas de previsão para a tomada de decisões (Huafei, 2011; Vaz et al., 2020).

Neste contexto, o presente estudo busca situar-se teoricamente dentro do campo da gestão de estoques, explorando, por meio de um estudo de caso, as lacunas identificadas e investigando como diferentes métodos de previsão de demanda podem influenciar as decisões de reabastecimento na cadeia de suprimentos de supermercados. A pergunta de pesquisa que norteia esta dissertação é:

Qual método de previsão de demanda, com suporte em inteligência artificial, apresenta maior assertividade para a tomada de decisão no reabastecimento de estoques em supermercados?

## 1.2 OBJETIVOS

### 1.2.1 Objetivo geral

Investigar a eficácia de diferentes métodos de previsão de demanda aplicados com inteligência artificial na gestão de estoques em supermercados.

### 1.2.2 Objetivos específicos

1. Descrever os conceitos fundamentais da gestão de estoque e previsão de demanda;
2. Classificar os métodos de previsão de demanda utilizados na gestão de estoque;
3. Comparar a precisão e confiabilidade dos métodos de previsão de demanda em supermercados;
4. Propor um modelo de previsão de demanda adequado para gestão de estoque em um supermercado.

### 1.3 JUSTIFICATIVA

A falta de um método claro para lidar com os problemas de gerenciamento de estoques pode levar a ineficiências que afetam negativamente as empresas e, também, a sociedade como um todo. A gestão ineficiente de estoque pode resultar em desperdício de recursos, aumento dos custos de produção e transporte, além de impactos ambientais não desejáveis devido ao descarte inadequado de produtos. Para alcançar os objetivos da empresa, os administradores devem utilizar uma variedade de modelos de gestão disponíveis para o seu setor empresarial. Diversos processos podem ser considerados, como a análise ABC, revisão contínua, *just-in-time* e outros métodos relevantes, que, quando aplicados corretamente, podem se tornar um diferencial competitivo para a organização (Silva et al., 2021).

Para superar esses desafios, é crucial que os gestores de estoque busquem conhecimento e se atualizem sobre os métodos administrativos eficazes e adequados para o seu setor. É essencial entender a natureza das operações de estoque, bem como as melhores práticas de gestão. A precisão das previsões de vendas e o viés nas decisões de inventário e produção podem ter efeitos significativos na gestão do estoque, sugerindo que os gestores operacionais muitas vezes desconsideram o valor das previsões de vendas, optando, em vez disso, por confiar em seus próprios dados históricos. No entanto, a precisão das previsões de vendas melhorou após a desagregação das previsões, com melhorias correspondentes na estabilidade do plano de produção (Brueggen et al., 2014).

Atualmente, muitos gestores de estoque enfrentam dificuldades significativas, pois os profissionais nem sempre sabem quais métodos administrativos devem ser utilizados com precisão. Além disso, muitos aplicam métodos sem um conhecimento aprofundado dos modelos que são funcionais no segmento específico em questão. Essa falta de compreensão adequada resulta em prejuízos financeiros e mina a confiança nas práticas administrativas. A análise de fatores influentes para sistemas de previsão de estoque revela que vários fatores econômicos e meteorológicos afetam diretamente a demanda dos consumidores por bens de consumo rápido em supermercados, destacando a necessidade de uma solução de previsão precisa baseada em *Machine Learning* que considere esses fatores (Abeysekara & Rupasinghe, 2019).

Quando os produtos são armazenados, muitas vezes se tornam obsoletos e as previsões de demanda se tornam menos precisas, pois os padrões históricos não podem ser mais confiáveis. Isso pode levar a um excesso de estoque de produtos obsoletos ou uma escassez de produtos em alta demanda, afetando negativamente a capacidade da empresa de atender às necessidades dos clientes de forma eficiente. A precisão das previsões de analistas é afetada negativamente em empresas com

níveis de estoque relativamente altos, sugerindo que é crucial para os analistas exercerem cuidado extra ao prever ganhos para empresas com histórico de altos níveis de estoque (Lin et al., 2019).

Os objetivos de desenvolvimento sustentável (ODS) previstos pela agenda 2030 da ONU mostram que a pesquisa em gestão de estoque e o suporte tecnológico nas decisões de reabastecimento e aquisição de mercadorias podem ser relacionados aos ODS 12, ODS 1 e ODS 8: Ao contribuir para melhorar a cadeia de suprimentos e reduzir o desperdício de recursos (ODS 12); Aprimorar a eficiência operacional na redução da pobreza (ODS 1); Promoção do emprego digno e do crescimento econômico (ODS 8). Ao aplicar um método preditivo que ofereça um diferencial em relação às soluções existentes, o estudo pode proporcionar uma gestão de estoque eficiente, empregando métodos de previsão de demanda confiáveis e utilizando ferramentas de gestão de estoque eficientes para evitar tanto a escassez quanto o excesso de materiais (Silva et al., 2021).

### **1.3.1 Inserção social da pesquisa**

A pesquisa realizada, centrada na inteligência artificial aplicada na previsão de demanda em supermercados, contribuiu significativamente para a inserção social em múltiplos contextos.

No âmbito organizacional, o estudo otimizou a eficiência operacional dos supermercados, fornecendo um modelo robusto de previsão de demanda. Este modelo possibilitou a redução de desperdícios e a melhoria na disponibilidade de produtos, gerando impactos econômicos positivos, como aumento da lucratividade e estabilidade no emprego para os trabalhadores.

Na esfera comunitária, a pesquisa promoveu melhorias na satisfação do consumidor ao contribuir para a maior disponibilidade e diversidade de produtos essenciais. A gestão eficaz de estoques assegurou que os itens necessários estivessem sempre acessíveis, beneficiando a qualidade de vida dos consumidores. Adicionalmente, ao reduzir o desperdício de alimentos, o estudo alinhou-se aos Objetivos de Desenvolvimento Sustentável (ODS) da ONU, particularmente ao ODS 12 - Consumo e Produção Responsáveis.

Em um contexto mais amplo, a pesquisa teve impacto educativo ao demonstrar a relevância da aplicação de métodos científicos em cenários empresariais práticos. Os resultados foram disseminados por meio de publicações e participações em conferências, contribuindo para o avanço do conhecimento acadêmico na área de gestão de cadeias de suprimentos e incentivando a inovação em práticas de gestão de estoques.

Por fim, a pesquisa inspirou outras organizações a adotar práticas mais sustentáveis e tecnologicamente avançadas de gestão. Também fomentou a possibilidade de influenciar políticas

públicas que visem beneficiar a economia nacional, promovendo maior eficiência produtiva e redução de custos logísticos.

#### 1.4 CARACTERIZAÇÃO INTERDISCIPLINAR E ADERÊNCIA AO PROGRAMA

A Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) publicou a tabela de áreas do conhecimento, organizada em quatro níveis, sendo: Grande área; Área de avaliação; Subárea; e Especialidade (CAPES, 2020b).

O Programa de Pós-graduação em Sistemas Produtivos (PPGSP), foi aprovado em 2020 na 198ª reunião do Conselho Técnico-Científico da Educação Superior (CTC-ES) da CAPES (UNIPLAC, 2021). O programa é resultado da associação entre quatro universidades comunitárias sendo elas a UNIPLAC, UNC, UNESC e UNIVILLE e está inserido na área de avaliação interdisciplinar, especialidade Engenharia/Tecnologia/Gestão (CAPES, 2020a).

A abordagem interdisciplinar desempenha um papel fundamental na compreensão abrangente e na resolução efetiva dos desafios enfrentados na gestão de estoque na automatização tecnológica de processos no comércio varejista.

A interdisciplinaridade, conforme descrito por Raento (2020), se refere à colaboração entre diferentes campos de conhecimento para criar uma compreensão abrangente de fenômenos complexos, permitindo uma visão mais holística e inovadora. Este conceito é particularmente relevante ao considerar a natureza da interdisciplinaridade do tema proposto, onde se objetiva investigar os métodos de previsão de demanda aplicados na gestão de estoque em supermercados. A proposta está alinhada à área de concentração: Engenharia e Gestão em Sistemas Produtivos e com a linha de pesquisa 1 - aplicada a Gestão e Conhecimento em Sistemas Produtivos do programa PPGSP, refletindo a necessidade, destacada por Okamura (2019), de abordagens interdisciplinares para aumentar o impacto e a dinâmica da pesquisa em campos complexos.

O enfoque desta pesquisa visa explorar sistemas produtivos por meio de uma lente interdisciplinar, integrando conhecimentos científicos e tecnológicos em contextos variados. O estudo aborda diretamente esta interseção, investigando como diferentes métodos de previsão de demanda podem otimizar a gestão de estoque em supermercados – um setor vital e desafiador dos sistemas produtivos. Além disso, a pesquisa propõe uma análise crítica e comparativa desses métodos, contribuindo para a gestão do conhecimento e inovação no campo. Ao avaliar a aplicação de tecnologias emergentes e práticas de gestão de estoque, o estudo reflete a ênfase da linha de pesquisa, na inteligência empresarial e na gestão eficiente de processos e produção. Assim, a pesquisa não apenas se insere na temática central da linha de pesquisa, mas também busca expandir o

entendimento e a aplicação prática de conceitos e técnicas inovadoras na gestão de sistemas produtivos.

Esta expansão do entendimento e aplicação prática é onde a abordagem interdisciplinar se torna particularmente valiosa. Diante da complexidade e relevância intrínsecas ao tema, a adoção da abordagem interdisciplinar surge como um recurso fundamental para enriquecer esta pesquisa, pela combinação de práticas tradicionais de logística, tecnologia e administração. A integração eficaz dessas disciplinas permite o desenvolvimento de estratégias que maximizam a eficiência operacional e a rentabilidade das operações de suprimentos no comércio varejista (Figura 1). A interdisciplinaridade com sua amplitude de visão, promove o diálogo constante entre distintas áreas de conhecimento, unindo saberes disciplinares e transdisciplinares em busca de uma compreensão mais abrangente e contextualizada (Raento, 2020).

**Figura 1**

*Representação da interdisciplinaridade sobre o tema*



Fonte: Do autor

A gestão de estoque no contexto do comércio varejista requer uma combinação entre as práticas tradicionais de logística e os avanços tecnológicos. A integração eficaz do campo da Logística (Gestão de Estoque) e da Tecnologia (Computação) permite o desenvolvimento de sistemas automatizados que utilizam dados históricos de vendas e informações em tempo real para aprimorar a previsão de demanda, a gestão de pedidos e a otimização dos níveis de estoque. A literatura tem mostrado que a adoção de soluções tecnológicas inovadoras, como sistema de gestão de estoque baseado em indicadores e técnicas estatísticas, contribui significativamente para a melhoria da eficiência operacional e redução de custos na cadeia de suprimentos (Silva et al., 2021).

Analisando com uma abordagem econômica, o processo de gestão de estoque concentra-se em entender o impacto financeiro que a otimização dos níveis de estoque pode ter nas operações de uma organização (Saleheen, 2014). Por meio de uma análise de indicadores, como custo de armazenagem, giro de estoque e, até mesmo níveis de serviço, é possível identificar oportunidades de melhoria e tomar decisões embasadas no contexto do setor do comércio varejista. Neste sentido, a aplicação de métodos estatísticos e tecnológicos pode auxiliar na tomada de decisões estratégicas, contribuindo para a maximização do retorno sobre o investimento em estoques (Campos Borges et al., 2010).

A automatização tecnológica pode resultar em impactos psicossociais relevantes para os colaboradores envolvidos no processo. A adoção e implementação de sistemas automatizados pode modificar as dinâmicas de trabalho e exigir a adaptação de habilidades e competências dos profissionais. A literatura mostra como as mudanças tecnológicas podem influenciar o ambiente organizacional, o engajamento dos funcionários e suas percepções sobre a automação, no sucesso da implantação de um novo sistema (Noronha et al., 2022).

Em suma, a abordagem interdisciplinar desempenha um papel crucial na compreensão aprofundada dos desafios e oportunidades apresentados pela automatização tecnológica na gestão de estoques no cenário do comércio varejista. Ao unir conceitos da logística, tecnologia, e administração, é possível construir estratégias que maximizem a eficiência operacional e a rentabilidade das operações de suprimentos. Ressalta-se que em um panorama em constante evolução, a interdisciplinaridade se apresenta como um guia fundamental para navegar com sucesso pelos desafios e benefícios da automatização tecnológica na gestão de estoques no setor do comércio varejista.

## 1.5 ESTRUTURA GERAL DO DOCUMENTO

O presente documento visa a exposição de dissertação, articulando-se em uma sequência lógica e orientada, dividida em capítulos e seções estratégicas para o desenvolvimento da análise

proposta. Inicialmente, procurou-se contextualizar o estudo com uma introdução abrangente, que delinea a motivação, o problema, os objetivos e a justificativa da pesquisa.

A introdução é seguida pelo referencial teórico, fundamentando-se em literatura científica sobre o tema, a fim de explicar o estudo comparativo dos métodos de previsão de demanda na gestão de estoque em supermercados.

A metodologia empregada foi detalhada em um capítulo dedicado, que descreve a abordagem quantitativa e dedutiva, as técnicas de coleta de dados e o processo de análise. Com a metodologia proposta, nota-se resultados que contribuam significativamente para o campo da gestão de sistemas produtivos.

Os resultados estão apresentados em um capítulo subsequente, onde foram expostas as descobertas da pesquisa, as análises de dados, e avaliação da precisão dos métodos de previsão adotados.

## 2 PANORAMA TEÓRICO

A presente pesquisa de dissertação de mestrado empreende uma análise de conceitos previamente examinados em literatura acadêmica e científica. A intenção é destacar a significância intrínseca de compreender de maneira precisa cada um desses conceitos, pois essa clareza conceitual é fundamental para a consecução dos objetivos delineados no estudo de caso em questão.

### 2.1 MERCADO VAREJISTA

O mercado varejista, frequentemente referido como setor varejista, desempenha um papel crucial na economia global, servindo como a interface final entre produtores e consumidores. Historicamente, o varejo tem sido uma atividade comercial essencial, evoluindo ao longo dos séculos para se adaptar às mudanças nas demandas dos consumidores, avanços tecnológicos e dinâmicas socioeconômicas (Trento et al., 2022).

No contexto moderno, o setor varejista não apenas facilita a distribuição e venda de mercadorias, mas também influencia significativamente as tendências de consumo, padrões de compra e, por extensão, a produção e a logística (Trento et al., 2022).

A diversidade do setor varejista tem evidências na variedade de formatos de lojas, desde pequenos varejistas independentes até grandes conglomerados multinacionais. Essa diversidade reflete a necessidade de atender a uma ampla gama de necessidades e preferências dos consumidores, bem como a adaptabilidade do setor às diferentes condições de mercado e geográficas. Além disso, o varejo moderno não se limita apenas à venda de produtos físicos, mas também abrange serviços, experiências e soluções digitais, ampliando ainda mais seu escopo e relevância (Cruz et al., 2022).

Com a ascensão da tecnologia digital e da internet, o setor varejista tem testemunhado uma transformação sem precedentes. O comércio eletrônico, ou *e-commerce*, emergiu como uma força dominante, desafiando os modelos tradicionais de varejo e oferecendo aos consumidores uma conveniência e variedade sem paralelo. Essa digitalização do varejo também trouxe consigo novos desafios, desde a gestão de cadeias de suprimentos globais até a necessidade de uma experiência de cliente integrada. Em um contexto mais amplo, o estudo de Magalhães et al. (2022) destaca o impacto da Covid-19 na geração e distribuição da riqueza em empresas do setor varejista, evidenciando as mudanças e desafios enfrentados pelo setor durante a pandemia.

No entanto, apesar dessas mudanças, a essência do varejo permanece a mesma, atender às necessidades e desejos dos consumidores. Seja através de uma loja física tradicional ou de uma

plataforma digital, o setor varejista continua a ser um barômetro vital da saúde econômica (Lima & Bezerra Barbosa, 2021).

## 2.2 GESTÃO DE ESTOQUE

A gestão de estoques desempenha um papel de extrema importância em empresas de diversos setores. Manter estoques em lugares como supermercados, centros de distribuição e outros tipos de negócios é fundamental, mas é essencial fazê-lo de forma eficiente. Quando bem gerenciado, o estoque pode ser um ativo valioso para a organização, contribuindo para o alcance de metas empresariais ao reduzir custos e aumentar os lucros. Uma organização que assume um papel de responsabilidade crítica no gerenciamento de seu estoque interno conquista uma notável vantagem competitiva no mercado contemporâneo. A gestão de estoque emerge como um dos pilares fundamentais de uma cultura empresarial orientada para o aprimoramento contínuo, desempenhando um papel primordial na otimização dos recursos financeiros, na capacidade de atender com precisão os prazos de entrega, mesmo diante de inesperadas intercorrências na produção (Kumar & Aouam, 2019).

A elaboração adequada de uma estratégia de gestão de estoque é crucial nesse contexto. Essa estratégia define quando adquirir, a quantidade ideal a ser mantida em estoque e quais produtos devem ser priorizados. Isso não apenas permite que a empresa atenda à demanda de seus clientes de forma consistente, mas também ajuda a evitar problemas como custos associados à falta de estoque ou excesso de materiais armazenados (Sanchez-Rodrigues et al., 2010).

Além disso, o estoque desempenha um papel fundamental como mecanismo de regulação no fluxo de materiais da empresa. Como a taxa de entrada de materiais muitas vezes difere da taxa de saída, manter uma quantidade adequada de materiais em estoque é essencial. Isso permite ajustar-se às variações de demanda, suavizar flutuações e garantir que a empresa possa atender às necessidades dos clientes de maneira eficiente, seja aumentando ou reduzindo a quantidade disponível conforme necessário (Provin & Sellitto, 2011).

É crucial compreender que cada item possui uma taxa de saída associada, acompanhada por um nível específico de estoque de segurança. Esses fatores desempenham um papel fundamental na gestão de estoques, com o objetivo principal de minimizar as perdas de produtos devido ao armazenamento prolongado. Uma das metodologias empregadas para avaliar a importância de cada conjunto de produtos é a análise ABC (B. Santos & Lubiana, 2017).

Empresas que mantêm um extenso portfólio de produtos enfrentam a necessidade imperativa de classificá-los de maneira preferencial e crítica. Essa classificação não é determinada

apenas pelo volume de demanda dos clientes, mas também considera os valores associados a cada item, sua relevância financeira no contexto do estoque e o tempo necessário para o processo de produção (Palomino et al., 2018).

### 2.3 CURVA ABC DE PRODUTOS

Para efetivamente administrar um estoque no âmbito da logística, é fundamental empregar ferramentas que orientem a tomada de decisões durante a execução de tarefas, com o propósito de otimizar a rentabilidade da empresa. Um dos métodos cruciais para alcançar esse objetivo é a aplicação da curva ABC, cujo princípio fundamental reside na capacidade de determinar uma abordagem econômica que assegure o controle dos itens no estoque.

O uso da curva ABC na tomada de decisões referentes à composição do estoque é essencial para melhorar a eficácia da empresa na organização de seus produtos em armazenamento. A implementação desse sistema proporciona diversas vantagens financeiras e aprimora a gestão do estoque. Além disso, a gestão de estoques eficiente, como mencionado anteriormente, desempenha um papel crítico no contexto da logística, contribuindo diretamente para a lucratividade da organização (B. Santos & Lubiana, 2017).

A curva ABC, um princípio essencial na gestão de estoques, encontra sua base na Lei de Pareto, que se originou de um estudo sobre a distribuição de renda na Itália. Esse estudo notou que aproximadamente 20% da população detinha cerca de 80% da renda total do país, resultando na denominação popular da regra como "Regra 80/20" (Aragao et al., 2016).

O princípio subjacente à Lei de Pareto, que é aplicável à gestão de estoques, sugere que uma minoria significativa de itens (classificados como "A") contribui de forma desproporcional para o valor total, enquanto a maioria dos itens ("B" e "C") possui uma contribuição menor.

Para entender como a Lei de Pareto se aplica na classificação de produtos de supermercado, a Tabela 1, adaptada de Santos et al. (2017) descreve cada elemento da curva ABC.

**Tabela 1**

*Classificação da Curva ABC*

	<b>Produtos em Estoque (%)</b>	<b>Valor em Estoque (%)</b>	<b>Impacto Econômico</b>
Classe A	10-20	80	Alto
Classe B	20-30	15	Médio
Classe C	50 ou mais	5	Baixo

Fonte: Adaptada de Santos et al. (2017)

Para exemplificar a classificação de produtos usando as classes da curva ABC, Santos et al. (2017) comenta que os itens devem ser ordenados pela sua importância relativa, conforme demonstra o Tabela 2.

**Tabela 2**

*Classificação ABC de Produtos*

Classe "A"	Produtos de grande valor financeiro. Com maior procura e maior necessidade de cuidados pela administração.
Classe "B"	Produtos de quantidade ou valor em situação intermediária.
Classe "C"	Produtos que são considerados menos importantes (10% do valor total) devido a sua alta qualidade.

Fonte: Adaptado de Santos et al. (2017)

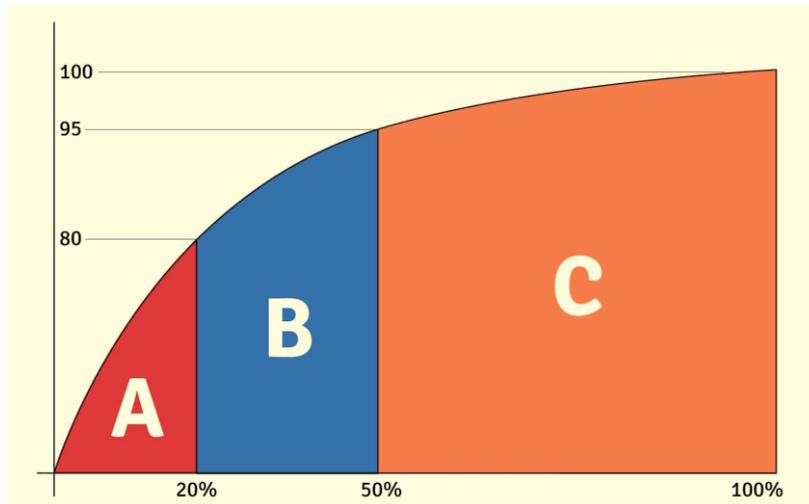
Observa-se três distintas categorias nos estoques, o **grupo A** denota um conjunto reduzido de produtos, mas com um substancial valor alocado, exigindo, assim, uma precisão mais apurada nas previsões. Por sua vez, o **grupo C** representa um investimento reduzido em uma extensa variedade de produtos, indicando uma situação em que o controle pode ser menos rígido, e estoques mais amplos são viáveis devido aos seus custos inferiores. Enquanto isso, o **grupo B** se situa como uma categoria intermediária, não demandando a mesma precisão que os produtos do **grupo A**.

Os autores complementam que para os itens de maior relevância, é fundamental adotar medidas distintas, tais como: otimizar a rotatividade de estoque, intensificar a frequência de reabastecimento, aprimorar a monitorização da dinâmica da demanda e dos prazos de reposição, implementar aquisições programadas e aperfeiçoar a precisão no cálculo do estoque de segurança. Além disso, é crucial considerar fatores como o tempo de fornecimento, o volume do item e, caso aplicável, a sua perecibilidade.

A construção de um gráfico para a classificação dos itens de estoque se apresenta como uma ferramenta estratégica, permitindo uma visualização clara da distribuição dos itens e do seu respectivo consumo. Utilizando um sistema de coordenadas cartesianas, o gráfico exhibe os percentuais de consumo acumulado no eixo horizontal, em contraponto aos percentuais dos números de itens acumulados nas respectivas classes no eixo vertical, detalhamento que pode ser observado na Figura 2.

**Figura 2**

*Gráfico de Ilustração da curva ABC*



Fonte: Adaptado de Mitiuye et al. (2008)

A curva ABC é de extrema relevância, uma vez que possibilita a identificação precisa dos itens com maior e menor importância. Isso permite direcionar a atenção e os recursos da administração da forma correta, dando mais atenção aos itens importantes e simplificando o gerenciamento dos itens menos cruciais (Mitiuye et al., 2008).

## 2.4 GESTÃO DE DEMANDA

A gestão da demanda é um conceito crescente, onde seu principal objetivo é garantir a rápida e eficaz incorporação das demandas do mercado em direção aos fornecedores, a fim de equilibrar e alinhar estrategicamente as necessidades de mercado com a capacidade operacional em toda a cadeia de suprimentos (Melo & Alcântara, 2011).

As empresas estão demonstrando crescente interesse na identificação das percepções de valor do consumidor final e na capacidade de transformá-las em ofertas relevantes. Esse foco nas percepções do cliente é fundamental para o desenvolvimento de produtos e serviços que atendam efetivamente às suas necessidades e expectativas, estabelecendo, assim, uma conexão sólida e duradoura com o mercado (Pereira et al., [s.d.]).

A otimização da gestão da cadeia de suprimentos desempenha um papel crucial para o sucesso das empresas nos mercados modernos. Para atingir uma gestão de demanda eficaz, é fundamental compreender as dinâmicas do mercado, tanto interna quanto externamente. Essa compreensão orienta as estratégias e práticas operacionais, garantindo a sincronização entre a demanda e a capacidade ao longo da cadeia de suprimentos.

A previsão de vendas é um componente crítico da gestão de demanda. Antes de qualquer ação ser tomada, as equipes multifuncionais devem garantir que as estratégias operacionais e estratégicas estejam alinhadas com o plano de negócios resultante da previsão. Caso contrário, é necessário revisar as previsões para identificar estratégias de marketing e vendas que estimulem a demanda. Paralelamente, as equipes de gerenciamento de suprimentos devem avaliar as iniciativas para expandir a capacidade, se necessário, a fim de cumprir o plano de negócios (Melo & Alcântara, 2011).

Para garantir uma gestão de demanda eficaz, o equilíbrio entre as necessidades dos clientes e a capacidade da empresa é fundamental. Esse equilíbrio resulta na minimização das incertezas relacionadas à oferta e demanda, além de melhorias notáveis no atendimento ao cliente. Reduzir os níveis de estoque e otimizar a utilização de ativos são benefícios adicionais desse alinhamento estratégico (Melo & Alcântara, 2011).

A antecipação precisa das necessidades de estoque é de suma importância tanto para fabricantes, distribuidores como para varejistas. Aguardar passivamente o surgimento da demanda e reagir a ela não é uma estratégia viável para a maioria das empresas. Portanto, é imprescindível que essas empresas se preparem de forma proativa para atender à demanda futura, o que lhes permitirá responder eficazmente às solicitações dos clientes (Dinh, 2020).

No entanto, se a gestão da demanda e as previsões de estoque não forem precisas, pode-se ter repercussões substanciais nos negócios, conforme destacado por Santos et al. (2017):

- **Insatisfação dos clientes:** As empresas frequentemente sofrem perdas substanciais devido à insatisfação dos clientes. A principal causa dessa insatisfação costuma ser a demora na entrega. O controle de estoque deficiente, a falta de organização, a escassez de recursos ou a manutenção de níveis de estoque inadequados podem resultar em atrasos na entrega. Portanto, a previsão de estoque pode ser uma ferramenta crucial para manter a organização eficiente e assegurar que os recursos estejam adequados durante os períodos de alta demanda, diminuindo, assim, a insatisfação dos clientes e os danos à reputação.
- **Falta de estoque:** A falta de estoque é um fator que leva à perda de vendas. A previsão de estoque proporciona uma visão precisa das vendas futuras e da quantidade de produtos necessários. Essas informações são essenciais para responder à pergunta sobre quando e o que reabastecer, a fim de evitar a falta de estoque.

A gestão eficaz da cadeia de suprimentos e a compreensão das percepções do cliente estabelecem as bases para o sucesso empresarial. No entanto, para alcançar uma harmonização

continua entre a oferta e a demanda, a previsão de demanda desempenha um papel fundamental. A previsão de demanda é a próxima etapa lógica nesse processo, permitindo que as empresas antecipem as necessidades do mercado e preparem estratégias para atender às demandas em constante evolução.

#### **2.4.1 Previsão de Demanda**

A gestão de estoques é uma ferramenta essencial para as empresas, pois permite o controle de custos e garante o andamento saudável das operações (Magalhães et al., 2022). Em particular, a previsão de demanda desempenha um papel crucial na otimização do estoque, especialmente em setores sensíveis a flutuações, como bares, restaurantes e microempresas no setor de alimentação.

No setor de bares e restaurantes, momentos de incerteza, como os vivenciados durante a pandemia de Covid-19, exigem um planejamento ainda mais rigoroso. Para enfrentar tais desafios, é proposto um modelo de otimização de estoque que utiliza a Curva ABC e o modelo de estoque por revisão periódica (Pâmela & Sachet, 2022). Além disso, diferentes métodos de previsão de demanda são aplicados, com destaque para o método de suavização exponencial tripla de Winter, que se mostrou adequado para certos insumos (Pâmela & Sachet, 2022).

As microempresas, especialmente aquelas no setor de alimentação, têm enfrentado desafios econômicos significativos (Assumpção & Rosa, 2022). Para superar esses obstáculos, técnicas de gerenciamento de sistemas produtivos são essenciais. Um estudo em uma microempresa do setor de doces e bolos artesanais aplicou um método quantitativo de previsão de demanda, utilizando a decomposição de série temporal (Assumpção & Rosa, 2022). Esse método resultou em previsões precisas, auxiliando no cálculo das necessidades de matéria-prima.

A importância do setor de serviços na economia global é inegável. Dentre as ferramentas de planejamento da produção, a previsão de demanda é fundamental. Métodos como a suavização exponencial tripla, desenvolvida por Winter, são amplamente utilizados devido à sua simplicidade, baixo custo, precisão e capacidade de ajuste rápido às mudanças na série em análise (Pâmela & Sachet, 2022).

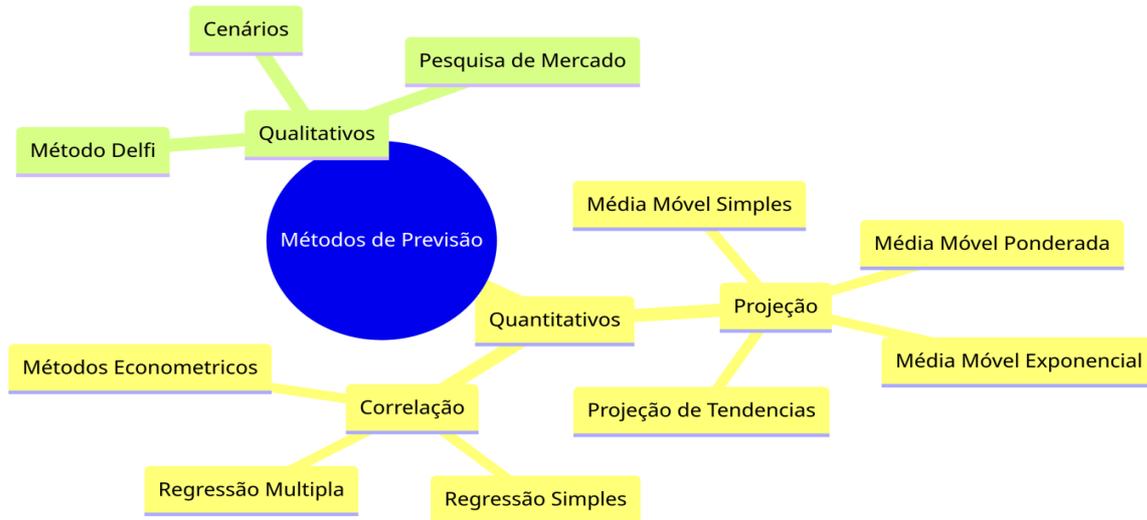
#### **2.4.2 Métodos de Previsão de Demanda**

Os métodos de previsão, conforme apresentados na Figura 3, visam antecipar a demanda de vendas com a maior precisão possível, fornecendo uma estimativa confiável. Há duas abordagens predominantes para essa previsão. Métodos denominados qualitativos, que se baseiam em opiniões,

experiências anteriores e até mesmo intuições bem fundamentadas das pessoas envolvidas no processo, e métodos que fazem uso de técnicas quantitativas, que auxiliam os gerentes a identificar tendências, estabelecer relações causais e projetar cenários futuros com base em dados e análises estatísticas (Slack et al., 2002).

**Figura 3**

*Métodos de Previsão de demanda*



Fonte: Do autor

### 2.4.3 Média Móvel Simples

O método da média móvel simples é considerado um dos mais fáceis de ser aplicado devido à compreensão descomplicada dos elementos estacionários envolvidos (Muttaqin et al., 2022).

Fetrina et al. (2018) reforçam essa ideia ao enfatizar que os modelos de médias móveis operam sob a premissa de que a melhor estimativa para o futuro é obtida pela média dos  $n$  últimos períodos. A fórmula da média móvel simples (MMS) é uma técnica de previsão que calcula a média dos valores observados em um número específico de períodos anteriores. Frequentemente usada para suavizar flutuações de curto prazo e destacar tendências de longo prazo (Equação 1).

$$P_{t+1} = \frac{D_t + D_{t-1} + D_{t-2} + \dots + D_{t-n+1}}{n} \quad (1)$$

A equação calcula a previsão para o próximo período ( $P_{t+1}$ ) por meio da média aritmética dos valores observados de demanda nos  $n$  períodos anteriores ( $D_t, D_{t-1}, D_{t-2}, \dots, D_{t-n+1}$ ). Cada valor de

demanda corresponde ao observado em um período específico, e a soma desses valores é dividida pelo número total de períodos considerados ( $n$ ). Assim, a média resultante fornece uma estimativa do comportamento futuro da demanda, com ênfase em períodos mais recentes, mas sem atribuir pesos diferentes aos dados passados. Esse método, apesar de simples, é eficaz em contextos em que os dados não apresentam variações significativas ou tendências sazonais.

As limitações deste modelo tornam-se evidentes quando se trata de séries históricas com tendências ou sazonalidades. Tubino (2007) destaca que uma das principais falhas é atribuir o mesmo peso às observações mais antigas e às mais recentes. Isso significa que, na técnica de média móvel, ao atualizar a média, a observação mais antiga é substituída pela mais recente, e a previsão de valores futuros é baseada na última média calculada.

Para mitigar essa imprecisão, a média ponderada pode ser uma solução eficaz, proporcionando uma representação mais fiel da realidade, como discutido na próxima seção.

#### **2.4.4 Média Móvel Ponderada**

Conforme Gomes et al. (2018), a média móvel ponderada assemelha-se ao método da média móvel simples. No entanto, sua característica distintiva é a atribuição de pesos diferenciados para diferentes períodos (Equação 2).

$$P_t = (D_1 \times PE_1) + (D_2 \times PE_2) + \dots + (D_n \times PE_n) \quad (2)$$

Na fórmula “ $P_t$ ” é a previsão da demanda para o período “ $t$ ”, “ $D_n$ ” é o valor da demanda observada no período “ $n$ ”, e “ $PE_n$ ” corresponde ao peso atribuído ao valor de demanda daquele período.

A principal vantagem dessa técnica é sua flexibilidade, pois permite que períodos mais recentes ou relevantes tenham um impacto maior na previsão. Contudo, conforme mencionado por Gomes et al. (2018), a desvantagem da média móvel ponderada reside na necessidade de conhecimento prévio ou de um critério bem definido para determinar os pesos a serem aplicados em cada período. Sem uma atribuição adequada dos pesos, a previsão pode perder sua eficácia e precisão.

#### **2.4.5 Média Móvel Exponencial**

A média móvel exponencial é uma técnica de suavização em que as observações passadas recebem pesos que decrescem exponencialmente, atribuindo maior importância às observações mais

recentes e menos importância às mais antigas. Esse método é útil em situações em que as últimas observações possuem maior relevância para as previsões futuras (Ballou, 2007). A fórmula para a média móvel exponencial é dada pela (Equação 3).

$$P_{t+1} = \alpha A_t + (1 - \alpha)P_t \quad (3)$$

Onde “ $P_{t+1}$ ” representa a previsão para o próximo período, “ $\alpha$ ” é um parâmetro de suavização entre 0 e 1 que determina o peso dado à demanda mais recente, e “ $A_t$ ” é o valor da demanda observada no período atual. O termo “ $(1 - \alpha)P_t$ ” refere-se à previsão do período anterior, que também influencia a previsão atual de maneira ponderada.

O método de suavização exponencial aplica um decaimento progressivo aos dados passados, permitindo que os eventos mais recentes impactem de forma mais significativa a previsão. A simplicidade dessa fórmula a torna amplamente utilizada em contextos em que a tendência recente é mais relevante do que dados históricos mais distantes. Além da suavização exponencial simples, variações mais avançadas, como a suavização exponencial dupla e o método de Holt-Winters, são aplicadas para lidar com séries temporais que apresentam tendências ou sazonalidade (Elías et al., 2022).

#### 2.4.5 Projeção de Tendências

A projeção de tendências é uma técnica fundamental nos métodos quantitativos de previsão, utilizada para antecipar comportamentos futuros com base em dados históricos. Este método é especialmente relevante em ambientes onde as séries temporais mostram padrões de crescimento ou declínio consistentes. Entre os métodos clássicos de projeção de tendências, destaca-se a tendência linear, que assume uma relação linear entre o tempo e a variável de interesse (Yawen Shao et al., 2022) no qual sua fórmula pode ser visualizada abaixo (Equação 4).

$$Y = a + bX \quad (4)$$

Na fórmula “ $Y$ ” representa a variável dependente que se deseja prever, “ $a$ ” é o ponto de interseção no eixo “ $Y$ ”, “ $b$ ” é o coeficiente angular (inclinação) que determina a taxa de variação da variável, e “ $X$ ” representa o tempo. Essa relação linear é útil para situações em que os dados seguem um padrão de crescimento ou decaimento constante.

Outro método clássico é a tendência exponencial, indicada para dados que crescem ou decrescem a uma taxa constante. Neste modelo, a equação é  $Y = ab^x$  onde  $a$  e  $b$  são constantes, e  $X$  é o tempo, sendo adequado para séries temporais que exibem crescimento ou decaimento exponencial (Yawen Shao et al., 2022).

A desvantagem do método de projeção de tendência é que este assume que os padrões observados nos dados históricos continuarão no futuro, o que nem sempre é verdade. Este método pode ser inadequado em situações em que há mudanças no comportamento da série temporal devido a eventos externos ou mudanças no ambiente de mercado (Elías et al., 2022; Ivanyuk et al., 2023).

## 2.5 APLICAÇÃO DE MODELOS DE LINGUAGEM NA PREVISÃO DE DEMANDA

Os Modelos de Linguagem de Grande Escala (LLM), representam um avanço significativo na área de inteligência artificial e aprendizado de máquina. Esses modelos utilizam arquiteturas de redes neurais profundas, especificamente *transformers*, que são treinadas em grandes volumes de dados textuais.

A arquitetura *transformer* foi introduzida por Vaswani et al. (2017) e revolucionou a forma como processamos e entendemos a linguagem natural. Os LLM são capazes de realizar uma ampla gama de tarefas de linguagem natural, incluindo tradução, resumo, geração de texto, e previsão de padrões em séries temporais, como a demanda de produtos (Vaswani et al., 2017).

A aplicação de LLM na previsão de demanda tem sido explorada devido à sua capacidade de capturar padrões complexos e não lineares em grandes conjuntos de dados. Estudos indicam que a incorporação de técnicas avançadas de *prompting*, como o *chain of thought prompting*, pode melhorar significativamente a capacidade dos LLM em realizar raciocínios complexos, resultando em previsões mais precisas e robustas (Wei et al., 2022). Além disso, esses modelos são capazes de integrar múltiplas fontes de dados, como histórico de vendas, tendências de mercado, variáveis econômicas e comportamentais, proporcionando uma visão mais holística e precisa da demanda futura (Gruver et al., 2023).

A escalabilidade e adaptabilidade dos LLM são outros aspectos cruciais. Com a capacidade de se adaptar a novos dados e condições de mercado em tempo real, esses modelos oferecem uma vantagem competitiva significativa para empresas que operam em mercados dinâmicos. A previsão de demanda precisa é crucial para otimização de estoques, planejamento de produção e estratégias de marketing, resultando em redução de custos e aumento de eficiência operacional (Abolghasemi et al., 2023).

A combinação dos LLM com outras técnicas de *machine learning* e modelos estatísticos tradicionais cria sistemas híbridos que aproveitam o melhor de ambos os mundos. Por exemplo, a integração de LLM com modelos de séries temporais ou modelos de suavização exponencial pode melhorar ainda mais a precisão das previsões, especialmente em cenários onde há sazonalidade ou tendências específicas (Jin et al., 2023).

Porém, é fundamental abordar as limitações e desafios na aplicação de LLM para previsão de demanda. Apesar dos resultados promissores, esses modelos tenham mostrado resultados promissores, eles exigem uma quantidade significativa de recursos computacionais para treinamento e inferência, além de uma grande quantidade de dados de alta qualidade. A interpretabilidade dos modelos também é um desafio, uma vez que a complexidade dos LLM pode dificultar a compreensão dos fatores que influenciam as previsões. Abordagens como *explainable AI (XAI)* estão sendo desenvolvidas para mitigar essas limitações, proporcionando maior transparência e confiança nas previsões geradas (Makridakis et al., 2023).

### 2.5.1 Relevância dos LLM na Previsão de Demanda

A previsão de demanda é um componente crítico na gestão de estoques, particularmente em setores como o varejo, onde a variabilidade da demanda pode ter impactos significativos nos custos operacionais e na satisfação do cliente. Tradicionalmente, métodos como médias móveis e modelos temporais têm sido utilizados para prever a demanda. No entanto, esses métodos frequentemente falham em capturar a complexidade dos dados reais de vendas, especialmente em ambientes dinâmicos e com alta variabilidade (Makridakis et al., 2023).

Os LLM, por outro lado, têm mostrado potencial para superar essas limitações devido à sua capacidade de processar e analisar grandes volumes de dados de forma eficiente. Modelos como o *Pathways Language Model (PaLM)* e sua variante *Flan-PaLM*, por exemplo, têm sido utilizados para tarefas complexas de previsão e mostraram um desempenho superior em comparação com métodos tradicionais (Singhal et al., 2023). Esses modelos podem integrar dados de múltiplas fontes, como históricos de vendas, dados de mercado, e comportamento do consumidor, proporcionando uma visão mais holística e precisa das tendências de demanda (Makridakis et al., 2023).

Além disso, os LLM podem ser utilizados em cenários de previsão de demanda sem necessidade de treinamento específico para a tarefa, demonstrando capacidades de *zero-shot learning* que muitas vezes superam os modelos tradicionais treinados especificamente para essa

finalidade (Gruver et al., 2023). Esse atributo permite que os LLM sejam extremamente versáteis e adaptáveis a diferentes contextos de previsão de demanda.

A capacidade dos LLM de realizar ajustes em previsões estatísticas e de *machine learning*, melhorando a precisão dessas previsões. Estudos demonstraram que técnicas como *prompting* podem facilitar o detalhamento passo a passo das previsões, resultando em uma maior quantidade de termos relacionados e, conseqüentemente, previsões mais precisas (Jagerman et al., 2023).

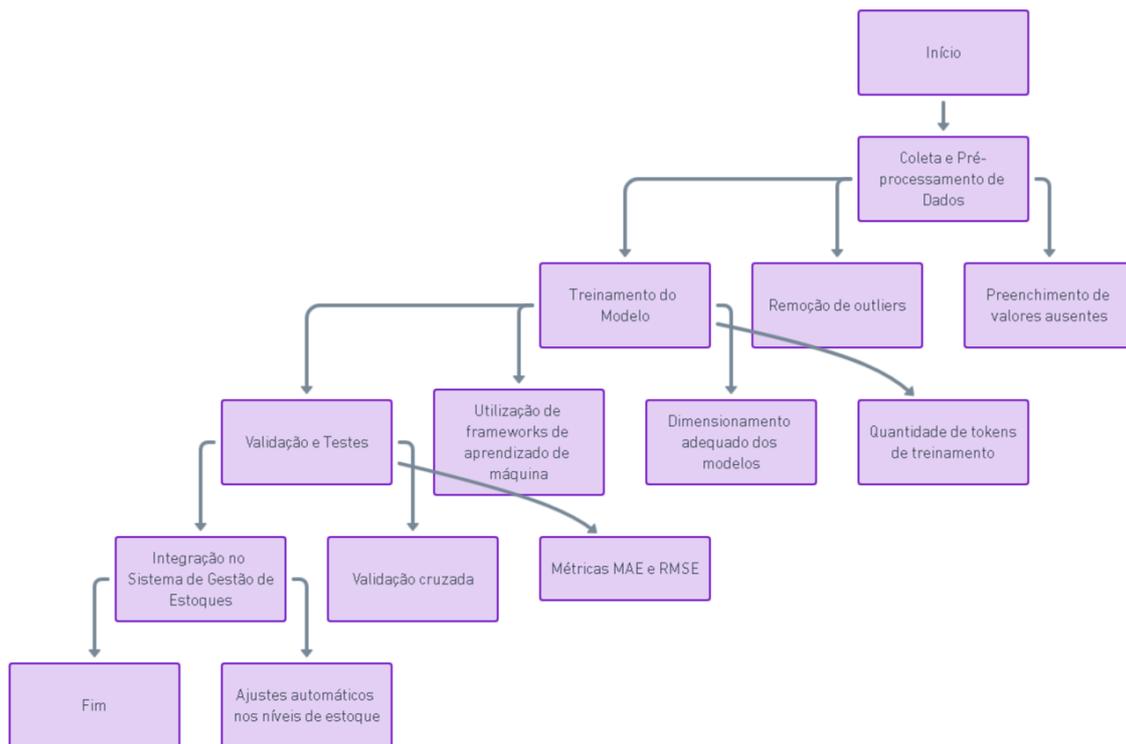
A flexibilidade dos LLM é particularmente útil em contextos onde os dados são heterogêneos e as relações entre variáveis são complexas. Eles podem ser reprogramados para alinhar dados de séries temporais com linguagem natural, aproveitando suas robustas capacidades de reconhecimento de padrões e raciocínio, superando modelos especializados de previsão em diversos cenários de aprendizado (Jin et al., 2023).

Finalmente, a eficiência dos LLM em fornecer previsões mais precisas a um custo menor reforça sua relevância na previsão de demanda. Em cenários de rotulagem de relevância em larga escala, esses modelos demonstraram uma precisão comparável à de rotuladores humanos, mas a um custo significativamente menor (Thomas et al., 2023). Essa economia de custos, juntamente com a alta precisão, reforça a relevância dos LLM na previsão de demanda (Thomas et al., 2023).

## 2.5.2 Metodologia para Implementação de LLM

A aplicação de Modelos de Linguagem de Grande Escala (LLM) na previsão de demanda representa uma inovação significativa na área de gestão de estoques e planejamento de recursos. A implementação desses modelos envolve um conjunto estruturado de etapas metodológicas que garantem a precisão e a eficiência das previsões geradas. Na Figura 4, foi detalhado cada fase do processo, desde a coleta e pré-processamento de dados até a integração final no sistema de gestão de estoques, é essencial para o sucesso da aplicação dos LLM.

**Figura 4**  
*Fluxograma para Implementação de LLM*



Fonte: Do autor

A primeira etapa envolve a coleta de dados históricos de vendas, dados de mercado, informações sobre promoções e eventos sazonais, entre outros. Esses dados devem ser pré-processados para garantir a qualidade e a consistência, removendo dados desnecessários e preenchendo valores ausentes. O pré-processamento é crucial para o desempenho do modelo, conforme destacado por (Brown et al., 2020).

Utilizando as técnicas de aprendizado de máquina, os dados são utilizados para treinar o LLM. Este processo envolve a utilização de *frameworks* e requer um poder computacional significativo. Estudos mostram que o dimensionamento adequado dos modelos e a quantidade de tokens de treinamento são críticos para o desempenho ótimo do modelo (Hoffmann et al., 2022).

Após o treinamento, o modelo deve ser validado usando métodos de validação cruzada para assegurar sua generalização. Métricas como o Erro Médio Absoluto (MAE) e o Erro Médio Quadrático (RMSE) são frequentemente utilizadas para avaliar a precisão das previsões (Zhao et al., 2023).

Finalmente, as previsões geradas pelo LLM são integradas no sistema de gestão de estoques da empresa. Esta integração permite ajustes automáticos nos níveis de estoque com base nas

previsões de demanda, melhorando a eficiência operacional e reduzindo custos associados a excessos ou faltas de estoque.

### 3 METODOLOGIA DA PESQUISA

A metodologia de pesquisa representa um pilar fundamental em qualquer investigação acadêmica, servindo como a bússola que orienta o pesquisador durante as fases de coleta, análise e interpretação dos dados. No contexto desta dissertação, adotou-se uma abordagem metodológica quantitativa com método dedutivo. Ao contrário da abordagem indutiva, que começa com observações específicas para formular teorias ou generalizações mais abrangentes, a abordagem dedutiva parte de uma teoria preexistente para testá-la empiricamente (Ramos et al., 2021).

Adicionalmente, Hohemberger et al. (2021) destacam a importância desta abordagem para alcançar um entendimento mais profundo e contextualizado, integrando o conhecimento científico com as experiências reais dos educandos. A seguir, na Figura 5, pode-se observar uma representação gráfica da metodologia utilizada nesta pesquisa:

**Figura 5**

*Design da Metodologia da pesquisa*



Fonte: Do autor

Na seção subsequente 3.1, foram delineadas as abordagens, objetivos, procedimentos e técnicas adotadas. O cenário, a população-alvo e as fases da pesquisa foram detalhados no subitem 3.2. O método de coleta de dados foi elucidado no subitem 3.3, enquanto a estratégia de análise dos dados coletados foi esboçada no subitem 3.4.

#### 3.1 ABORDAGEM, OBJETIVOS, PROCEDIMENTOS E TÉCNICAS DE PESQUISA

No presente tópico, foi discutida a classificação da pesquisa científica, com foco em aspectos como abordagem, objetivos, procedimentos, técnicas de pesquisa e outros fatores relevantes. A

pesquisa foi definida como um procedimento racional e sistemático cujo objetivo principal era proporcionar respostas a problemas previamente estabelecidos. Tornou-se necessária quando a disponibilidade de informações era insuficiente para resolver o problema ou quando as informações disponíveis estavam em um estado tão desordenado que não podiam ser adequadamente relacionadas à questão de pesquisa (A. C. Gil, 2002).

No que diz respeito às abordagens adotadas neste estudo, optou-se pela abordagem quantitativa. Esta abordagem teve como foco a quantificação de elementos, visando a análise de fenômenos por meio de medidas numéricas, frequentemente empregando ferramentas estatísticas para essa finalidade (A. Gil, 2017).

Quanto aos objetivos da pesquisa, este estudo caracterizou-se por ter objetivo descritivo, no qual concentrou-se na descrição das características de populações ou fenômenos específicos. Esta abordagem frequentemente fez uso de técnicas padronizadas de coleta de dados, como questionários ou observação sistemática. Além disso, este estudo classificou-se como uma pesquisa exploratória, que buscou investigar um tópico ou problema de forma preliminar, geralmente quando havia uma falta de informações prévias disponíveis. Isso incluiu a revisão da literatura e a coleta inicial de dados (Sloane, 2021).

No que diz respeito às estratégias de pesquisa, aplicou-se um estudo de caso. Este método envolveu uma investigação detalhada e aprofundada de um ou poucos objetos de estudo, permitindo uma compreensão abrangente do fenômeno em questão. O estudo de caso pôde ser aplicado tanto em pesquisas exploratórias quanto em pesquisas descritivas e explicativas, dependendo do propósito da pesquisa (Tosin & Köprülü, 2022).

A escolha de técnicas estatísticas avançadas e análise de dados neste estudo foi essencial para atingir o objetivo de investigar métodos de previsão de demanda na gestão de estoques em supermercados. Em um ambiente de supermercado, onde a precisão na previsão de demanda era crucial para otimizar o estoque e reduzir custos, a aplicação de métodos estatísticos permitiu uma análise mais profunda e precisa dos padrões de consumo. A capacidade de analisar grandes volumes de dados de vendas e tendências de consumo com métodos estatísticos não só melhorou a precisão das previsões, mas também forneceu dados valiosos para a tomada de decisão estratégica (Bandeira et al., 2023).

### 3.2 DELIMITAÇÃO DO ESTUDO

A seguir são apresentadas a descrição do local e população em estudo, bem como as etapas para a elaboração da pesquisa.

### 3.2.1 Descrição do local e população em estudo

A pesquisa tem como estudo de caso em um supermercado localizado ao Sul do estado de Santa Catarina. A história desse supermercado teve início em 1980, quando foi fundado como um modesto estabelecimento com uma área de vendas de apenas 77m<sup>2</sup>. Ao longo dos anos, o negócio prosperou e, como resultado desse sucesso, foi construído um novo prédio com uma área expandida de aproximadamente 320m<sup>2</sup>. O crescimento constante nas vendas ao longo do tempo evidenciou a necessidade de mais espaço, o que levou a quatro expansões subsequentes do estabelecimento.

No contexto atual da empresa em análise, a previsão de demanda desempenha um papel fundamental. A empresa segue uma política consistente de manter um estoque mínimo de 40% e um estoque máximo de 95% da capacidade disponível em seu centro de distribuição. Embora esse nível de estoque atenda às necessidades de produtos de alta rotatividade, produtos com menor saída permanecem armazenados por períodos prolongados, ocupando espaço valioso e representando um investimento inativo significativo para a empresa.

Em certos momentos, o supermercado se depara com dificuldades na manutenção de níveis apropriados de produtos de alta demanda em estoque, devido à ocupação de espaço por produtos de menor rotatividade. Isso ocorre porque a empresa não implementa de maneira eficaz a previsão de demanda para cada um dos itens comercializados, resultando em níveis inadequados de estoque e custos de manutenção elevados.

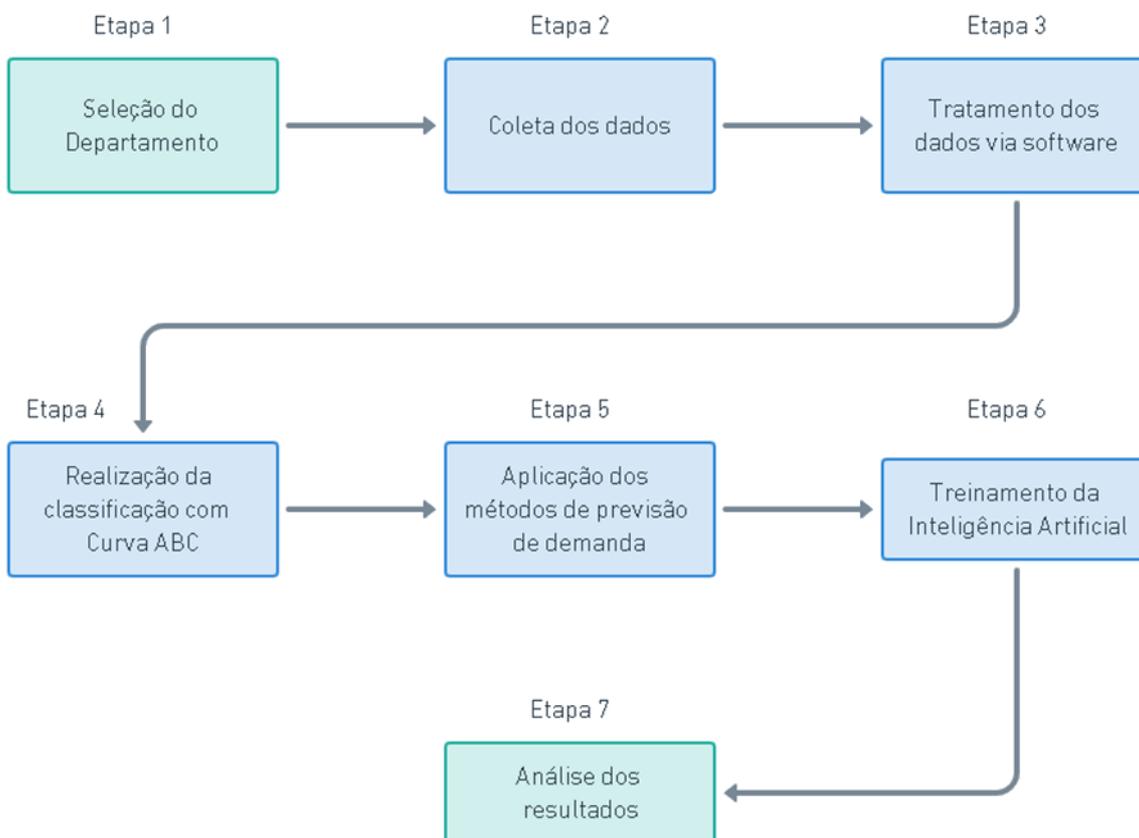
### 3.2.2 Etapas da pesquisa

A pesquisa em questão foi conduzida seguindo uma estrutura metodológica composta por etapas fundamentais, que incluirão desde a coleta inicial de dados até a análise dos resultados. Cada uma dessas etapas é planejada e executada com o propósito central de analisar as dinâmicas de vendas e demanda de um departamento específico.

A Figura 6 fornece uma representação visual das etapas que são integralmente incorporadas ao processo metodológico desta pesquisa. Essa representação visual contribuirá para uma compreensão nítida e estruturada das etapas conduzidas no estudo.

**Figura 6**

*Fluxograma das etapas da pesquisa*



Fonte: Do autor

Na primeira etapa, foi realizada a seleção do departamento analisado. A escolha do departamento foi feita com base nos dados da estrutura mercadológica atual do supermercado, constituída por departamento, seção, grupo e subgrupo, utilizando a Teoria de Pareto (W. Santos et al., 2017).

Após a escolha do departamento, foi realizado o levantamento dos dados históricos de vendas dos produtos do ano anterior ao corrente, diretamente do sistema de *business intelligence* (BI) utilizado pelo supermercado, desenvolvido na linguagem Flutter, onde são registradas todas as entradas e saídas de produtos. A escolha desse intervalo de tempo se deveu ao fato de que os produtos podem sofrer alterações ao longo do ano, assim como seus códigos de barras, além das rápidas mudanças no mercado e no comportamento dos consumidores.

Em seguida, a terceira etapa envolveu o tratamento e a organização desses dados, utilizando a ferramenta PgAdmin 4 do banco de dados relacional PostgreSQL e planilhas eletrônicas para filtrar

e classificar os valores exportados. Essa etapa foi fundamental para preparar os dados e facilitar os cálculos subsequentes.

Na quarta etapa, foi realizada uma análise da classificação dos produtos de acordo com a curva ABC, resultando na elaboração de um *ranking* dos produtos de maior giro no estoque, ou seja, aqueles com maior valor agregado ao supermercado no departamento selecionado na primeira etapa.

Na quinta etapa, foram aplicados os métodos quantitativos de previsão de demanda, conforme descritos na fundamentação teórica da pesquisa. Esses métodos permitiram entender e antecipar as variações na demanda ao longo do tempo, por meio de simulação de vendas, fornecendo informações valiosas para a gestão do departamento em questão.

Após a conclusão dos cálculos, foi realizada uma análise comparativa entre o desvio médio absoluto e o erro médio quadrático, além de uma análise gráfica de como a demanda real se comportou em relação à demanda prevista.

Na sexta etapa, foi implementada uma solução de inteligência artificial, treinada com os métodos aplicados ao produto estudado. Essa etapa envolveu a construção e treinamento de modelos de aprendizado de máquina, por meio da biblioteca LangcCain4j (*opensource*) na linguagem Java 21, utilizando os dados históricos sobre as vendas de 2023. A inteligência artificial, uma vez treinada, foi capaz de, mediante a entrada de determinados parâmetros, quantidade vendida no mês e valor de venda, prever qual o método de previsão de demanda seria mais assertivo para outros produtos dentro do mesmo departamento. Essa abordagem permitiu uma otimização contínua das estratégias de gestão de estoque, garantindo uma maior acurácia nas previsões e, conseqüentemente, uma melhor eficiência operacional.

A sétima etapa foi dedicada à análise dos resultados e à escolha do método de previsão mais apropriado para o supermercado.

### 3.3 PROCESSO DE COLETA DE DADOS

O processo de coleta de dados é uma etapa crucial em qualquer pesquisa, pois determina a qualidade e a relevância das informações que serão analisadas. No contexto desta pesquisa, o processo foi planejado e executado em sete etapas distintas, conforme descrito a seguir:

#### 3.3.1 Seleção do departamento

Para a seleção do departamento, foi aplicada a Teoria de Pareto, utilizando a Curva ABC em conjunto com uma análise das estatísticas de vendas. Esse procedimento possibilitou a identificação do departamento de maior relevância e contribuição para o desempenho global do supermercado.

### **3.3.2 Coleta dos dados históricos de vendas**

Os dados históricos de vendas foram coletados diretamente do sistema de *Business Intelligence (BI)* da empresa, que registra todas as transações de vendas. Foram extraídos dados do ano de 2023 para garantir uma amostra representativa e atualizada, considerando variações sazonais e promoções.

### **3.3.3 Tratamento e organização dos dados**

Os dados coletados foram exportados e tratados utilizando uma combinação de ferramentas de banco de dados relacional e planilhas eletrônicas. Esta etapa envolveu a limpeza dos dados, a remoção de inconsistências, a organização por categoria e a filtragem para incluir os produtos do departamento selecionado.

### **3.3.4 Classificação dos Produtos com Curva ABC**

Após a organização dos dados, foi realizada uma análise de classificação dos produtos do departamento utilizando a metodologia da Curva ABC. Os produtos foram categorizados em três grupos (A, B e C) com base em seu valor e volume de vendas. Isso permitiu a identificação dos produtos de maior relevância financeira para o supermercado.

### **3.3.5 Métodos de previsão de demanda**

Os métodos quantitativos de previsão de demanda (Média Móvel Simples, Média Móvel Ponderada, Média Móvel Exponencial e Projeção de Tendências) foram aplicados aos dados históricos de vendas. Cada método foi implementado conforme descrito na fundamentação teórica desta pesquisa e suas previsões foram geradas para o período do estudo.

### **3.3.6 Treinamento da Inteligência Artificial**

Foi desenvolvido e treinado um modelo de inteligência artificial (IA) utilizando técnicas de aprendizado de máquina. O modelo foi implementado com os dados históricos de vendas e as previsões geradas pelos métodos quantitativos. O treinamento envolveu a definição de parâmetros como período de análise, pesos para a Média Móvel Ponderada e fator de suavização para a Média Móvel Exponencial.

### 3.3.7 Análise comparativa

Uma análise comparativa foi realizada utilizando métricas como o Desvio Médio Absoluto (DMA) e o Erro Médio Quadrático (EMQ) para avaliar a precisão dos métodos de previsão. Além disso, gráficos foram gerados para visualizar a comparação entre a demanda real e a demanda prevista.

## 3.4 PROCESSO DE ANÁLISE DE DADOS

O processo de análise de dados é um componente essencial da pesquisa, uma vez que permite a extração de dados que podem direcionar decisões estratégicas. Este processo foi conduzido de maneira iterativa, possibilitando ajustes conforme novas informações se tornavam disponíveis. As etapas envolvidas na análise de dados são delineadas a seguir, seguidas por uma avaliação detalhada da assertividade dos métodos de previsão aplicados, bem como a implementação e testes de um *plugin* criado para o *Generative pre-trained transformer* (GPT-4).

*Plugins* são programas que aprimoram a funcionalidade de uma aplicação de software ao se conectarem através de uma interface específica do programa, expandindo os recursos e capacidades operacionais. Esses componentes são essenciais no desenvolvimento moderno de *software*, permitindo a integração e implementação de funções adicionais que não estavam presentes no sistema original (Zhang, 2017). No caso deste estudo, o *plugin* foi desenvolvido para permitir que o GPT-4, um modelo avançado de inteligência artificial criado pela OpenAI, realizasse análises dos métodos de previsão de demanda. O GPT-4 tem a capacidade de processar e interpretar grandes volumes de dados, oferecendo dados precisos sobre a assertividade das previsões. A implementação desta ferramenta proporcionou a integração das previsões geradas pelos métodos tradicionais com a análise avançada oferecida pela IA melhorando a precisão dos resultados.

### 3.4.1 Compreensão Inicial dos Dados

Inicialmente, foi realizada uma revisão da estrutura dos dados coletados, incluindo a verificação de inconsistência e erros. Estatísticas descritivas básicas, como média, mediana, desvio padrão e variância, foram calculadas para entender a distribuição e as tendências centrais dos dados.

### **3.4.2 Identificação de Padrões e Correlações**

Técnicas gráficas e analíticas de correlações foram utilizadas para identificar padrões e correlações nos dados de vendas. Gráficos de linha foram criados para visualizar as variações nas vendas ao longo do tempo e entender as dinâmicas de demanda.

### **3.4.3 Modelagem Estatística e Predição**

Os métodos de previsão de demanda foram aplicados aos dados históricos. Cada método (Média Móvel Simples, Média Móvel Ponderada, Média Móvel Exponencial e Projeção de Tendências) foi implementado conforme as fórmulas estabelecidas. As previsões foram geradas para o período de estudo (ano de 2023) e comparadas com a demanda real.

### **3.4.4 Análise de Sensibilidade**

Para investigar o impacto de diferentes variáveis nas previsões, foram conduzidas análises de sensibilidade. Esta etapa envolveu a simulação de diferentes cenários e a avaliação de como mudanças em variáveis-chave (como fatores sazonais e promocionais) poderiam afetar os resultados das previsões.

### **3.4.5 Comparação das Previsões dos Modelos**

A precisão dos métodos de previsão foi avaliada utilizando métricas como o Desvio Médio Absoluto (DMA) e o Erro Médio Quadrático (EMQ). Foram calculadas as diferenças entre a demanda real e as previsões geradas por cada método. Os resultados foram organizados em tabelas para facilitar a comparação.

### **3.4.6 Implementação e Testes do Plugin GPT-4**

Foi desenvolvido um *plugin* para o GPT-4, para analisar os métodos de previsão de demanda e calcula a assertividade das previsões. O *plugin* foi testado com diferentes conjuntos de dados para garantir sua eficácia. Os resultados das previsões geradas pelo plugin foram comparados com as previsões dos métodos tradicionais, utilizando as mesmas métricas de precisão (DMA e EMQ).

## 4 RESULTADOS E DISCUSSÃO

Nesta seção, são apresentados os resultados da aplicação dos métodos de previsão de demanda, destacando os achados científicos e as implicações para a gestão de estoques em supermercados. A análise comparativa entre os métodos é discutida em profundidade, e são sugeridas possíveis aplicações práticas para otimizar a gestão de estoques com base nos resultados obtidos.

A pesquisa utilizou dados históricos de vendas do supermercado para analisar e comparar diferentes métodos de previsão de demanda, como média móvel simples, média móvel ponderada, média móvel exponencial e projeção de tendências. Os métodos foram aplicados a um conjunto de dados pré-processados, que passou por etapas de tratamento como a remoção de *outliers* e normalização. *Outliers* são observações que se desviam significativamente do restante dos dados, podendo resultar de erros de medição ou representar eventos raros. A remoção de *outliers* é uma etapa essencial no pré-processamento de dados, pois a presença desses valores extremos pode distorcer os resultados e reduzir a precisão das previsões (Hiren R. Kavathiya & Dr. G. C. Bhimani, 2019).

Os resultados mostraram que os métodos baseados em médias móveis (ponderada e exponencial) apresentaram os melhores resultados em termos de precisão, de acordo com as métricas de desvio médio absoluto (DMA) e erro médio quadrático (EMQ). A média móvel ponderada foi o método mais assertivo, com os menores valores de DMA e EMQ, o que corrobora com estudos anteriores que apontam a eficácia da ponderação para capturar melhor a demanda em cenários de alta variabilidade (Zhu et al., 2015).

Os testes iniciais foram realizados com o produto Óleo de Soja Coamo PET 900ml, onde os métodos aplicados foram comparados diretamente com a demanda real. Posteriormente, o sistema foi expandido para incluir 3.230 produtos do departamento de mercearia seca, permitindo uma avaliação mais ampla dos resultados.

Por fim, os apontamentos apresentados permitem uma reflexão sobre a eficiência dos diferentes métodos de previsão aplicados, destacando as vantagens da automatização do processo através do *plugin* GPT-4. Esses resultados sugerem que a utilização de ferramentas baseadas em IA e a integração de diferentes modelos de previsão podem contribuir significativamente para a melhoria da gestão de estoques em supermercados. A capacidade de prever com maior precisão a demanda de produtos pode reduzir desperdícios, otimizar a reposição de estoques e, conseqüentemente, aumentar a eficiência operacional. Esse estudo reforça a necessidade de adoção de tecnologias avançadas para tornar a gestão de estoques mais eficaz e sustentável. O passo a passo de como essa pesquisa foi conduzida e implementada seguirá nos tópicos subsequentes.

#### 4.1.1 Escolha do departamento

Conforme discutido anteriormente, para a seleção do departamento, aplicou-se a Teoria de Pareto (W. Santos et al., 2017), utilizando a Curva ABC, em conjunto com uma análise das estatísticas de vendas. Este procedimento possibilitou a identificação do departamento de maior relevância e contribuição para o desempenho global do mercado, constituindo o ponto central desta pesquisa.

A estrutura mercadológica atual do supermercado é constituída por 17 departamentos, nos quais, após a aplicação da Teoria de Pareto, foi possível identificar quais pertencem ao Ranking A, B ou C. Classificados como A, encontrou-se 4 departamentos, indicando um nível significativamente maior de relevância em comparação com os demais. Além disso, 3 departamentos foram classificados como categoria B, enquanto os restantes receberam a classificação C, como demonstrado na Tabela 3 a seguir:

**Tabela 3**

*Teoria de Pareto aplicado nos Departamentos*

Classificação	Ranking	Departamento	% Participação	Venda Total 2023
A	1	MERCEARIA SECA	23,859	55.011.999,02
A	2	MERCEARIA LIQUIDA	16,579	38.227.339,41
A	3	FRIOS	14,446	33.308.588,06
A	4	FLV (HORTIFRUTI)	11,255	25.949.867,64
B	5	ACOUGUE	9,346	21.548.393,39
B	6	PADARIA	6,259	14.432.107,90
B	7	PERFUMARIA	5,655	13.039.177,28
C	8	LEITE LÍQUIDO	4,269	9.842.255,22
C	9	LIMPEZA GERAL	3,677	8.477.926,05

C	10	BAZAR	2,595	5.983.656,81
C	11	FOODS	0,695	1.602.338,09
C	12	PET SHOP	0,592	1.365.395,60
C	13	EXCLUSAO FUTURA	0,458	1.055.079,44
C	14	TABACARIA	0,224	517.149,97
C	15	USO INTERNO	0,046	105.224,42
C	16	IMPORTACAO	0,028	63.500,63
C	17	CESTAS	0,018	42.179,96

Fonte: Do autor

Dessa forma, considerando os resultados da aplicação da Teoria de Pareto e a análise da Curva ABC (W. Santos et al., 2017), o departamento de mercearia seca foi selecionado para o estudo detalhado. Este departamento, que ocupa o primeiro lugar no ranking com uma participação de 23,859% e um total de vendas de R\$ 55.011.999,02 no ano de 2023, destaca-se como o mais relevante em termos de contribuição para o desempenho global do mercado. A escolha de mercearia seca se justifica pela sua expressiva participação e impacto nas vendas totais, tornando-o o foco ideal para a investigação e desenvolvimento das estratégias propostas nesta pesquisa.

#### 4.1.2 Histórico de vendas

Para coleta dos dados históricos foi utilizado o sistema de *Business Intelligence* (BI) do supermercado, uma ferramenta que registra todas as transações de vendas. Por intermédio dele foi possível coletar dados de vendas agrupadas por departamento e sua classificação do ano de 2023, conforme ilustrado na Tabela 4:

**Tabela 4**

*Vendas anuais agrupadas por departamento*

Classificação	Quantidade de Departamento	% Quantidade	Venda	% Venda
A	4	22.2	152.497.794,13	66.1
B	3	16.7	49.019.678,57	21.3
C	10	61.1	29.054.706,19	12.6
=	17	100.0	230.572.178,89	100.0

Fonte: Do autor

Com os dados históricos de vendas do departamento mercearia seca, a etapa seguinte será de tratamento e organização dos dados.

#### 4.1.3 Seleção do Produto estudado

Com a seleção do departamento, foi possível realizar uma análise da classificação dos produtos do departamento utilizando a metodologia da Curva ABC. Assim como na seleção do departamento, esta técnica, amplamente utilizada na gestão de estoques, permitiu a elaboração de um ranking dos produtos baseado em seu giro e relevância financeira para o supermercado. Os produtos, ao serem categorizados em três grupos A, B e C, podem destacar os itens de maior valor agregado.

O departamento mercearia seca contém 3.230 produtos. Para título de amostragem, a tabela 5 apresenta os 3 primeiros produtos de cada classificação.

**Tabela 5**

*Teoria de Pareto aplicado nos produtos do departamento mercearia seca*

Classificação	Produto	Venda Total	Giro mensal
A	OLEO DE SOJA COAMO PET 900ML	1.153.259,46	2.829
A	CAFÉ MELITA TRAD 500GR	888.557,29	2.270
A	CAFÉ PILAO TRAD 500GR	888.150,17	2.074

B	BISCOITO ZEZE MIGNON 200GT	44.189,18	2.541
B	ACUCAR CRISTAL ALTO ALEGRE 2KG	44.119,06	1.127
B	CHOLATE LACTA BARRA LAKA/OREO 165GR	44.050,24	3.194
C	ROSQUINHA GIRASSOL Z 270GR	10.300,38	1.630
C	ERVILHA CONSERVA ODERICH 200GR	10.285,87	0.909
C	BATATA PALHA ELMA CHIPS TRAD 100GR	10.263,11	0.536

Fonte: Do autor

Com base nesta coleta, o produto óleo de soja Coamo pet 900 ml foi escolhido para um estudo mais detalhado. Este produto, destacado na classificação A, não só possui o maior valor de vendas totais, mas também apresenta um giro mensal significativo, evidenciando sua relevância e impacto nas vendas do departamento mercearia seca.

A tabela 6 abaixo mostra a quantidade mensal vendida e o valor total vendido do produto óleo de soja Coamo pet 900 ml em cada mês do ano de 2023, fornecendo uma visão detalhada do desempenho de vendas ao longo do ano.

**Tabela 6**

*Visão do desempenho mensal de vendas em 2023*

<b>Período</b>	<b>Quantidade Vendida</b>	<b>Valor Total Vendido</b>
<b>Janeiro</b>	14.440	R\$ 111.131,83
<b>Fevereiro</b>	23.155	R\$ 157.283,58
<b>Março</b>	9.611	R\$ 65.850,63
<b>Abril</b>	8.766	R\$ 56.942,96
<b>Mai</b>	17.160	R\$ 83.814,71
<b>Junho</b>	21.860	R\$ 108.279,93
<b>Julho</b>	53.889	R\$ 259.156,12
<b>Agosto</b>	32.981	R\$ 166.051,87
<b>Setembro</b>	15.759	R\$ 82.322,68
<b>Outubro</b>	7.065	R\$ 38.418,36

<b>Novembro</b>	4.158	R\$ 22.007,59
<b>Dezembro</b>	354	R\$ 1.179,20
<b>TOTAL</b>	209.198	R\$ 1.152.439,46

Fonte: Do autor

Para obter uma visão mais clara da demanda real do produto ao longo do ano de 2023, o gráfico abaixo contém a quantidade e vendas de todos os meses do ano, permitindo uma visão detalhada das tendências de consumo deste produto no supermercado, conforme demonstrado na Figura 7.

**Figura 7**

*Demanda Real do Produto OLEO DE SOJA COAMO PET 900ML em 2023*



Fonte: Do autor

A **Figura 7** evidencia que os meses de julho e agosto apresentaram picos significativos nas vendas, o que pode estar relacionado a fatores sazonais ou a promoções específicas. Esses dados reforçam a importância de prever corretamente a demanda em períodos de alta demanda, de forma a evitar rupturas de estoque ou excessos que possam gerar custos adicionais. A observação dessas variações sazonais é crucial para ajustar os métodos de previsão e garantir que a gestão de estoque seja alinhada com as flutuações de consumo, permitindo uma maior eficiência nas operações de reposição e uma melhor adequação ao comportamento dos consumidores ao longo do ano.

#### 4.1.4 Detalhamento dos Métodos de previsão de demanda

Com o produto de maior relevância identificado, foram aplicados os métodos de previsão de demanda — média móvel simples, média móvel ponderada, média móvel exponencial e projeção de

tendências — aos dados históricos de estoque e vendas do ano 2023. Aplicou-se a fórmula da Média Móvel Simples (MMS) levando em consideração 3 períodos ( $n=3$ ), conforme Tabela 7 abaixo:

**Tabela 7**

*Aplicação da Média Móvel Simples no ano de 2023*

Período	Valores Considerados	Nº de Períodos	Média Móvel Simples
Março	14.440 + 23.155	2	18.797
Abril	14.440 + 23.155 + 9.611	3	15.735
Maio	23.155 + 9.611 + 8.766	3	13.844
Junho	9.611 + 8.766 + 17.160	3	11.845
Julho	8.766 + 17.160 + 21.860	3	15.928
Agosto	17.160 + 21.860 + 53.889	3	30.303
Setembro	21.860 + 53.889 + 32.981	3	36.243
Outubro	53.889 + 32.981 + 15.759	3	34.209
Novembro	32.981 + 15.759 + 7.065	3	18.601
Dezembro	15.759 + 7.065 + 4.158	3	8.327

Fonte: Do autor

A escolha de  $n = 3$  para o cálculo da média móvel simples foi feita com base na necessidade de suavizar as flutuações de curto prazo nos dados de vendas, sem perder de vista as tendências mais recentes. Um número menor de períodos ( $n$ ) poderia resultar em previsões mais voláteis, pois seria muito sensível às variações pontuais de vendas de cada mês. Já um valor maior poderia suavizar demais os dados, ocultando mudanças importantes no comportamento de compra (Nikulchenko, 2018). Assim, o valor de 3 períodos foi considerado ideal para capturar a tendência geral de consumo enquanto ainda reflete de forma adequada as mudanças sazonais e eventos específicos ao longo do ano de 2023, como observado nas variações mensais apresentadas na Tabela 7.

Para Média Móvel Ponderada (MMP) foi considerado pesos 1, 2 e 3 para os três períodos ( $n = 3$ ):

**Tabela 7**

*Aplicação da Média Móvel Ponderada no ano de 2023*

Período	Valores Considerados	Pesos	Média Móvel Ponderada
Março	$(14.440 * 1 + 23.155 * 2)$	1+2	20.250
Abril	$(14.440 * 1 + 23.155 * 2 + 9.611 * 3)$	1+2+3	14.930
Maio	$(23.155 * 1 + 9.611 * 2 + 8.766 * 3)$	1+2+3	11.445

Junho	$(9.611 * 1 + 8.766 * 2 + 17.160 * 3)$	1+2+3	13.103
Julho	$(8.766 * 1 + 17.160 * 2 + 21.860 * 3)$	1+2+3	18.111
Agosto	$(17.160 * 1 + 21.860 * 2 + 53.889 * 3)$	1+2+3	37.091
Setembro	$(21.860 * 1 + 53.889 * 2 + 32.981 * 3)$	1+2+3	38.096
Outubro	$(53.889 * 1 + 32.981 * 2 + 15.759 * 3)$	1+2+3	27.854
Novembro	$(32.981 * 1 + 15.759 * 2 + 7.065 * 3)$	1+2+3	14.282
Dezembro	$(15.759 * 1 + 7.065 * 2 + 4.158 * 3)$	1+2+3	7.060

Fonte: Do autor

A escolha dos pesos 1, 2 e 3 na aplicação da média móvel ponderada (MMP) para três períodos ( $n = 3$ ), se justifica porque os pesos foram definidos com base na necessidade de atribuir maior importância aos dados mais recentes. A ponderação crescente (1 para o período mais antigo, 2 para o intermediário e 3 para o mais recente) tem como objetivo refletir o fato de que as vendas mais recentes possuem maior relevância na previsão futura, pois capturam com maior precisão as variações recentes na demanda. Essa abordagem ajuda a suavizar flutuações de curto prazo sem negligenciar as tendências emergentes, resultando em uma previsão mais ajustada à realidade do mercado (Nikulchenko, 2018). Além disso, ao aplicar essa ponderação, busca-se evitar a subestimação de eventos sazonais ou mudanças súbitas no comportamento de consumo que possam impactar a demanda de forma significativa ao longo de 2023.

Em relação à Média Móvel Exponencial (MME), conforme demonstrado na Tabela 9, foi considerado um fator de suavização de 0.5:

**Tabela 8**

*Aplicação da Média Móvel Exponencial no ano de 2023*

Período	Valores Considerados	Média Móvel Exponencial
Março	$(0.5 * 9.611) + (0.5 * 18.797)$	14.204
Abril	$(0.5 * 8.766) + (0.5 * 14.204)$	7.106
Maio	$(0.5 * 17.160) + (0.5 * 7.106)$	12.133
Junho	$(0.5 * 21.860) + (0.5 * 12.133)$	16.997
Julho	$(0.5 * 53.889) + (0.5 * 16.997)$	35.443
Agosto	$(0.5 * 32.981) + (0.5 * 35.443)$	34.215
Setembro	$(0.5 * 15.759) + (0.5 * 34.215)$	24.987
Outubro	$(0.5 * 7.065) + (0.5 * 24.987)$	16.026

Novembro	$(0.5 * 4.158) + (0.5 * 16.026)$	10.092
Dezembro	$(0.5 * 354) + (0.5 * 10.092)$	5.223

Fonte: Do autor

A escolha de um fator de suavização de 0,5 para a aplicação da média móvel exponencial (MME) foi feita para equilibrar a sensibilidade às mudanças recentes e a estabilidade das previsões. O fator de suavização, também conhecido como alpha ( $\alpha$ ), determina o peso dado aos dados mais recentes em relação aos valores anteriores. Um valor de 0,5 implica que tanto o valor atual quanto o anterior têm a mesma importância no cálculo da previsão. Optar por 0,5 garante que as variações mais recentes sejam incorporadas ao modelo de previsão de maneira significativa, mas sem que as flutuações extremas dominem completamente as tendências de longo prazo. Se fosse utilizado um fator de suavização menor, como 0,3 por exemplo, as previsões seriam mais estáveis, mas menos responsivas às mudanças recentes. Por outro lado, um valor maior, como 0,7, aumentaria a sensibilidade do modelo, tornando-o mais volátil. Portanto, o valor de 0,5 é um meio-termo adequado, proporcionando previsões que respondem adequadamente às variações de demanda observadas ao longo do ano de 2023 (Wijaya et al., 2023).

Para a Projeção de Tendências foi utilizado a regressão linear, usando os dados de quantidade vendida como variável dependente (Y) e o período (mês) como variável independente (X), apontado na Tabela 10 abaixo:

**Tabela 9**

*Aplicação da Projeção de Tendências no ano de 2023*

<b>Período</b>	<b>Quantidade Vendida (Y)</b>
Março	20.239
Abril	19.437
Maio	18.635
Junho	17.834
Julho	17.032
Agosto	16.230
Setembro	15.428
Outubro	14.627

Novembro	13.825
Dezembro	13.023

Fonte: Do autor

A projeção de tendências, baseada em regressão linear, foi escolhida para identificar o comportamento da demanda ao longo do tempo, utilizando os dados históricos de vendas mensais. A regressão linear simples é uma técnica amplamente usada para modelar a relação entre uma variável dependente (no caso, a quantidade vendida) e uma variável independente (o tempo, representado pelos meses). Ao aplicar essa técnica, foi possível capturar a tendência de queda nas vendas ao longo do ano de 2023, conforme ilustrado na Tabela 10. Essa técnica é particularmente útil para identificar padrões sazonais ou mudanças estruturais na demanda, e pode ser aplicada em contextos em que o comportamento de venda apresenta uma tendência clara e relativamente linear, como o observado no ano de 2023 (Wijaya et al., 2023).

Os resultados dessas previsões foram comparados com a demanda real no mesmo período para avaliar a precisão de cada método, conforme apontado na Tabela 11.

**Tabela 10**

*Comparativo dos métodos de projeção no ano de 2023 em relação a demanda real*

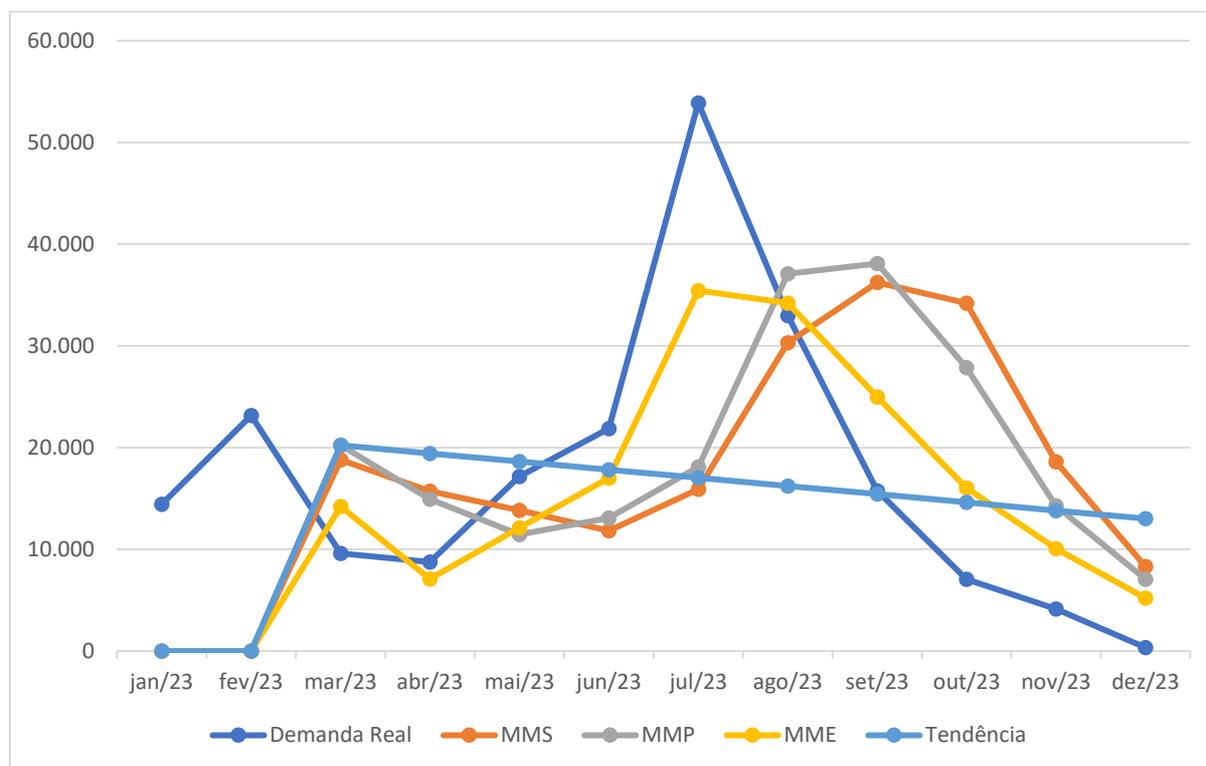
Período	Demanda Real	MMS	MMP	MME	Tendência
Janeiro	14.440	-	-	-	-
Fevereiro	23.155	-	-	-	-
Março	9.611	18.797	20.250	14.204	20.239
Abril	8.766	15.735	14.930	11.485	19.437
Maiο	17.160	13.844	11.445	12.133	18.635
Junho	21.860	11.845	13.103	16.997	17.834
Julho	53.889	15.928	18.111	35.443	17.032
Agosto	32.987	30.303	37.091	34.215	16.230
Setembro	15.759	36.243	38.096	24.987	15.428
Outubro	7.065	34.209	27.865	16.026	14.627
Novembro	4.158	18.601	14.282	10.092	13.825
Dezembro	354	8.327	7.060	5.223	13.023

Fonte: Do autor

Abaixo, na Figura 8, é apresentado um gráfico comparativo dos métodos de previsão aplicados em relação a demanda real do produto, conforme Figura 8.

**Figura 8**

*Comparativo em relação a demanda real*



Fonte: Do autor

A comparação entre os métodos tradicionais de previsão de demanda — Média Móvel Simples, Média Móvel Ponderada, Média Móvel Exponencial e Projeção de Tendências — com o modelo de IA desenvolvido revelou uma melhora substancial na precisão das previsões. Essa superioridade da IA em relação aos métodos tradicionais já foi amplamente discutida na literatura, conforme evidenciado por González Perea et al. (2019), que argumentam que técnicas como *deep learning* e redes neurais artificiais são capazes de capturar relações não lineares e padrões complexos nos dados, proporcionando previsões mais adaptáveis e precisas em ambientes voláteis.

Os resultados deste estudo indicam que o modelo de IA foi particularmente eficaz em antecipar variações sazonais e eventos inesperados no comportamento de compra dos consumidores. Como discutido por Rogulin (2023), uma das principais vantagens dos modelos de IA é sua capacidade de processar grandes volumes de dados e identificar padrões que métodos tradicionais, como as médias móveis falham em detectar. No contexto dos supermercados, onde a volatilidade de demanda é elevada, essa capacidade se mostrou crucial para a precisão das previsões.

#### 4.1.5 Treinamento da Inteligência Artificial

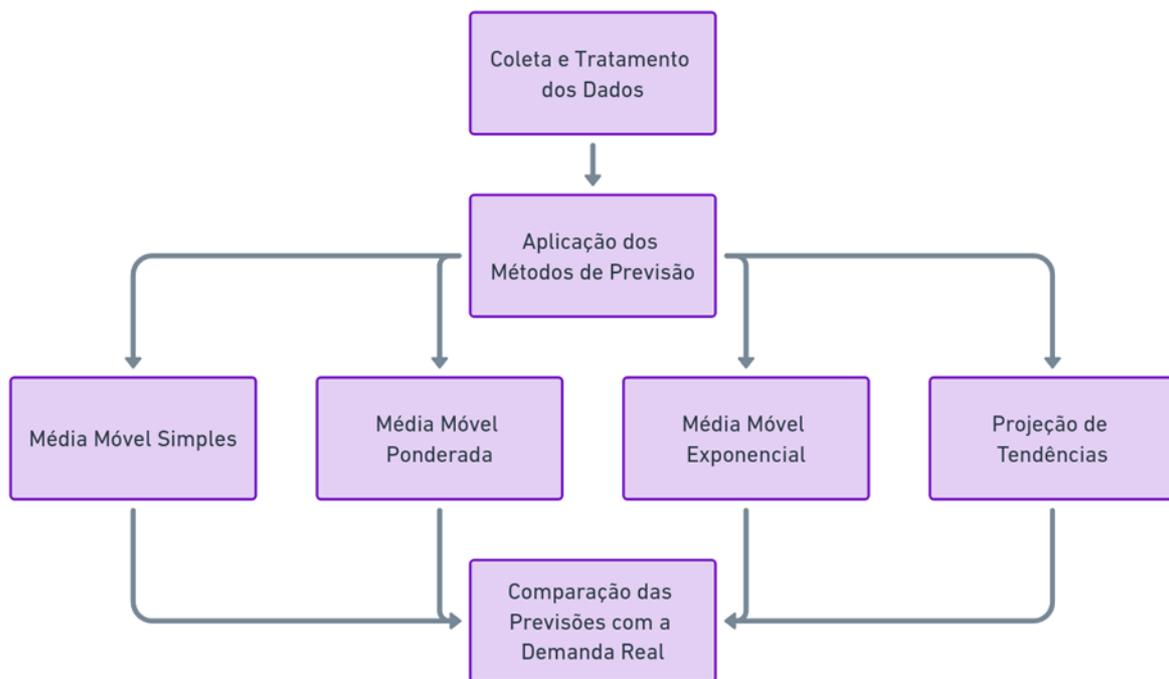
Inicialmente, os dados históricos de vendas foram coletados, tratados e organizados para garantir sua qualidade. Esse tratamento incluiu a remoção de *outliers* e a normalização dos dados, conforme recomendado por Bansal et al. (2016), para garantir que os valores extremos não distorcessem as previsões.

Após o tratamento, cada método de previsão — Média Móvel Simples, Média Móvel Ponderada, Média Móvel Exponencial e Projeção de Tendências — foi aplicado aos dados. As previsões geradas foram comparadas com a demanda real utilizando métricas de precisão, como o Desvio Médio Absoluto (DMA) e o Erro Médio Quadrático (EMQ).

A Figura 9 ilustra esse processo inicial, desde a coleta e tratamento dos dados até a aplicação das médias móveis e a projeção de tendências.

**Figura 9**

*Fluxograma para os processos de tratamento dos dados*



Fonte: Do autor

Para guiar o treinamento do modelo de IA, foram elaborados *prompts*, garantindo a aplicação correta dos métodos de previsão e a análise detalhada dos resultados. No contexto de inteligência artificial, *prompts* são instruções ou exemplos fornecidos ao modelo para direcionar sua tarefa. Servem como uma maneira de orientar o comportamento da IA ao resolver problemas ou gerar respostas em tarefas específicas. A eficácia do modelo depende em grande parte da qualidade dos *prompts* utilizados (Gonen et al., 2022). Esses *prompts* foram essenciais para orientar o comportamento da IA ao resolver problemas ou gerar previsões. Exemplos utilizados no treinamento da IA incluem:

- **Organização e Tratamento dos Dados:**

“Os dados históricos de vendas do produto XYZ foram coletados. Primeiro, organize e trate os dados para garantir a qualidade. Em seguida, aplique os seguintes métodos de previsão de demanda: Média Móvel Simples, Média Móvel Ponderada, Média Móvel Exponencial e Projeção de Tendências. Calcule as métricas de precisão (DMA e EMQ) para cada método e compare com a demanda real”.

- **Aplicação dos Métodos de Previsão:**

“Dado o conjunto de dados de vendas do produto XYZ, aplique a Média Móvel Simples com uma janela de 3 períodos. Mostre as previsões e compare com os dados reais.”

“Dado o conjunto de dados de vendas do produto XYZ, aplique a Média Móvel Ponderada com pesos 1, 2, e 3. Mostre as previsões e compare com os dados reais.”

“Dado o conjunto de dados de vendas do produto XYZ, aplique a Média Móvel Exponencial com fator de suavização  $\alpha = 0.5$ . Mostre as previsões e compare com os dados reais.”

“Dado o conjunto de dados de vendas do produto XYZ, aplique a Projeção de Tendências utilizando regressão linear. Mostre as previsões e compare com os dados reais.”

- **Cálculo das Métricas de Precisão:**

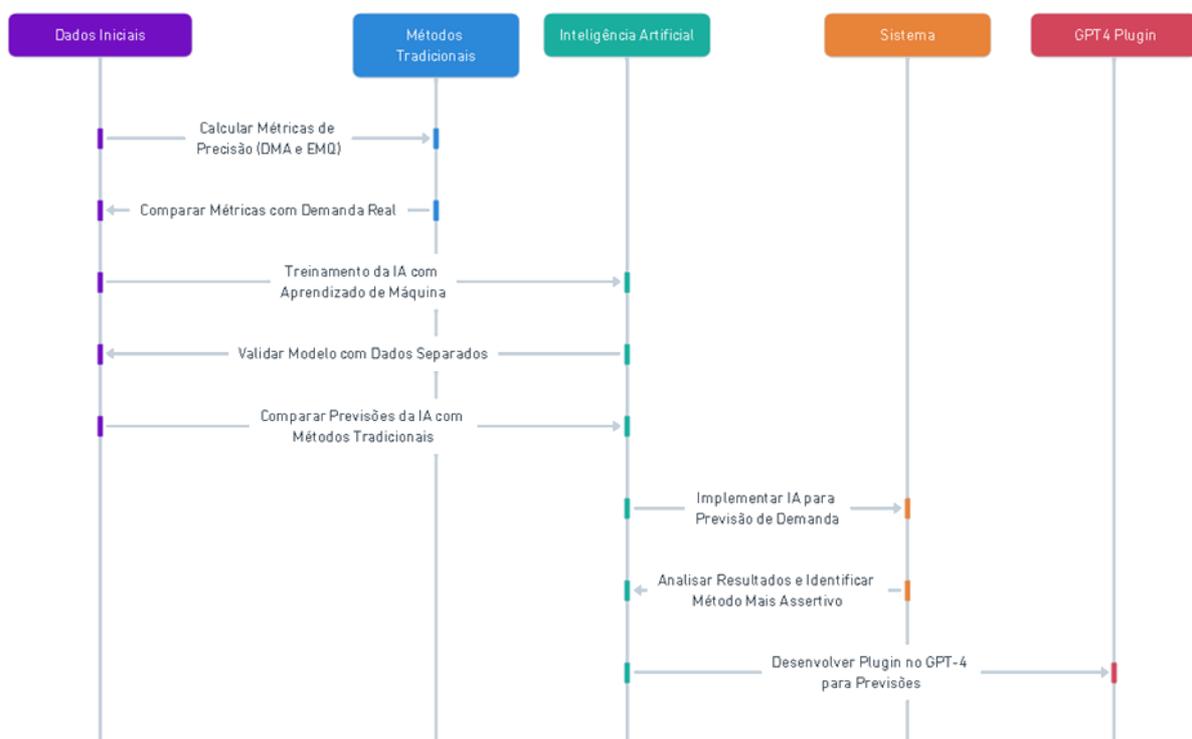
“Para as previsões geradas pelos métodos de previsão de demanda aplicados ao produto XYZ, calcule o Desvio Médio Absoluto (DMA) e o Erro Médio Quadrático (EMQ). Compare as métricas com a demanda real.”

Após a aplicação dos métodos tradicionais e a análise das métricas de precisão, o modelo de IA foi treinado utilizando técnicas de aprendizado de máquina. O objetivo do treinamento foi permitir que a IA identificasse padrões e tendências nos dados históricos, resultando em previsões mais precisas. Conforme apontado por Henriques et al. (2024), a capacidade da IA de lidar com grandes volumes de dados e identificar padrões complexos foi crucial para o sucesso do treinamento.

A figura 10 mostra as etapas seguintes, desde o cálculo das métricas de precisão até a validação e implementação de IA:

**Figura 10**

*Fluxograma para os processos de tratamento dos dados*



Fonte: Do autor

A validação do modelo de IA foi realizada utilizando um conjunto de dados separado (dados de teste), prática comum em modelos de aprendizado de máquina. Esses dados não foram utilizados durante o treinamento, garantindo uma avaliação imparcial do modelo. Segundo Mediavilla et al. (2022), a separação entre dados de treino e teste é essencial para simular situações do mundo real e verificar como o modelo se comporta com dados novos. As previsões geradas pela IA foram então comparadas com as previsões dos métodos tradicionais — Média Móvel Simples, Média Móvel Ponderada, Média Móvel Exponencial e Projeção de Tendências — utilizando as mesmas métricas de

precisão, como o Desvio Médio Absoluto (DMA) e o Erro Médio Quadrático (EMQ). Esse processo de validação permitiu avaliar de forma objetiva a eficácia do modelo de IA em relação aos métodos tradicionais, mensurando sua capacidade de generalização e precisão com dados novos, conforme descrito por Runge et al. (2023).

Após a validação, a IA treinada foi implementada para prever a demanda de outros produtos no supermercado. As previsões foram analisadas para identificar o método mais assertivo para cada tipo de produto, ajustando parâmetros como o período de análise e o fator de suavização.

Com base nesses resultados, foi desenvolvido um *plugin* no GPT-4 que permite a entrada de dados históricos de vendas e retorna previsões de demanda com a avaliação da assertividade de cada método. Essa ferramenta facilita a gestão de estoque e o planejamento de demanda em supermercados, conforme recomendado por Henriques et al. (2024).

#### 4.1.6 Comparação das Previsões dos Modelos

A comparação entre os métodos de previsão de demanda foi realizada utilizando duas métricas amplamente aceitas na literatura para avaliar a precisão das previsões: o Desvio Médio Absoluto (DMA) e o Erro Médio Quadrático (EMQ). Estas métricas fornecem uma visão clara da diferença entre os valores reais e os previstos, sendo fundamentais para avaliar a eficácia dos modelos de previsão. As fórmulas matemáticas utilizadas para o cálculo do DMA e do EMQ são apresentadas a seguir:

- Desvio Médio Absoluto (DMA) (Equação 5)

$$DMA = \frac{1}{n} \sum_{i=1}^n |Q_{real,i} - Q_{prev,i}| \quad (5)$$

- Erro Médio Quadrático (EMQ) (Equação 6)

$$EMQ = \frac{1}{n} \sum_{i=1}^n (Q_{real,i} - Q_{prev,i})^2 \quad (6)$$

O DMA mede a magnitude média dos erros entre os valores reais e previstos, enquanto o EMQ amplifica os erros maiores, tornando-o mais sensível a grandes desvios entre a demanda real e a prevista (Henriques & Nobre Pereira, 2024). Ambas as métricas são cruciais para entender o

desempenho dos métodos de previsão, mas o EMQ, por penalizar erros maiores, é particularmente útil para identificar grandes variações ou inconsistências nas previsões.

A Tabela 12 apresenta os valores do DMA e do EMQ calculados para cada método de previsão aplicado aos dados históricos de vendas.

**Tabela 11**

*Métricas DMA e EMQ*

<b>Método</b>	<b>DMA</b>	<b>EMQ</b>
<b>Média Móvel Simples</b>	8.695.800	117.184.900
<b>Média Móvel Ponderada</b>	6.232.017	58.684.000
<b>Média Móvel Exponencial</b>	6.256.762	60.205.330
<b>Projeção de Tendência</b>	11.063.790	219.549.400

Fonte: Do autor

A análise dos resultados indica que a média móvel ponderada foi o método de previsão mais assertivo, com os menores valores de DMA (6.232.017) e EMQ (58.684.000). Isso sugere que o uso de pesos para dar maior importância a períodos específicos ajudou a capturar melhor as flutuações da demanda ao longo do tempo. Em segundo lugar, a média móvel exponencial apresentou valores de DMA (6.256.762) e EMQ (60.205.330) próximos, o que indica que ambos os métodos conseguem capturar bem as variações, mas a ponderação proporciona uma ligeira vantagem.

Conforme discutido por Zhu et al. (2015), a ponderação dos períodos mais recentes em séries temporais ajuda a melhorar a precisão das previsões, especialmente em ambientes de alta variabilidade, como o varejo de supermercados.

Por outro lado, a projeção de tendência apresentou os maiores valores de DMA (11.063,790) e EMQ (219.549,400), refletindo sua limitação em capturar as rápidas variações na demanda. Como apontado por Runge et al. (2023), a projeção de tendências pode ser inadequada em contextos em que há uma alta volatilidade e mudanças frequentes no comportamento do consumidor.

Esses resultados corroboram com a literatura existente, que destaca a eficácia da média móvel ponderada e da média móvel exponencial em ambientes com demandas dinâmicas e a limitação de modelos baseados em tendências lineares simples para prever variações complexas e abruptas na demanda (Henriques & Nobre Pereira, 2024; Runge & Saloux, 2023).

A partir dos resultados obtidos, pode-se concluir que os métodos de média móvel ponderada e média móvel exponencial são mais adequados para previsões de demanda no contexto de

supermercados, onde há uma variabilidade significativa nos padrões de consumo. A escolha entre esses métodos depende da necessidade de suavização dos dados e da sensibilidade a variações mais recentes, sendo que ambos apresentam vantagens consideráveis sobre a projeção de tendências, que demonstrou ser menos eficaz para capturar mudanças rápidas no mercado.

Essas conclusões reforçam a importância de se utilizar métodos que ponderem de forma mais eficiente os dados mais recentes, e que possam ser adaptados para diferentes produtos e contextos de vendas, como sugerido por Zhu et al. (2015).

#### 4.1.7 Implementação e Testes do Plugin GPT-4

A implementação do *plugin* GPT-4 foi desenvolvida com o objetivo de automatizar e comparar diferentes métodos de previsão de demanda, aplicados à gestão de estoques em supermercados. Esse *plugin* foi construído utilizando linguagem de programação Java, que permite a execução dos cálculos e validações necessárias para prever a demanda futura de produtos. Os métodos de previsão integrados no *plugin* incluem Média Móvel Simples, Média Móvel Exponencial, Média Móvel Ponderada e Projeção de Tendências.

O *script* foi projetado para automatizar o processo de previsão de demanda, facilitando o uso por gestores de estoques e analistas. Ele recebe como entrada os dados históricos de vendas e aplica os métodos de previsão mencionados. A precisão do *plugin* foi garantida pela implementação de mecanismos de tratamento de dados, como a remoção de *outliers* e a normalização dos dados. Esses processos são essenciais para garantir que valores atípicos ou extremos não comprometam as previsões, conforme discutido por Bansal et al. (2016).

A interface do *plugin* foi configurada para ser intuitiva, permitindo que o usuário insira parâmetros como o número de períodos a serem considerados para cada método, bem como os pesos específicos no caso da média móvel ponderada. Além disso, o *plugin* foi desenhado para gerar um quadro comparativo com os resultados obtidos por cada método de previsão. As métricas de avaliação, como o desvio médio absoluto e o erro médio quadrático, são calculadas para cada método, facilitando a identificação do mais assertivo para o cenário de demanda analisado.

Os testes do *plugin* foram realizados em duas etapas distintas para assegurar sua eficácia e capacidade de generalização para diferentes produtos:

1. **Testes iniciais com o produto principal:** O produto escolhido para os testes iniciais foi o Óleo de Soja Coamo PET 900ml, identificado como um dos itens mais vendidos no departamento de mercearia seca. Os testes mostraram que o *plugin* foi capaz de gerar previsões com alta

precisão, comparando os resultados com a demanda real. O desempenho do plugin ao prever a demanda para esse produto específico forneceu uma base sólida para a validação dos métodos de previsão integrados, com a média móvel ponderada e a média móvel exponencial se destacando como os métodos mais assertivos, de acordo com as métricas DMA e EMQ.

2. **Testes em grande escala:** Após os testes iniciais, o plugin foi submetido a uma avaliação mais abrangente, envolvendo 3.230 produtos do mesmo departamento. Essa fase foi essencial para validar a robustez do sistema em diferentes cenários de demanda. Os resultados confirmaram que o *plugin* é capaz de oferecer previsões confiáveis e consistentes para uma grande variedade de produtos, demonstrando sua capacidade de generalização. As previsões para cada produto foram novamente avaliadas utilizando as mesmas métricas de precisão (DMA e EMQ), confirmando o bom desempenho dos métodos de previsão em diferentes contextos.

Os resultados dos testes evidenciaram que o *plugin* GPT-4 desenvolvido é uma ferramenta que pode ser utilizada para a previsão de demanda em supermercados, com potencial para otimizar a gestão de estoques e melhorar a eficiência operacional. Por exemplo, na análise de um conjunto de 20 produtos do departamento mercearia seca, observou-se que o sistema inicial utilizou o método Média Móvel Simples para prever a demanda e planejar o reabastecimento. Esse método resultou em um desvio médio significativo para produtos como o Óleo de Soja Coamo PET 900ml, que apresentou uma previsão inferior à demanda real, ocasionando ruptura de estoque.

A Tabela 13 ilustra os resultados dessa análise (excluindo o produto Óleo de Soja apresentado anteriormente), mostrando a previsão real utilizada pelo sistema comparando as previsões realizadas pelo plugin.

**Tabela 12**

*Resultado da análise comparativa entre previsão real x sugerida*

Referência	Produto	Quantidade Total Anual	Previsão Real Utilizada	Sugerido Plugin
1	Café Melitta Trad 500Gr	59.38	MMS	MMS
2	Café Pilão Trad 500Gr	61.94	MMS	MMS
3	Óleo De Soja Vitaliv Pet 900MI	146.04	MMS	Projeção

4	Bombom Nestle C/11 Variedad 251Gr	73.83	MMS	MME
5	Cafe Caboclo Trad 500Gr	59.96	MMS	MME
6	Oleo De Soja Soya Pet 900MI	126.86	MMS	MME
7	Bombom Lacta Favoritos 250.6Gr	41.64	MMS	MMP
8	Acucar Ref.Alto Alegre 5Kg	22.59	MMS	MME
9	Leite Cond Marajoara Tp 395Gr	103.5	MMS	Projeção
10	Cafe Melitta Extra Forte 500Gr	27.03	MMS	MMS
11	Feijao Caldao Preto Tipo 1 1Kg	48.36	MMS	MME
12	Acucar Ref.Da Barra 5Kg	20.01	MMS	Projeção
13	Oleo De Soja Cocamar 900MI	66.44	MMS	MMS
14	Leite Cond Piracanjuba Tp 395Gr	71.50	MMS	MMS
15	Acucar Ext.Fino Docesucar 5Kg	20.55	MMS	MME
16	Oleo De Soja Vila Velha 900MI	54.22	MMS	Projeção
17	Acucar Ref.Da Barra 1Kg	85.74	MMS	MMP
18	Cafe Pilao Extra Forte 500Gr	23.11	MMS	Projeção
19	Massa Todeschini Sem.Spaghett 500Gr	113.67	MMS	MMS

Fonte: Do autor

A Tabela 14 mostra o detalhamento estatístico feito por quatro métodos diferentes: Média Móvel Simples, Média Móvel Ponderada, Suavização Exponencial e Projeção de Tendências. Nela, é possível observar como o *plugin* avaliou automaticamente os métodos aplicados e identificou alternativas mais assertivas para cada produto. Por exemplo, para o produto Óleo De Soja Vitaliv Pet 900MI, o *plugin* indicou que o método de projeção seria mais preciso, ajustando a previsão e evitando a ruptura de estoque. Por outro lado, para outros itens como o Café Melitta Tradicional 500g, o *plugin* confirmou que o método inicial era adequado, validando as previsões realizadas.

**Tabela 13**

*Detalhamento estatístico com quatro métodos diferentes*

Referência	MMS	MMP	MME	Projeção	Sugerido
1	59.82	53.08	57.93	55.57	MMS
2	67.05	55.28	56.21	54.76	MMS

3	152.63	153.73	158.56	159.69	Projeção
4	67.49	68.71	78.83	66.07	MME
5	59.89	64.13	65.47	60.71	MME
6	126.69	122.79	132.97	121.84	MME
7	38.77	43.78	41.33	38.03	MMP
8	22.40	22.72	25.30	21.53	MME
9	98.5	92.64	105.12	112.01	Projeção
10	29.66	26.39	23.65	26.60	MMS
11	48.03	46.54	53.86	53.05	MME
12	18.39	20.82	21.69	22.54	Projeção
13	66.28	61.23	60.91	60.55	MMS
14	72.48	68.92	61.62	71.07	MMS
15	18.8	21.15	22.1	19.24	MME
16	52.6	47.97	49.97	58.24	Projeção
17	91.3	91.69	73.65	89.42	MMP
18	21.26	21.26	23.37	25.72	Projeção
19	121.17	111.96	102.41	112.09	MMS

Fonte: Do autor

A capacidade do *plugin* de integrar diferentes métodos de previsão e comparar os resultados de forma automatizada representa um diferencial significativo, que contribui para decisões mais assertivas no gerenciamento de estoques, conforme discutido por Henriques et al. (2024).

A integração de diferentes métodos de previsão e a flexibilidade do sistema em aceitar ajustes de parâmetros permitem que o *plugin* se adapte a diferentes produtos e contextos de demanda. A interface amigável e a automatização dos cálculos garantem que os gestores possam comparar métodos de forma prática, facilitando o uso da ferramenta no dia a dia da gestão de estoque. Como apontado por Runge et al. (2023), sistemas automatizados de previsão de demanda, como o desenvolvido neste estudo, podem reduzir significativamente o desperdício e melhorar a eficiência logística em ambientes complexos, como o varejo.

#### 4.2 APLICABILIDADE DO ESTUDO

Esta pesquisa traz implicações significativas para a melhoria dos sistemas de previsão de demanda e gestão de estoques em supermercados. A aplicação de modelos preditivos avançados,

como os desenvolvidos neste estudo, aborda desafios essenciais na manutenção de níveis ótimos de estoque, redução de desperdícios e aprimoramento da eficiência operacional.

Em nível local, a implementação desses modelos ajudará os supermercados a gerenciar melhor seus estoques, garantindo a disponibilidade de produtos e minimizando faltas ou excessos. Isso beneficia diretamente os consumidores, melhorando a experiência de compra e assegurando que produtos essenciais estejam sempre disponíveis. Além disso, ao reduzir o desperdício, os supermercados podem se alinhar com objetivos de sustentabilidade ambiental, contribuindo para os esforços locais de redução de resíduos e consumo responsável.

Em nível regional e nacional, esta pesquisa oferece um modelo replicável para outros varejistas, com potencial para influenciar práticas de gestão de estoques em todo o setor. Ao otimizar a gestão de estoques, os supermercados podem reduzir custos associados ao excesso de mercadorias, melhorar a lucratividade e apoiar o crescimento econômico no setor varejista. Essas melhorias também estão em conformidade com os objetivos nacionais para produção e consumo sustentáveis, como previsto nos Objetivos de Desenvolvimento Sustentável (ODS 12) da ONU.

As oportunidades de internacionalização também são evidentes, já que os modelos preditivos desenvolvidos podem ser adaptados e aplicados em supermercados ao redor do mundo, especialmente em regiões que enfrentam desafios semelhantes na gestão de estoques. Ao demonstrar a eficácia desses modelos em diversos contextos, a pesquisa tem o potencial de influenciar práticas globais na cadeia de suprimentos, oferecendo uma solução que promove tanto a sustentabilidade econômica quanto a ambiental.

As contribuições desta pesquisa vão além do setor varejista, pois também fornecem dados sobre a integração de tecnologias de IA, como o GPT-4, em modelos de previsão, fomentando a inovação em soluções de negócios impulsionadas por tecnologia.

## 5 CONSIDERAÇÕES FINAIS OU CONCLUSÕES

Este estudo teve como objetivo principal investigar a eficácia de diferentes métodos de previsão de demanda aplicados com inteligência artificial na gestão de estoques em supermercados. Os resultados obtidos indicam que a utilização de técnicas de previsão de demanda fornece dados estatísticos aos gestores, os quais podem, a partir dessas informações, implementar ações que resultem em ganhos significativos em termos de eficiência operacional, redução do desperdício de produtos e aumento da disponibilidade de mercadorias. Com isso, verificou-se uma importante contribuição para o equilíbrio entre oferta e demanda, permitindo que as empresas possam alinhar suas práticas com objetivos estratégicos de gestão de estoques de forma mais precisa. Além disso, a introdução de novas tecnologias, como a inteligência artificial, foi uma conquista relevante, demonstrando que a inovação tecnológica pode ter um impacto positivo no setor varejista ao proporcionar soluções mais adequadas para os desafios enfrentados por essas empresas.

A natureza inovadora deste estudo está, sobretudo, na integração de técnicas preditivas modernas com métodos tradicionais de previsão de demanda, oferecendo uma abordagem inédita que ainda não havia sido suficientemente explorada no contexto de gestão de estoques de supermercados. A combinação entre inteligência artificial e esses métodos permitiu a criação de um modelo preditivo flexível e aplicável a diferentes realidades empresariais, ampliando seu potencial de utilização não apenas no setor varejista, mas em outras indústrias que demandam a otimização de seus processos logísticos.

Espera-se que a pesquisa tenha um impacto econômico significativo no futuro, uma vez que a aplicação do modelo preditivo poderá reduzir os custos operacionais ao minimizar os excessos de estoque e aumentar a precisão na aquisição de produtos. Além do aspecto econômico, o estudo também gerou impactos sociais ao garantir que os consumidores tivessem maior disponibilidade de produtos essenciais, resultando em uma experiência de compra aprimorada.

Culturalmente, a pesquisa incentiva práticas empresariais mais sustentáveis, alinhando-se aos Objetivos de Desenvolvimento Sustentável da ONU, particularmente no que se refere ao consumo e produção responsáveis, reforçando a importância de uma gestão mais eficiente e consciente dos recursos.

Embora a pesquisa tenha alcançado resultados expressivos, vale destacar que a implementação dos modelos preditivos em diferentes realidades pode demandar ajustes específicos, especialmente em setores que possuem dinâmicas de demanda altamente voláteis. A flexibilidade

dos métodos desenvolvidos permite adaptações, mas esses ajustes deverão ser cuidadosamente analisados para maximizar os resultados em diferentes cenários.

Para estudos futuros, sugere-se a ampliação do uso deste modelo preditivo em outros segmentos do varejo, como o setor farmacêutico ou de vestuário, que apresentam padrões de demanda diferenciados. Ademais, pesquisas que associem essas previsões de demanda com a automação de processos de reabastecimento podem fornecer novos dados sobre a maximização da eficiência operacional. Outra possibilidade seria a liberação externa das APIs do *plugin*, permitindo a integração de softwares de terceiros, o que viabilizaria o uso das previsões por sistemas externos, aumentando a flexibilidade e o alcance das soluções propostas. Por fim, a aplicação dessa abordagem em mercados internacionais seria uma oportunidade interessante para avaliar a flexibilidade e a adaptação do modelo em diferentes contextos culturais e econômicos, promovendo assim a internacionalização das práticas de gestão de estoques.

## REFERÊNCIAS

- Abeyssekara, T. K., & Rupasinghe, S. (2019). Analysis of Influential Factors for Inventory Forecasting Systems. *2019 IEEE 5th International Conference for Convergence in Technology (I2CT)*, 1–4. <https://doi.org/10.1109/I2CT45611.2019.9033725>
- Abolghasemi, M., Ganbold, O., & Rotaru, K. (2024). *Humans vs large language models: Judgmental forecasting in an era of advanced AI*. <https://doi.org/10.48550/arXiv.2312.06941>
- Aragao, A., Santos, D., & Monteiro, L. (2016, outubro 3). APLICAÇÃO DA CURVA ABC EM UMA EMPRESA DO SETOR ATACADISTA NO ESTADO DE SERGIPE. *XXXVI ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO*.
- Assumpção, G., & Rosa, V. (2022). *APLICAÇÃO DE MÉTODO QUANTITATIVO DE PREVISÃO DE DEMANDA EM UMA DOCERIA*.
- Bala, P., & Xavier, M. (2013). CLASSIFICATION BASED FORECASTING FOR IMPROVED INVENTORY MANAGEMENT. *International Journal of Strategic Management*, 13(1), 115–122. <https://doi.org/10.18374/IJSM-13-1.13>
- Ballou, R. H. (2007). *Gerenciamento da cadeia de suprimentos/logística empresarial* (D. W. N. Aiysinha Jacques Affonso, Org.; 5º ed). Bookman.
- Bandeira, A. M., Nogueira, J., Vale, J., Tavares, M. C., & Azevedo, G. (2023). Accounting for change: the importance of information technology in the accountants academic qualification. *2023 18th Iberian Conference on Information Systems and Technologies (CISTI)*, 1–7. <https://doi.org/10.23919/CISTI58278.2023.10211754>
- Bansal, R., Gaur, N., & Singh, S. N. (2016). Outlier Detection: Applications and techniques in Data Mining. *2016 6th International Conference - Cloud System and Big Data Engineering (Confluence)*, 373–377. <https://doi.org/10.1109/CONFLUENCE.2016.7508146>
- Brown, T. B., Mann, B., Ryder, N., Subbiah, M., Kaplan, J., Dhariwal, P., Neelakantan, A., Shyam, P., Sastry, G., Askell, A., Agarwal, S., Herbert-Voss, A., Krueger, G., Henighan, T., Child, R., Ramesh, A., Ziegler, D. M., Wu, J., Winter, C., ... Amodi, D. (2020). *Language Models are Few-Shot Learners*.
- Brueggen, A., Grabner, I., & Sedatole, K. L. (2014). The Folly of Forecasting: The Effects of Sales Forecast Accuracy and Bias on Inventory and Production Decisions under Aggregated and Disaggregated Forecasting Regimes. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.2482321>
- Campos Borges, T., Campos, M. S., & Campos Borges, E. (2010). Implantação de um sistema para o controle de estoques em uma gráfica/editora de uma universidade. *Revista Eletrônica Produção & Engenharia*, 236–247. <http://www.repositorio.ufop.br/jspui/handle/123456789/8811>
- CAPES. (2020a). *Ata 198ª Reunião Ordinária*. <https://www.gov.br/capes/pt-br/centrais-de-conteudo/documentos/conselho-tecnico-cientifico-da-educacao-superior/atas-ctc-es/ata-198.pdf>
- CAPES. (2020b). *Tabela de Áreas do Conhecimento*. [https://www.gov.br/capes/pt-br/centrais-de-conteudo/TabelaAreasConhecimento\\_072012\\_atualizada\\_2017\\_v2.pdf](https://www.gov.br/capes/pt-br/centrais-de-conteudo/TabelaAreasConhecimento_072012_atualizada_2017_v2.pdf)
- Costantino, F., Di Gravio, G., Shaban, A., & Tronci, M. (2014). Replenishment policy based on information sharing to mitigate the severity of supply chain disruption. *International*

- Journal of Logistics Systems and Management*, 18(1), 3–23.  
<https://doi.org/10.1504/IJLSM.2014.062119>
- Cruz, T., Pakes, P. R., Silva, B. B., & Rocha, T. S. da. (2022). Análise da adoção de práticas da gestão da qualidade total em uma central de atendimento ao cliente do setor varejista. *Revista de Gestão e Secretariado*, 13(3), 610–624.  
<https://doi.org/10.7769/gesec.v13i3.1346>
- Dinh, H. (2020). *The Revolution Warehouse Inventory Management in Finland by Using Artificial Intelligence (Case: Warehouse of Company X)*.
- Elías, A., Jiménez, R., & Shang, H. L. (2022). On projection methods for functional time series forecasting. *Journal of Multivariate Analysis*, 189, 104890.  
<https://doi.org/10.1016/j.jmva.2021.104890>
- Emmett, S. (2005). *Excellence in Warehouse Management How to Minimise Costs and Maximise Value*.
- Farzana, S., & Prakash. (2020). Machine Learning in Demand Forecasting - A Review. *Second International Conference on IoT, Social, Mobile, Analytics & Cloud in Computational Vision & Bio-Engineering (ISMAC-CVB 2020)*, 26–34.  
<https://doi.org/10.2139/ssrn.3733548>
- Fetrina, E., Utami, M., & Permatasari, A. (2018). Forecasting System of Office Supplies Demand Using Simple Moving Average and Simple Exponential Smoothing (Case Study: Regional Office of The Ministry of Religious Affairs of Jakarta). *Atlantis Press*, 149, 156–159.
- Gil, A. (2017). *Como Elaborar Projetos de Pesquisa* (6<sup>o</sup> ed). Atlas Ltda.
- Gil, A. C. (2002). *Como Elaborar Projetos de Pesquisa* (4<sup>o</sup> ed). Atlas Ltda.
- Gomes, C., Guimarães, A., & Lopes, K. (2018, outubro 16). ANÁLISE E APLICAÇÃO DO MÉTODO QUANTITATIVO DE PREVISÃO DE DEMANDA COM MÉDIAS MÓVEIS: ESTUDO DE CASO EM UMA INDÚSTRIA DE FIOS E CABOS ELÉTRICOS. XXXVIII ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO.
- Gonen, H., Iyer, S., Blevins, T., Smith, N. A., & Zettlemoyer, L. (2022). *Demystifying Prompts in Language Models via Perplexity Estimation*.
- González Perea, R., Camacho Poyato, E., Montesinos, P., & Rodríguez Díaz, J. A. (2019). Optimisation of water demand forecasting by artificial intelligence with short data sets. *Biosystems Engineering*, 177, 59–66.  
<https://doi.org/10.1016/j.biosystemseng.2018.03.011>
- Gruver, N., Finzi, M., Qiu, S., & Wilson, A. G. (2023). *Large Language Models Are Zero-Shot Time Series Forecasters*.
- Henriques, H., & Nobre Pereira, L. (2024). Hotel demand forecasting models and methods using artificial intelligence: A systematic literature review. *Tourism & Management Studies*, 20(3), 39–51. <https://doi.org/10.18089/tms.20240304>
- Hiren R. Kavathiya, & Dr. G. C. Bhimani. (2019). A DETAIL INVESTIGATION ON THE MEDICAL DATABASES BY IMPLEMENTING VARIOUS METHODS. *PARIPEX INDIAN JOURNAL OF RESEARCH*, 8(12).
- Hoffmann, J., Borgeaud, S., Mensch, A., Buchatskaya, E., Cai, T., Rutherford, E., Casas, D. de Las, Hendricks, L. A., Welbl, J., Clark, A., Hennigan, T., Noland, E., Millican, K., Driessche, G. van den, Damoc, B., Guy, A., Osindero, S., Simonyan, K., Elsen, E., ... Sifre, L. (2022). *Training Compute-Optimal Large Language Models*.

- Hohemberger, R., Góes Bilar, J., Schwanke, C., & Coutinho, R. X. (2021). O ensino de Paleontologia: interpretações de uma abordagem contextualizada à realidade local. *Revista de Ensino de Ciências e Matemática*, 12(1), 1–23. <https://doi.org/10.26843/rencima.v12n1a19>
- Huafei, C. (2011). Research on uncertainty demand inventory control in supply chain. *MSIE 2011*, 874–878. <https://doi.org/10.1109/MSIE.2011.5707547>
- Ivanyuk, V., Shuvalov, K., Akhobadze, G., Malekova, V., Mikhailov, A., & Levchenko, K. (2023). Development of Modern Forecasting Models. *2023 16th International Conference Management of large-scale system development (MLSD)*, 1–4. <https://doi.org/10.1109/MLSD58227.2023.10303848>
- Jagerman, R., Zhuang, H., Qin, Z., Wang, X., & Bendersky, M. (2023). *Query Expansion by Prompting Large Language Models*.
- Jin, M., Wang, S., Ma, L., Chu, Z., Zhang, J. Y., Shi, X., Chen, P.-Y., Liang, Y., Li, Y.-F., Pan, S., & Wen, Q. (2023). *Time-LLM: Time Series Forecasting by Reprogramming Large Language Models*.
- Krajewski, L., Malhotra, M., & Ritzman, L. (2007). *Operations Management: Process and Supply Chains* (1<sup>o</sup> ed). Eleventh Edition.
- Kumar, K., & Aouam, T. (2019). Extending the strategic safety stock placement model to consider tactical production smoothing. *European Journal of Operational Research*, 279(2), 429–448. <https://doi.org/10.1016/j.ejor.2019.06.009>
- Lima, M. T., & Bezerra Barbosa, B. (2021). *Análise de Custo-Volume-Lucro para Multiprodutos como Ferramenta Gerencial: um Estudo de Caso em um Microempreendimento do Setor Varejista de Brinquedos*.
- Lin, B., Schwarzbach, H., & Lin, C.-M. (2019). How does inventory management affect analyst forecast accuracy. *Pressacademia*, 8(1), 17–27. <https://doi.org/10.17261/Pressacademia.2019.1012>
- Magalhães, M. de A., Assis, A. C., Souza, R. P. de, Roberto, J. C. A., Cavalcante, Z. P., & Magalhães, S. S. de A. (2022). A relevância da gestão de estoque nas empresas. *Revista Científica Multidisciplinar Núcleo do Conhecimento*, 8, 169–178. <https://doi.org/10.32749/nucleodoconhecimento.com.br/contabilidade/relevancia-da-gestao>
- Makridakis, S., Petropoulos, F., & Kang, Y. (2023). Large Language Models: Their Success and Impact. *Forecasting*, 5(3), 536–549. <https://doi.org/10.3390/forecast5030030>
- Masoud, S. A., & Mason, S. J. (2016). A bi-criteria hybrid metaheuristic for analysing an integrated automotive supply chain. *Journal of the Operational Research Society*, 67(3), 516–526. <https://doi.org/10.1057/jors.2015.75>
- Mediavilla, M. A., Dietrich, F., & Palm, D. (2022). Review and analysis of artificial intelligence methods for demand forecasting in supply chain management. *Procedia CIRP*, 107, 1126–1131. <https://doi.org/10.1016/j.procir.2022.05.119>
- Melo, D., & Alcântara, R. (2011). A gestão da demanda em cadeias de suprimentos. *Gestão de Produção*, 18, 809–824.
- Mitiuye, E., Silva, Miriam., & Pereira, Mirela. (2008). CURVA ABC: PRINCÍPIOS E APLICABILIDADE EMPRESARIAL. *REVISTA CIENTÍFICA ELETRÔNICA DE CIÊNCIAS CONTÁBEIS*.
- Muller, M. (2003). *ESSENTIALS OF INVENTORY MANAGEMENT* (Vol. 1). American Management Association.

- Muttaqin, W. M. I., Ramdhan, W., & Kifti, W. M. (2022). Sistem Peramalan Permintaan Darah dengan Metode Simple Moving Average. *Edumatic: Jurnal Pendidikan Informatika*, 6(2), 242–251. <https://doi.org/10.29408/edumatic.v6i2.6326>
- Nikulchenko, A. A. (2018). Forecasting of customer demand for seasonal goods using retail curve vector. *Bulletin of National Technical University “KhPI”. Series: System Analysis, Control and Information Technologies*, 0(21), 23–27. <https://doi.org/10.20998/2079-0023.2018.21.05>
- Noronha, M., Martins, J., Lietti, T., & Silva, R. (2022). A Agilidade Organizacional e a Difusão de Inovação Tecnológica das Empresas Cleantech. *Revista Inteligência Competitiva*, 12(1), e0412. <https://doi.org/10.24883/iberoamericanic.v12i.2022.e0412>
- Okamura, K. (2019). Interdisciplinarity revisited: evidence for research impact and dynamism. *Palgrave Communications*, 5(1), 141. <https://doi.org/10.1057/s41599-019-0352-4>
- Palomino, R., Silveira, R., Oliveira, R., Moura, T., & Santana, L. (2018). *APLICAÇÃO DA CURVA ABC NA GESTÃO DE ESTOQUE DE UMA MICRO EMPRESA DE ARACAJU-SE.*
- Pâmela, J., & Sachet, N. (2022). *GESTÃO DE ESTOQUE E PREVISÃO DE DEMANDA EM UM RESTAURANTE NA REGIÃO CENTRAL DO RIO GRANDE DO SUL.*
- Pereira, B. M., Chaves, G., Bellumat, M. S., & Vieira Barboza, M. ([s.d.]). *GESTÃO DA DEMANDA: UM ESTUDO DE CASO EM UMA EMPRESA DE PEQUENO PORTE DE JAGUARÉ.*
- Provin, D. T., & Sellitto, M. A. (2011). POLÍTICA DE COMPRA E REPOSIÇÃO DE ESTOQUES EM UMA EMPRESA DE PEQUENO PORTE DO RAMO ATACADISTA DE MATERIAIS PARA CONSTRUÇÃO CIVIL. *Revista Gestão Industrial*, 7(2), 187–200. <https://doi.org/10.3895/s1808-04482011000200010>
- Raento, P. (2020). Interdisciplinarity. Em *International Encyclopedia of Human Geography* (p. 357–363). Elsevier. <https://doi.org/10.1016/B978-0-08-102295-5.10659-6>
- Ramos, W. M., Carminatti, B., & Bedin, E. (2021). *A metodologia Dicumba e a abordagem CTS: a busca pela alfabetização científica no ensino médio The Dicumba methodology and the CTS approach: the search for scientific literacy in high school.* 33(1), 159–171. [www.revistas.unc.edu.ar/index.php/revistaEF](http://www.revistas.unc.edu.ar/index.php/revistaEF)
- Rogulin, R. S. (2023). FORECASTING AND FORECASTING DEMAND: THE CASE OF ARTIFICIAL INTELLIGENCE IN SUPPLY CHAIN MANAGEMENT. *Region:systems,economy,management*, 60(1), 172–180. <https://doi.org/10.22394/1997-4469-2023-60-1-172-180>
- Runge, J., & Saloux, E. (2023). A comparison of prediction and forecasting artificial intelligence models to estimate the future energy demand in a district heating system. *Energy*, 269, 126661. <https://doi.org/10.1016/j.energy.2023.126661>
- Saleheen, F. (2014). Demand and Supply Planning in Retail Operations. *International Journal of Business and Economics Research*, 3(6), 51. <https://doi.org/10.11648/j.ijber.s.2014030601.18>
- Sanchez-Rodrigues, V., Potter, A., & Naim, M. M. (2010). Evaluating the causes of uncertainty in logistics operations. *International Journal of Logistics Management*, 21(1), 45–64. <https://doi.org/10.1108/09574091011042179>
- Santos, B., & Lubiana, C. (2017). *O USO DA CURVA ABC PARA A TOMADA DE DECISÃO NA COMPOSIÇÃO DE ESTOQUE THE USE OF THE ABC CURVE FOR THE DECISION MAKING IN THE STOCK COMPOSITION THE.*

- Santos, W., Alves, G., Santos, W., & Fernandes, L. (2017). *APLICAÇÃO DA CURVA ABC EM UMA EMPRESA DE ARTIGOS ESPORTIVOS DE ITABAIANA-SE: UM ESTUDO DE CASO*. *APPLICATION OF THE ABC CURVE IN A COMPANY OF ITABAIANA-SE SPORTS ARTICLES: A CASE STUDY*. [www.simprod.ufs.br](http://www.simprod.ufs.br)
- Sillanpää, V., & Liesiö, J. (2018). Forecasting replenishment orders in retail: value of modelling low and intermittent consumer demand with distributions. *International Journal of Production Research*, 56(12), 4168–4185. <https://doi.org/10.1080/00207543.2018.1431413>
- Silva, I., Medeiro, Y., Rodrigues, L., & Souza, J. (2021). Aplicação de Novas Tecnologias na Gestão do Estoque. *Revista Multidisciplinar e de Psicologia*, 15(55). <https://doi.org/10.14295/online.v15i55.3031>
- Singha, D., & Panse, C. (2022). Application of different Machine Learning models for Supply Chain Demand Forecasting: Comparative Analysis. In *2022 2nd International Conference on Innovative Practices in Technology and Management (ICIPTM)*, 312–318. <https://doi.org/10.1109/ICIPTM54933.2022.9753864>
- Singhal, K., Azizi, S., Tu, T., Mahdavi, S. S., Wei, J., Chung, H. W., Scales, N., Tanwani, A., Cole-Lewis, H., Pfohl, S., Payne, P., Seneviratne, M., Gamble, P., Kelly, C., Babiker, A., Schärli, N., Chowdhery, A., Mansfield, P., Demner-Fushman, D., ... Natarajan, V. (2023). Large language models encode clinical knowledge. *Nature*, 620(7972), 172–180. <https://doi.org/10.1038/s41586-023-06291-2>
- Slack, N., Chambers, S., & Johnston, R. (2002). *Administração da produção* (2º ed). Atlas S.A.
- Sloane, J. D. (2021). Primary Literature in Undergraduate Science Courses: What are the Outcomes? *Journal of College Science Teaching*, 50(3), 51–60. <https://doi.org/10.1080/0047231X.2021.12290508>
- Stevenson, W. J. (2017). *Operations Management* (13º ed). Rochester Institute of Technology.
- Thomas, P., Spielman, S., Craswell, N., & Mitra, B. (2023). *Large language models can accurately predict searcher preferences*.
- Tosin, O., & Köprülü, F. (2022). CONTENT ANALYSIS OF THE ARTICLES PUBLISHED IN EDUCATIONAL TECHNOLOGY. *Near East University Online Journal of Education*, 5(1), 26–35. <https://doi.org/10.32955/neuje.v5i1.475>
- Trento, F., Neto, P., Lago, S., & Meneghatti, M. (2022). Logística Reversa De Vidros: Perspectivas Na Visão Dos Gestores De Compras Do Setor Varejista e de Conveniências. *Retail Management Review*, 2(1), e10. <https://doi.org/10.53946/rmr.v2i1.10>
- Tubino, D. (2007). *Planejamento e Controle da Produção: teoria e prática*. (1º ed, Vol. 2). Atlas S.A.
- UNIPLAC. (2021). *Aprovado o primeiro mestrado associado em sistemas produtivos de Santa Catarina*. [https://www.uniplaclages.edu.br/noticias\\_visualiza/5751-aprovado-o-primeiro-mestrado-associado-em-sistemas-produtivos-de-santa-catarina#:~:text=O Programa Interinstitucional Associado em Sistemas Produtivos -,de 14 a 18 de setembro de 2020.](https://www.uniplaclages.edu.br/noticias_visualiza/5751-aprovado-o-primeiro-mestrado-associado-em-sistemas-produtivos-de-santa-catarina#:~:text=O Programa Interinstitucional Associado em Sistemas Produtivos -,de 14 a 18 de setembro de 2020.)
- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, L., & Polosukhin, I. (2017). *Attention Is All You Need*.
- Vaz, A., Tedjamulja, A., Mallak, S., & Rajagopal, P. (2020). Modelling and Simulation of Inventory Replenishment Policies and Comparison of Target Days Vs Actual Days of Inventory Held. Em *Int. J Sup. Chain. Mgt* (Vol. 9, Número 2). <http://excelingtech.co.uk/>

- Wei, J., Wang, X., Schuurmans, D., Bosma, M., Ichter, B., Xia, F., Chi, E., Le, Q., & Zhou, D. (2022). *Chain-of-Thought Prompting Elicits Reasoning in Large Language Models*.
- Wijaya, R. A., Rr. Erlina, & Mardiana, N. (2023). Comparison of Moving Average and Exponential Smoothing Methods in Sales Forecasting of Banana Chips Products in Pd. Dwi Putra Tulang Bawang Barat. *Journal of Finance and Business Digital*, 2(2), 193–208. <https://doi.org/10.55927/jfbd.v2i2.4913>
- Xi, J., & Sha, P. B. (2014). Research on Optimization of Inventory Management Based on Demand Forecasting. *Applied Mechanics and Materials*, 687–691, 4828–4831. <https://doi.org/10.4028/www.scientific.net/AMM.687-691.4828>
- Yawen Shao, Quan J. Wang, Andrew Schepen, Dongryeol Ryu, & Florian Pappenberger. (2022). Improved Trend-Aware Postprocessing of GCM Seasonal Precipitation Forecasts. *Journal of Hydrometeorology*, 23(1), 25–37. <https://doi.org/10.1175/JHM-D-21-0099.1>
- Zhang, X. (2017). *The Influence and Application of Plug-in Technology on Computer Software*. <https://doi.org/10.2991/emcm-16.2017.223>
- Zhao, W. X., Zhou, K., Li, J., Tang, T., Wang, X., Hou, Y., Min, Y., Zhang, B., Zhang, J., Dong, Z., Du, Y., Yang, C., Chen, Y., Chen, Z., Jiang, J., Ren, R., Li, Y., Tang, X., Liu, Z., ... Wen, J.-R. (2023). *A Survey of Large Language Models*.
- Zhu, X., Xiang, X., & Chen, D. (2015). Improved Inventory Management for Retail Stores based on Intelligent Demand Forecasts. *International Journal of Hybrid Information Technology*, 8(8), 233–244. <https://doi.org/10.14257/ijhit.2015.8.8.24>