



UNIVERSIDADE FEDERAL DO CEARÁ
FACULDADE DE ECONOMIA, ADMINISTRAÇÃO, ATUÁRIA E
CONTABILIDADE
PROGRAMA DE PÓS-GRADUAÇÃO EM ADMINISTRAÇÃO E
CONTROLADORIA

ABDIAS KELLY DE PAIVA NETO

PROPOSTA E IMPLANTAÇÃO DE UMA SOLUÇÃO DE PREVISÃO DE
DEMANDA EM UMA INDÚSTRIA DE IMPLEMENTOS AGRÍCOLAS

FORTALEZA

2025

ABDIAS KELLY DE PAIVA NETO

**PROPOSTA E IMPLANTAÇÃO DE UMA SOLUÇÃO DE PREVISÃO DE
DEMANDA EM UMA INDÚSTRIA DE IMPLEMENTOS AGRÍCOLAS**

Dissertação apresentada à Coordenação do Programa de Pós-Graduação em Administração e Controladoria da Universidade Federal do Ceará, como parte dos requisitos para obtenção do título de Mestre em Administração e Controladoria. Área de Concentração: Gestão organizacional.

Orientador: Prof. Dr. Érico Veras Marques

FORTALEZA

2025

ABDIAS KELLY DE PAIVA NETO

**PROPOSTA E IMPLANTAÇÃO DE UMA SOLUÇÃO DE PREVISÃO DE
DEMANDA EM UMA INDÚSTRIA DE IMPLEMENTOS AGRÍCOLAS**

Dissertação submetida à Coordenação do Curso de Pós-Graduação em Administração e Controladoria, da Universidade Federal do Ceará, como requisito para a obtenção do grau de Mestre em Administração e Controladoria.

Aprovado em 29/10/2025

BANCA EXAMINADORA

Prof. Dr. Érico Veras Marques (Universidade Federal do Ceará)

Orientador

Prof. Dr. Jocildo Figueiredo Correia Neto (Universidade Federal do Ceará)

Membro

Prof. Dr. Josimar Souza Costa (Universidade de Fortaleza)

Membro

FORTALEZA

2025

AGRADECIMENTOS

Aos meus pais, Ana Lúcia e Kellter, por todo amor e apoio ao longo da minha vida, por colocarem minha educação acima de qualquer outra coisa e por me ensinarem o valor do estudo, do trabalho e do amor.

À minha esposa, Bruna, por ter sido meu alicerce durante todo esse processo, acreditando em mim quando eu mesmo duvidava.

À minha filha, Isis, por cada sorriso que me deu força nos momentos difíceis.

Ao meu irmão, Yan, por estar comigo sempre.

Ao Dr. Carlos Prado e ao Olindo Chaves, por apostarem tanto em mim, financiando essa pesquisa e abrindo as portas da sua empresa para mim, sempre permitindo que eu implante minhas ideias, contribuindo para o meu crescimento pessoal e profissional. Agradecimento especial também à Sônia Felix, por todo carinho e ensinamento.

Ao meu orientador, Prof. Érico Veras Marques, por todo ensinamento e apoio fundamental para a realização desse trabalho. A todos os professores do PPAC Profissional, especialmente à Professora Alessandra Vasconcelos e ao Professor Augusto Cabral, pelos ensinamentos e inspiração.

A todos os amigos que carrego para a vida: Yuri, Victor, Hideki, Severiano, Thiago, Ádso e Allana, por sempre me mostrarem que nunca estarei sozinho. Aos colegas que fiz no mestrado, por tudo que aprendi e por tudo que passamos juntos.

“Milagres acontecem quando a gente vai à luta.”

Sérgio Vaz.

RESUMO

Este trabalho teve como objetivo propor e validar uma solução de previsão de demanda para uma indústria de implementos agrícolas. Desenvolveu-se um processo modelo de previsão de demanda baseado nas especificidades da empresa-alvo do estudo. Além do processo, foi desenvolvida uma solução desenvolvida em *Python*, com interface interativa em *Streamlit*, integrando modelos de previsão quantitativa e qualitativa. Os modelos foram avaliados com base nas métricas MAE e WAPE, e os resultados foram discutidos junto à equipe gestora. As previsões foram realizadas para os meses de agosto, setembro e outubro de 2025. No âmbito deste trabalho, foi possível comparar os erros de previsão de dois dos três meses previstos, uma vez que os resultados reais de outubro ainda não estavam disponíveis. Para agosto e setembro, o WAPE médio geral foi de 6,69% e o MAE de 16 unidades. Observou-se que a aplicação prática da solução gerou impactos positivos nos processos de compras, planejamento de produção e definição de metas comerciais, promovendo maior integração entre os setores e reduzindo a subjetividade das decisões. O estudo evidenciou, ainda, a aplicabilidade de uma abordagem híbrida que combina métodos quantitativos e julgamento de especialistas, demonstrando seu potencial de replicação em outras empresas do setor.

Palavras-chave: previsão de demanda; métodos híbridos; indústria de implementos agrícolas; planejamento da produção; integração organizacional.

ABSTRACT

This study aimed to propose and validate a demand forecasting solution for an agricultural implements industry. A model-based forecasting process was developed according to the specific characteristics of the company under study. In addition to the process, a computational solution was implemented in the Python programming language, featuring an interactive interface in Streamlit and integrating both quantitative and qualitative forecasting models. The models were evaluated using the MAE and WAPE metrics, and the results were discussed with the management team. Forecasts were generated for the months of August, September, and October 2025. Within the scope of this research, it was possible to compare the forecasting errors of two out of the three forecasted months, as the actual results for October were not yet available. For August and September, the average overall WAPE was 6.69%, and the MAE was 16 units. The practical application of the solution produced positive impacts on purchasing processes, production planning, and the definition of sales targets, promoting greater integration among departments and reducing subjectivity in decision-making. The study also demonstrated the applicability of a hybrid approach that combines quantitative methods and expert judgment, showing its potential for replication in other companies within the sector.

Keywords: demand forecasting; hybrid methods; agricultural machinery industry; production planning; organizational integration.

LISTA DE QUADROS

Quadro 1 - Estudos empíricos anteriores.	30
Quadro 2 - Resumo das etapas do processo e seus resultados.	37
Quadro 3 - Lista de variáveis.....	42
Quadro 4 – Dicionário de dados: variáveis utilizadas, fontes, unidades de medida e tipo	44
Quadro 5 – Modelo quantitativo utilizado	55
Quadro 6 – Ajustes da previsão na região Centro-Oeste	57
Quadro 7 – Ajustes da previsão na região Sudeste.....	57
Quadro 8 – Ajustes da previsão na região Nordeste.....	58

LISTA DE FIGURAS

Figura 1 - Processo de previsão de demanda	24
Figura 2 - Processo de previsão de demanda com a incorporação de julgamentos.....	29
Figura 3 - Processo-modelo proposto.	34
Figura 4 - Framework da solução de previsão de demanda	38
Figura 5 - Página inicial da solução.....	59
Figura 6 - Parâmetros de configuração	60
Figura 7 - Resultados	61
Figura 8 - Gráfico de série histórica	61

LISTA DE TABELAS

Tabela 1 - Participação de cada região no total de vendas.....	48
Tabela 2 - MAE e WAPE para a família de carretas.	53
Tabela 3 - MAE e WAPE para a linha de tanques.....	54
Tabela 4 - Resultado da previsão quantitativa.....	56
Tabela 5 - Previsão final.....	58
Tabela 6 - Previsto vs. Realizado	62

LISTA DE GRÁFICOS

Gráfico 1 - Vendas por região	47
Gráfico 2 - Total Previsto vs. Realizado em agosto	64
Gráfico 3 - Total Previsto vs. Realizado em setembro	65
Gráfico 4 - Comparação do WAPE	66

LISTA DE SIGLAS E ABREVIACÕES

CAPES	Coordenação de Aperfeiçoamento de Pessoal de Nível Superior
CEPEA	Centro de Estudos Avançados em Economia Aplicada
CO	Região Centro-Oeste
GRU	<i>Gated Recurrent Unit</i> (Unidade Recorrente com Portões)
IBGE	Instituto Brasileiro de Geografia e Estatística
INMET	Instituto Nacional de Meteorologia
IPCA	Índice Nacional de Preços ao Consumidor Amplo
LGBM	<i>Light Gradient Boosting Machine</i>
MAE	<i>Mean Absolute Error</i> (Erro Médio Absoluto)
MAPE	<i>Mean Absolute Percentage Error</i> (Erro Percentual Médio Absoluto)
NE	Região Nordeste
NO	Região Norte
PIB	Produto Interno Bruto
SE	Região Sudeste
SELIC	Sistema Especial de Liquidação e de Custódia (Taxa Básica de Juros)
SMAPE	<i>Symmetric Mean Absolute Percentage Error</i> (Erro Percentual Absoluto Médio Simétrico)
SVR	<i>Support Vector Regression</i> (Regressão por Vetores de Suporte)
WAPE	<i>Weighted Absolute Percentage Error</i> (Erro Percentual Absoluto Ponderado)

SUMÁRIO

1 INTRODUÇÃO	15
1.1 Contextualização e delimitação do tema	15
1.2 Questão de pesquisa	17
1.3 Objetivos.....	17
1.3.1 <i>Objetivo geral</i>	17
1.3.2 <i>Objetivos específicos</i>	17
1.4 Justificativa	17
1.5 Estrutura do relatório.....	19
2 DIAGNÓSTICO DA SITUAÇÃO	19
2.1 Caracterização da empresa.....	19
2.2 Processo de previsão de demanda.....	21
3 REVISÃO DE LITERATURA.....	23
3.1 Previsão de demanda.....	23
3.2 Métodos qualitativos de previsão de demanda.....	25
3.3 Métodos quantitativos de previsão de demanda	27
3.4 Integração entre métodos de previsão de demanda	28
3.5 Estudos empíricos anteriores	30
4 PLANO DE AÇÃO.....	34
4.2 Detalhamento das etapas.....	35
4.2.1 <i>Definição de problema</i>	35
4.2.2 <i>Levantamento de variáveis causais</i>	35
4.2.3 <i>Obtenção e tratamento dos dados</i>	35
4.2.4 <i>Seleção dos métodos quantitativos e qualitativos</i>	36
4.2.5 <i>Previsão quantitativa</i>	36
4.2.6 <i>Incorporação de julgamentos</i>	36
4.2.7 <i>Monitoramento da performance</i>	36
4.3 Quadro resumo.....	37
4.4 Solução de previsão de demanda proposta.....	37
4.5 Impactos esperados	39
5 AVALIAÇÃO CRÍTICA DOS IMPACTOS ESPERADOS	40
5.1 Aplicação do plano de ação.....	40

<i>5.1.1 Definição de problema</i>	40
<i>5.1.2 Levantamento de variáveis causais</i>	41
<i>5.1.3 Obtenção e tratamento dos dados</i>	44
<i>5.1.4 Seleção dos métodos quantitativos e qualitativos</i>	47
<i>5.1.4.1 Seleção dos métodos quantitativos</i>	48
<i>5.1.4.2 Seleção do método qualitativo</i>	50
<i>5.1.5 Previsão quantitativa</i>	50
<i>5.1.6 Incorporação de julgamentos</i>	51
<i>5.1.7 Monitoramento da performance</i>	52
<i>5.1.8 Construção da solução</i>	53
5.2 Resultados e discussões	53
<i>5.2.1 Desempenho dos modelos</i>	53
<i>5.2.2 Resultado da previsão</i>	56
<i>5.2.3 Construção da solução</i>	59
<i>5.2.4 Discussão dos resultados</i>	62
<i>5.2.5 Impactos observados</i>	67
6 CONCLUSÕES	68
REFERÊNCIAS	72
APÊNDICE A – ROTEIRO DA ENTREVISTA SEMIESTRUTURADA (DIAGNÓSTICO DA SITUAÇÃO)	75
APÊNDICE B – ROTEIRO DA ENTREVISTA SEMIESTRUTURADA (ETAPA DE DEFINIÇÃO DE PROBLEMA)	76
APÊNDICE C – ESTRUTURA DA BASE DE DADOS (AMOSTRA ILUSTRATIVA)	77

1 INTRODUÇÃO

1.1 Contextualização e delimitação do tema

O agronegócio brasileiro se consolidou como um dos principais atores econômicos no país no ano de 2024. Segundo dados do Centro de Estudos Avançados em Economia Aplicada - CEPEA (2025), a participação do agronegócio no produto interno bruto (PIB) do Brasil chegou a 22%. De maneira complementar, Guth e Salvador (2017) defendem que o setor de máquinas e implementos agrícolas é significativo no cenário do agronegócio.

Lima, Santos e Amato Neto (2017) analisaram o desenvolvimento da indústria de máquinas e implementos agrícolas no Brasil no período compreendido entre os anos de 1985 e 2015 e constataram que o número de empresas fabricantes de máquinas e implementos agrícolas mais do que dobrou em 30 anos. Este crescimento teve uma concentração maior no mercado de implementos agrícolas, uma vez que as barreiras de entrada (investimento, tecnologia, entre outras) para esse mercado são menores quando comparado com a fabricação de tratores e colheitadeiras (Lima; Santos; Amato Neto, 2017).

Para Batista, Lopes e Costa (2022), o mercado da agroindústria é marcado por elevada complexidade, uma vez que o setor enfrenta forte dependência de variáveis externas, como as condições de mercado, as mudanças climáticas e a instabilidade econômica, que introduzem incertezas significativas no processo de gestão.

De forma complementar, Lima, Santos e Amato Neto (2017) defendem que o desenvolvimento do setor de máquinas agrícolas no Brasil ocorreu de forma fortemente atrelada a políticas públicas, em especial incentivos fiscais, taxas de juros subsidiadas e programas de financiamento direcionados ao produtor. Esse movimento esteve associado à expansão da área cultivada e ao aumento da produção e da produtividade no campo, além do avanço tecnológico, apesar de ainda concentrado em poucas grandes empresas.

A atividade agrícola é altamente dependente de fatores sociais, econômicos e políticos que afetam diretamente a produtividade e os ganhos financeiros. Isso exige dos produtores o uso de estratégias de adaptação diante de um ambiente incerto e altamente competitivo. O ambiente competitivo não se restringe ao microambiente interno das organizações, mas é fortemente condicionado pela conjuntura macroeconômica, marcada por incertezas como desaceleração da produção, elevação da inflação, aumento do desemprego e oscilações na taxa de juros. (Farago et al., 2016; Assad; Assad, 2024).

Por sua vez, o setor de máquinas agrícolas e implementos agrícolas se mostrou fortemente dependente da política agrária nacional e da disponibilização de crédito. Além disso, o mercado de máquinas está intrinsicamente ligado as variações da produção agrícola, especialmente das commodities para exportação, como grãos, laranja e café. As vendas internas de tratores e máquinas agrícolas sofrem sazonalidade em função do período de maior capitalização desses produtores, já que 70% das vendas se concentram no período de março a outubro, exigindo maior capacidade de gestão das empresas do segmento (Lima; Santos; Amato Neto, 2017).

Diante de um cenário de tanta competição, a previsão de demanda surge como uma das atividades de gestão mais importantes para o planejamento de operações de uma empresa. A previsão de demanda tem se mostrado um diferencial competitivo para as empresas que buscam otimizar suas operações. Ao utilizar modelos estatísticos para analisar dados históricos e identificar tendências, é possível tomar decisões mais estratégicas e aumentar a eficiência dos processos (Veríssimo et al., 2012). Nesse sentido, Atwani, Hlyal e Alami (2024) afirmam que a previsão de demanda tem um papel fundamental no fortalecimento e na resiliência de uma cadeia de suprimentos.

Para Gomes *et al.* (2023), a previsão de demanda se mostra importante uma vez que torna possível antecipar os anseios do mercado, fazendo com que as empresas possam se planejar, junto à sua cadeia de suprimentos, de forma a trabalhar de forma mais eficiente e gerar vantagens competitivas. Contudo, ainda de acordo com os autores, obter confiabilidade na previsão é uma tarefa muito difícil: o que gerará o diferencial competitivo desejado é errar menos que seus concorrentes.

A evolução dos métodos de previsão de séries temporais acompanhou o avanço tecnológico. Iniciada com os modelos ARIMA de Box e Jenkins, a área também viu a utilização de métodos estatísticos mais complexos, como, por exemplo, o método de Holt ou de Holt-Winters, que se trata de um método de suavização exponencial dupla ou tripla. Entretanto, houve uma transformação significativa com a popularização da inteligência artificial. Redes neurais e outras técnicas computacionais, como neuro-fuzzy, modelos caóticos e algoritmos como Random Forest e XG Boost surgiram como alternativas mais flexíveis e poderosas para lidar com a complexidade dos dados reais. A partir dos anos 2010, essas abordagens se consolidaram como ferramentas essenciais para a previsão de demanda em diversas áreas, desde a indústria até o varejo (Ackermann; Sellito, 2021; Alves *et al.*, 2019).

1.2 Questão de pesquisa

Diante do exposto na seção anterior, tem-se, então, a seguinte pergunta de pesquisa: como desenvolver uma solução de previsão de demanda que atenda às necessidades de planejamento de uma indústria de implementos agrícolas?

1.3 Objetivos

A seguir os objetivos (geral e específicos) do trabalho são apresentados.

1.3.1 Objetivo geral

O objetivo geral desta pesquisa é desenvolver e avaliar uma solução de previsão de demanda aplicada a uma indústria de implementos agrícolas.

1.3.2 Objetivos específicos

Como objetivos específicos, busca-se:

- (i) Definir um processo de previsão de demanda;
- (ii) Identificar os elementos mais relevantes para a construção do modelo de previsão, considerando abordagens qualitativas e quantitativas;
- (iii) Propor uma solução de previsão de demanda a partir dos elementos identificados;
- (iv) Aplicar a solução proposta, comparando o previsto e o realizado;

1.4 Justificativa

No campo acadêmico, diversos estudos sobre modelos de previsão de demanda foram feitos, propondo previsões através da aplicação das mais diversas técnicas de duas principais áreas: técnicas de computação estatística e de técnicas de Inteligência Artificial (Borsato; Corso, 2019).

Um estudo conduzido por Atwani, Hlyal e Alami (2024) indicou que cerca de 57% de das pesquisas de aplicação de métodos de previsão de demanda em indústrias realizadas até 2023 estão concentradas em quatro áreas: automotiva (18%), farmacêutica (18%), eletrônicos (12%) e alimentícia (9%). Não há menção direta à indústria de máquinas agrícolas, o que demonstra ter pouca produção sobre o tema aplicado especificamente à essa área.

De maneira complementar, Lv *et al.* (2024) afirmam que os métodos de previsão de demanda disponíveis na literatura são poucos efetivos ao ser aplicados na cadeia de suprimentos de equipamentos agrícolas, devido à complexidade desse mercado que conta com diversos fatores influenciadores. Portanto, a relevância acadêmica da presente pesquisa está em estudar

o processo de previsão de demanda aplicado a uma indústria de implementos agrícolas, tema pouco abordado na comunidade científica.

Os produtores rurais estão sujeitos a uma série de fatores que influenciam sua atividade. As condições naturais, como o solo e o clima, são elementos-chave e, por sua vez, difíceis de controlar. Além disso, a dinâmica da economia global, especialmente a taxa de câmbio, impacta diretamente a renda dos produtores, uma vez que muitos produtos agrícolas são comercializados em dólar no mercado internacional (Pinatti, 2008).

Como parte da cadeia de suprimento do agronegócio, o setor de máquinas e implementos agrícolas também sofre com as incertezas supracitadas. Para Lv *et al.* (2024), a demanda deste mercado apresenta características periódicas, demonstrando uma grande variação entre meses de pico e vales. Além disso, ainda de acordo com os autores, os processos de previsão de demanda dessas empresas são frequentemente baseados na experiência de seus gestores, que carecem de uma base científica.

Veríssimo *et al.* (2012) defendem que um processo acertado de previsão de demanda permite que os gestores planejem, aloquem e dimensionem recursos de forma otimizada, visando a redução de custos e ganho de eficiência operacional. Outro benefício apontado pelos autores está na redução de riscos na tomada de decisões, já que, quando bem executado, o processo de previsão traz segurança para os números, evitando vieses e decisões baseadas em achismo.

Nesse cenário, o presente estudo mostra sua relevância empírica ao propor uma solução de previsão de demanda adaptada à realidade dos fabricantes de máquinas e implementos agrícolas, setor caracterizado por elevada complexidade. Ao estruturar um processo de previsão eficiente e direcionado às especificidades desse mercado, a pesquisa oferece contribuições práticas para os gestores, auxiliando na tomada de decisões mais precisas, levando a ganhos operacionais e financeiros.

Como já exposto, por participar diretamente da cadeia de produção agropecuária, é necessária a realização de mais estudos nessa área, para que se possa visualizar melhor os seus reflexos na agroindústria, que é responsável por quase 25% do PIB do país (CEPEA, 2024). Nesse sentido, o estudo mostra sua relevância social, ao fornecer ferramentas para os gestores manterem a eficiência dessa indústria, garantindo o bom funcionamento de toda a cadeia econômica e trabalhista das empresas participantes desse mercado.

1.5 Estrutura do relatório

Além da introdução, o projeto possui mais 3 seções. A segunda seção trata do diagnóstico da situação alvo do estudo. Posteriormente, a seção 3 traz revisão de literatura sobre os temas centrais da pesquisa. A seção 4, por sua vez, apresenta o plano de ação proposto para a realização do estudo, já a seção 5 traz a avaliação crítica dos impactos esperados. Finalmente, na seção 6, encontram-se as conclusões do projeto.

2 DIAGNÓSTICO DA SITUAÇÃO

Esta seção apresentará o diagnóstico da situação alvo do estudo, iniciando pela caracterização da empresa e descrição como se configura o processo de previsão de demanda que é utilizado.

Para a obtenção dos dados utilizados para as análises expostas nessa seção, foi realizada uma entrevista semiestruturada com os principais gestores da empresa: diretor, gerentes comercial e de produção e coordenadora de suprimentos.

2.1 Caracterização da empresa

A empresa objeto deste estudo é uma tradicional fabricante de implementos agrícolas localizada no Nordeste brasileiro. Com mais de 50 anos de atuação no mercado nacional de equipamentos agropecuários, a empresa estudada foi, segundo o seu diretor, pioneira do segmento no Nordeste e produz, em média, 220 produtos por mês, atendendo 21 estados brasileiros, além de também possuir atuação no mercado externo, com exportações feitas para a América Latina e África. Possui um quadro com cerca de 210 funcionários, onde 47% desses estão diretamente ligados à produção, 36% são de setores que apoiam a produção e os outros 17% exercem atividades administrativas.

A empresa é organizada da seguinte forma: presidência da empresa, ocupada pelo principal investidor. Abaixo da presidência, está o Diretor Geral, responsável pelas decisões estratégicas e garantir o bom funcionamento da organização. Diretamente ligadas à direção, existem 2 gerências (produção e vendas externas), 5 coordenações (gestão de pessoas, compras, manutenção, contabilidade e engenharia de produtos) e 7 supervisões (controle de qualidade, SESMT, almoxarifado, financeiro, T.I., marketing e administração comercial).

Apesar de estar expandindo sua linha de produtos, é no nicho de transportes agrícolas que a empresa estudada se destaca. Os dados apresentados pelo setor comercial mostram que a linha de carretas (ou reboques agrícolas) correspondem a, em média, 98,51% do faturamento anual. O Diretor projeta um aumento na participação da linha de outros produtos nos próximos

anos, devido aos investimentos feitos pela empresa em pesquisa e desenvolvimento, principalmente em produtos direcionados para a área de colheita, lançados em julho de 2023.

A linha de carretas agrícolas está dividida em 2 famílias, de acordo com informações fornecidas pela Gerente comercial. Na primeira família estão as carretas utilizadas para transporte de forragem, grãos, café, frutas, entre outros produtos. As carretas também são utilizadas para os serviços gerais nas fazendas, servindo de apoio para limpeza, descarte de lixo, alimentação de animais etc. A segunda família de carretas tanques para água, utilizada para irrigação, combate a incêndio e transporte de água nas fazendas. Todas possuem diversas opções de capacidade de carga (variando de 2 a 12 toneladas), de sistema de rodado e opcionais como mola e freios. Além disso, o cliente pode optar por uma das 5 cores disponíveis: laranja, vermelho, amarelo, azul e verde.

Segundo a diretoria, a atuação comercial da empresa é do tipo *business to business* (B2B): a venda é realizada para revendas autorizadas e essas realizam a comercialização para o consumidor final, no caso, o agricultor. A equipe de vendas conta com 13 representantes comerciais, que realizam o atendimento junto às 420 revendas parceiras distribuídas por todas as regiões do país, com exceção do Sul.

O processo produtivo é composto por 6 principais etapas: corte de peças, estamparia, usinagem, solda, pintura e expedição, de acordo com o gerente de produção. A produção é do tipo puxada: só ocorre mediante a um pedido de venda. O tempo médio de entrega gira em torno de 20 dias corridos e cada produto é produzido, em média, em 5 dias. Apesar da distância geográfica para a maioria de seus clientes, o prazo de entrega é um dos menores do mercado, se configurando como um diferencial competitivo, de acordo com o diretor.

Segundo o gerente de produção, não há estoque de produtos acabados, uma vez que a estratégia adotada é produzir somente sob pedido de venda. Essa opção se justifica pelo elevado grau de flexibilidade existente entre os modelos de cada família, bem como pelo alto nível de personalização exigido, especialmente na etapa de pintura. Além disso, essa prática contribui para a redução dos estoques e dos custos associados, permitindo à empresa manter maior eficiência operacional e preservar o prazo de entrega como diferencial competitivo.

Contudo, essa estratégia necessita de um alinhamento bem executado entre a produção e o departamento de suprimentos. Segundo o gerente de produção, é comum que haja ruptura nos estoques de matéria-prima, principalmente nos itens mais específicos.

A coordenadora de suprimentos informou que grande parte dos fornecedores estão localizados no Sudeste e no Sul, o que faz com que o tempo entre o pedido e a entrega de um item seja de 35 dias, em média. O aço é a principal matéria-prima da empresa, responsável por

61,41% do total de compras. Tal material é comprado de duas formas principais: chapas ou perfis (aços redondos, quadrados, tubos e barras chatas).

A realidade exposta aponta para uma necessidade latente de um processo de previsão de demanda robusto e confiável, uma vez que a organização alvo desse estudo possui um mercado de atuação amplo e acirrado e, ao mesmo tempo, possui um desbalanceamento entre o tempo médio de suprimentos e o de produção.

Nesse contexto, a utilização de uma previsão de demanda mais precisa poderia contribuir significativamente para o planejamento da empresa como um todo. Do ponto de vista produtivo, permitiria melhor alinhamento com o setor de suprimentos, reduzindo o risco de rupturas de estoque e antecipando a necessidade de materiais críticos como o aço. No âmbito administrativo, setores como gestão de pessoas e financeiro também se beneficiariam, já que seria possível planejar a alocação de mão de obra e os fluxos de caixa com maior segurança. Dessa forma, a previsão de demanda se configura como uma ferramenta estratégica, capaz de integrar diferentes áreas e aumentar a eficiência organizacional.

O contexto narrado até aqui corrobora com o que é apresentado no trabalho de Kumar, Khdlekar e Khdlekar (2024), onde é posto que a gestão moderna da cadeia de suprimentos necessita de técnicas mais avançadas de previsão de demanda e de estratégias de controle de estoque para conseguir performar bem diante a uma realidade de demandas flutuantes, variações sazonais e interrupções de fornecimento.

2.2 Processo de previsão de demanda

Como participante da cadeia de suprimentos do agronegócio, a empresa também apresenta demanda com características sazonais e aleatórias. Atualmente, não há um processo de previsão estruturado na empresa, o que traz dificuldade para o planejamento de setores como a produção, suprimentos e financeiro.

Para a empresa estudada, a meta estabelecida é que o valor de vendas mensal seja superior ao faturamento registrado no mesmo período. Essa lógica pressupõe a manutenção de uma carteira de pedidos ativa, de modo a assegurar a continuidade da produção e possibilitar um planejamento mais assertivo dos setores de suprimentos e manufatura. Assim, busca-se garantir que o fluxo produtivo não sofra interrupções e que a empresa esteja preparada para atender à demanda futura com maior eficiência.

O valor da meta de venda é definido pela diretoria tanto com base em informações de mercado colhida em conversas com a gerente comercial e os representantes, como com base nos dados históricos do mês anterior e no mesmo período do ano anterior. Não há o uso de

qualquer ferramenta que, de alguma forma, faça a gestão dessas informações coletadas, para a realização de análises mais aprofundadas.

Segundo o diretor e a gerente de vendas, nas conversas com os representantes comerciais, fala-se sobre como está o mercado local, abordando a quantidade de cotações recebidas, os preços dos concorrentes e aspectos pontuais de cada região, tais como aspectos políticos, climáticos e econômicos. Essa realidade corrobora com a apresentada por Lv et al. (2024), um processo de previsão baseado na experiência e na análise de gestores e na equipe comercial, sem uma base científica definida.

Na empresa estudada, a carteira de pedidos corresponde ao conjunto de vendas registradas pelos representantes no sistema ERP, que permanecem pendentes até o faturamento, momento em que a mercadoria é enviada ao cliente, após a produção e expedição. Esse registro desempenha papel central na gestão organizacional, pois fornece subsídios para diferentes áreas: no setor de suprimentos, orienta a identificação dos materiais necessários, suas quantidades e a eventual necessidade de reposição de estoque; na produção, serve como base para a elaboração do plano mestre de produção; e, no setor financeiro, constitui referência para a projeção do fluxo de caixa.

Diante disso, a coordenadora de suprimentos informou que o setor de compras utiliza duas principais estratégias para o seu planejamento. Em um primeiro cenário, onde há uma pendência de pedidos de venda, o setor de compras realiza as aquisições dos itens necessários para o atendimento dos itens vendidos, de acordo com os dados presentes nos relatórios do ERP. No segundo cenário, quando a pendência de pedidos não permita uma programação a longo prazo, o comprador analisa o consumo médio o item, com base em dados históricos, e com base nisso decide a quantidade de compra e as datas de entrega.

A primeira estratégia só funciona bem em um cenário que a pendência esteja maior do que o tempo médio de entrega por parte dos fornecedores. A segunda estratégia tende a apresentar falhas quando há consumo concentrado de determinados itens, já que a média considera um consumo constante diário, o que não acontece na realidade. Arvan *et al.* (2019) defendem que a previsão de demanda é um processo crítico para o planejamento da cadeia de suprimentos e que as decisões estratégicas relacionadas a compras, tais como, por exemplo a escolha de fornecedores, devem ser baseadas na demanda.

A gestão da produção funciona de maneira mais eficiente quando há uma carteira de pedidos estruturada, pois, isso permite planejar de forma antecipada as etapas de fabricação. No entanto, nos períodos de retração nas vendas, surgem dificuldades adicionais. Nessas situações, quando não existem novos pedidos de carretas a serem produzidas, o planejamento

passa a ser orientado pela média móvel das vendas dos últimos meses, conforme relatado pelo gerente de produção. Esse cenário é particularmente desafiador em função da grande variedade de modelos ofertados e do elevado grau de customização exigido pelos clientes, o que amplia a complexidade do processo produtivo. Como consequência, podem ocorrer problemas como desbalanceamento das linhas de produção, aumento das horas extras, maior rotatividade de funcionários e até interrupções por falta de materiais. Nesse sentido, Veríssimo et al. (2012) destacam que, no setor industrial, a qualidade das previsões é determinante para assegurar a conformidade e a eficiência do processo produtivo.

3 REVISÃO DE LITERATURA

Nesta seção será feita a revisão de literatura, abordando os tópicos de previsão de demanda, métodos qualitativos de previsão de demanda, métodos quantitativos de previsão de demanda, métodos híbridos de previsão de demanda. Para concluir, serão apresentados estudos empíricos anteriores sobre aplicação de previsão de demanda.

3.1 Previsão de demanda

Os processos de planejamento em operações, tais como estoque, suprimentos e produção, dependem, de forma direta ou indireta, de uma previsão de demanda, de tal forma que, a qualidade desses planejamentos está intrinsecamente ligada à qualidade da previsão (Petropoulos *et al.*, 2018).

Ackermann e Sellitto (2022) definem a previsão de demanda como uma metodologia da administração de empresas que busca estimar o futuro da demanda proveniente de um mercado, sendo um elemento necessário para o processo de planejamento de operações de uma empresa. Ainda de acordo com os autores, a previsão de demanda busca prever o comportamento futuro através do reconhecimento de padrões em uma série de dados histórica ou da identificação de fatores que podem afetar o comportamento.


O impacto causado por um bom processo de previsão de demanda é transversal à organização e pode ser sentido nas mais diversas áreas e não apenas nas áreas operacionais. Por exemplo, o setor financeiro pode planejar melhor seu fluxo de caixa, a área de gestão de pessoas poderá gerir melhor seu processo de recrutamento e a área comercial poderá realizar ações promocionais em períodos que apontem por uma baixa de vendas (Pellegrini e Fogliatto, 2001).

Montgomery, Jennings e Kulachi (2016) estabelecem que o processo de previsão de demanda em 7 passos (Figura 1). O processo se inicia pela definição do problema, onde o

objetivo é entender como o requerente da previsão pretende utilizar os resultados. Após isso, os passos de coleta de dados históricos, tanto da variável de interesse como de variáveis preditoras potenciais, e o passo de análise desses dados, onde se deve plotar os dados históricos obtidos, para que se possa observar se existe padrões de sazonalidade e/ou tendência.

O quarto passo consiste na seleção de um ou mais modelos a serem utilizados, que, posteriormente serão validados no próximo passo, através da avaliação de sua performance na base de dados utilizada. Finalmente temos a aplicação do modelo na prática, realizando previsões, que devem ser constantemente monitoradas, através do cálculo dos erros de previsão, para averiguar se o modelo está performando da maneira que ele foi validado.

Figura 1 - Processo de previsão de demanda



Fonte: Adaptado de Montgomery, Jennings e Kulachi (2016).

É comum que as condições que vigoravam durante a validação do modelo mudem com o passar do tempo, o que pode fazer com que um método de previsão de teve um bom desempenho no passo de validação perca sua eficácia, resultando em erros maiores e mais sistemáticos nas suas previsões (Alves *et al.*, 2019).

O constante crescimento no volume de dados e na complexidade no ambiente de negócios estão promovendo incertezas nas previsões. Geralmente, as incertezas estão relacionadas à falta de conhecimento ou informações incorretas, bem como a mudanças constantes nas linhas de produtos (ciclo de vida cada vez menores) e interferência de fatores sazonais, econômicos e até climáticos (Moroff; Kurt; Kamphunes, 2021).

Nesse sentido, Alves *et al.* (2019) argumentam que existem métodos de se determinar a eficácia de um modelo de previsão. O desempenho do modelo é medido o erro entre o que foi previsto e realizado. As medidas mais utilizadas são:

O erro médio:

$$ME = \frac{1}{n} \sum_{t=1}^n (y_t - \hat{y}_t)$$

O erro médio absoluto; e

$$MAE = \frac{1}{n} \sum_{t=1}^n |y_t - \hat{y}_t|$$

O erro quadrático médio

$$MSE = \frac{1}{n} \sum_{t=1}^n [(y_t - \hat{y}_t)]^2$$

Onde n é o número de períodos previstos, y_t é o valor real obtido e \hat{y}_t é o valor da previsão. De forma complementar, Panarese *et al.* (2022) apresentam o Erro Médio Percentual Absoluto Ponderado (WAPE) como uma métrica relevante, já que retrata o erro absoluto ponderado pela quantidade real demandada. Em comparação com os outros métodos, o WAPE se destaca em cenários de vendas intermitentes ou com valores próximos a zero, uma vez que pondera o erro da previsão em relação ao volume total de vendas. O cálculo do WAPE é feito conforme a fórmula abaixo:

$$WAPE = \frac{1}{n} \frac{\sum_{t=1}^n |y_t - \hat{y}_t|}{\sum_{t=1}^n |y_t|}$$

Classificam-se os métodos de previsão de demanda em qualitativos e quantitativos. Nos qualitativos não é necessário a manipulação de dados, apenas julgamentos e análises baseadas na experiência do analista são utilizados para criar uma previsão. Já nos quantitativos, não existem julgamentos, apenas procedimentos padronizados que produzem resultados objetivos (Ackermann; Sellitto, 2022).

3.2 Métodos qualitativos de previsão de demanda

Os métodos qualitativos de previsão de demanda, que também podem ser chamados de métodos baseados no julgamento, são baseados na experiência de especialistas no segmento onde a previsão está sendo feita. Esses métodos são mais apropriados quando não há dados suficientes, ou confiáveis, para se realizar uma previsão quantitativa (Arvan *et al.*, 2019; Ackermann; Sellitto, 2022).

Para Petropoulos *et al.* (2018), os gestores acreditam firmemente que eles conhecem melhor o contexto mercadológico que gerou aqueles dados e, portanto, conseguem previsões mais acertadas do que aqueles puramente estatísticos. Staudt, Gonçalves e Rodriguez (2015) afirmam que previsões baseadas em julgamentos são mais adaptáveis às mudanças no mercado, devido ao conhecimento atualizado dos especialistas, contudo, é importante ressaltar que o julgamento humano pode conter inconsistências e tendências.

Para Ackermann e Sellitto (2022), um dos métodos qualitativos mais utilizados é o julgamento por especialista (ou abordagem de painel), que utiliza a opinião de especialistas como base para a predição de demanda. Cada especialista realiza individualmente sua previsão, que posteriormente serão combinadas com outras partes, chegando a uma previsão combinada. Ainda de acordo com os autores, os julgamentos dos especialistas podem ser utilizados em conjunto com métodos matemáticos, de modo que julgamentos subjetivos se tornem insumos estruturados para a tomada de decisão.

Para operacionalizar o uso de julgamento de especialistas, Staudt, Gonçalves e Rodriguez (2015) propõem um processo claro: iniciando pela seleção do painel, que deve priorizar especialistas com conhecimento de mercado e acesso a informações contextuais que o modelo não captura. Posteriormente, é feito um procedimento estruturado para coletar ajustes, registrando cada alteração sobre a previsão quantitativa em formulário padrão, o terceiro ponto é a justificativa obrigatória, vinculando cada ajuste a evidências observáveis (por exemplo, ações promocionais, restrições de suprimento, mudanças regulatórias). Além disso, deve-se fazer uma definição prévia de limites para a magnitude dos ajustes, a fim de reduzir viés e, finalmente, deve-se ter uma auditoria e retroalimentação, confrontando os ajustes com os resultados realizados para revisar limites e aperfeiçoar o procedimento nas iterações seguintes.

O método Delphi também é utilizado como um método qualitativo. Esse método consiste no envio de um questionário a uma equipe de 5 a 20 especialistas, onde são feitas e justificadas as previsões. O processo é repetido até que haja pouca variação entre as rodadas. O Delphi é frequentemente adotado em fenômenos complexos e pouco explorados anteriormente. Pode-se aplicar também o método de analogia estruturada, que consiste em gerar previsões com base em situações anteriores análogas às que se pretende prever (Ackermann; Sellitto, 2022).

Outro método qualitativo é o de analogia estruturada, que parte do princípio de que comportamentos passados podem orientar a previsão de uma nova situação por meio de comparações sistemáticas com casos históricos semelhantes. Normalmente, as pessoas recorrem às analogias para elaborar provisões, mas de forma não estruturada. O método de analogias estruturadas propõe um método formal que se inicia selecionando os especialistas que já tenham tido experiência direta em situações análogas. Esses especialistas identificam casos similares, qualificam o grau de semelhança em relação aos aspectos mais relevantes e mapeiam os desfechos observados nesses casos para o contexto atual. Em seguida, combinam-se os julgamentos para produzir uma estimativa análoga por especialista e, por fim, uma previsão consolidada para a situação-alvo (Amstrong; Green, 2019).

Tem-se que destacar os cuidados que devem ser tomados durante o processo qualitativo de previsão, de forma a eliminar possíveis vieses. Um viés pode acontecer quando um especialista realiza uma previsão motivado por algo particular (meta pessoal, por exemplo), quando há uma pressão externa para alcançar determinados resultados ou até mesmo o gestor pode ter controle parcial da variável alvo (Staudt; Gonçalves; Rodriguez, 2015).

3.3 Métodos quantitativos de previsão de demanda

Para Lv *et al.* (2024), os métodos quantitativos de previsão de demanda basicamente fazem suas previsões baseados na análise de dados históricos da variável que se quer prever, através da aplicação modelos matemáticos ou estatísticos, como análise de séries temporais e modelos de regressão e métodos de predição baseados em aprendizado de máquina (ou *Machine Learning*).

De maneira complementar, Atwani, Hlyal e Alami (2024) estabelecem que todos os métodos convencionais partem de uma mesma premissa: assumir que a demanda futura irá espelhar os padrões do passado. Consequentemente, ainda de acordo com os autores, a eficácia desses métodos está diretamente ligada à qualidade e quantidade dos dados utilizados o que torna a previsão de novos produtos desafiadora.

Os métodos quantitativos podem ser divididos em modelos causais e séries temporais. Ademais, os métodos com base em inteligência artificial também são considerados nesta classificação. Nos métodos causais, a demanda para determinado produto ou serviço (aqui chamada de variável dependente), apresentam uma relação causa-efeito com outras variáveis, ditas independentes ou causais. Ou seja, a demanda por um produto pode ser prevista em função de variáveis econômicas ou ambientais, por exemplo. Para isso, os dados devem seguir um comportamento identificável ao longo do tempo e devem existir relações identificáveis entre as variáveis dependentes e independentes (Ackermann; Sellitto, 2022).

A modelagem de séries temporais, que também é conhecida como modelagem univariada, é um conjunto de observações geradas sequencialmente durante um período e busca realizar a previsão utilizando apenas o tempo como variável de entrada (Ackermann; Sellitto, 2022). Essencialmente os métodos de previsão que utilizam essa modelagem, identificam padrões na série e buscam separá-lo dos ruídos (erros aleatórios) contidos nas observações. São considerados métodos estocásticos, uma vez que a evolução do processo ao longo do tempo é gerada e controlada por leis probabilísticas. Existem duas principais subdivisões entre os modelos matemáticos de séries temporais: os modelos Box-Jenkins, que partem da premissa que todos os valores de uma série são dependentes e que um valor pode ser explicado por

valores anteriores e os modelos de Suavização Exponencial, que aplicam uma ponderação distinta para cada valor observado na série temporal, de modo que valores mais recentes recebem um peso superior aos mais antigos (Alves *et al.*, 2019).

Diante da diversidade de métodos presentes na literatura, Veríssimo et al. (2012) destacam que a escolha pelo método mais adequado depende diretamente do comportamento da série temporal alvo da análise. Identificar características como média, sazonalidade, ciclo e tendência são determinantes para a escolha do modelo, uma vez que cada modelo foi pensado para aplicação para uma combinação entre essas características.

Para Pavlyshenko (2019), a previsão de vendas é um problema mais suscetível a ser resolvido por métodos de regressão do que de séries temporais. O autor argumenta que isso se deve à complexidade do ambiente onde os negócios estão inseridos, as características de sazonalidade e tendência podem ser causadas por fatores como preço, promoções, número de competidores e comportamento do consumidor. Além dos fatores conhecidos, podem ocorrer ainda ruídos na série, que podem ser definidos como fatores que não são conhecidos. Nesse cenário, ainda de acordo com o autor, algoritmos de *machine learning* são mais adequados para serem utilizados no processo de previsão de demanda.

Borsato e Corso (2019) complementam argumentando que a disseminação da inteligência artificial, métodos inteligentes de previsão feitos a partir de algoritmos *de machine learning* estão sendo cada vez mais utilizados em estudos de previsão de demanda. Segundo Ackermann e Sellitto (2022), os modelos baseados em IA podem identificar relações não lineares e interativas. Para os autores as redes neurais artificiais (RNA) têm sido amplamente aplicadas na previsão de demanda e vem apresentando valores satisfatórios. Contudo, além da RNA outros algoritmos também são empregados em estudos de previsão de demanda, tais como árvores de decisões, modelos caóticos, sistemas *neuro-fuzzy* e lógica difusa.

Contudo, apesar dos resultados dos métodos de IA serem satisfatórios, ainda existem lacunas que precisam ser melhoradas. Para isso, há uma tendência crescente de utilizar modelos híbridos baseados simultaneamente em modelos estatísticos e baseados em IA (Atwan; Hlyal; Alami, 2024).

3.4 Integração entre métodos de previsão de demanda

O uso de métodos quantitativos combinados com julgamento de especialistas é considerado por Arvan *et al.* (2019) a abordagem mais comum de previsão de demanda utilizada na indústria. De modo geral, o julgamento por especialistas é considerado um complemento aos métodos quantitativos. Enquanto os modelos quantitativos buscam identificar


padrões históricos por meio de técnicas estatísticas ou de aprendizado de máquina, o julgamento gerencial incorpora informações contextuais, conhecimento tácito e expectativas sobre eventos futuros ainda não refletidos nos dados históricos. Os métodos de integração podem ser classificados como ajustes de previsão baseados em julgamento e sistemas avançados de suporte à previsão.

De acordo com Staudt, Gonçalves e Rodriguez (2015), a integração entre métodos quantitativos e qualitativos é o melhor caminho para a obtenção de previsões mais adequadas e podem ser feitas através de três principais caminhos: o julgamento informa quais dados são relevantes, o julgamento pode influenciar na escolha do método a ser utilizado e o julgamento pode ser incorporado diretamente na previsão.

Existem diversos métodos de combinar as previsões: o primeiro trata-se de julgamento revisado, onde os especialistas fazem uma previsão inicial e, em seguida, a revisão com base nos dados provenientes de extrapolações estatísticas. O método da previsão combinada chega ao valor final realizando uma média simples ou ponderada de uma previsão estatística e por julgamento. O método de previsão baseado em regras utiliza o julgamento de especialistas para extrapolar os resultados de séries temporais, integrando o conhecimento do especialista sobre o ambiente e os processos de previsão, utiliza-se de regras condicionais (*if-then*), os pesos dos métodos de previsão simples são ajustados conforme as características da série previamente identificadas. Finalmente, no método de extrapolação corrigida, os especialistas ajustam uma previsão quantitativa, com base no seu conhecimento e informações disponíveis (Staudt; Gonçalves; Rodriguez, 2015).

O trabalho de Staudt, Gonçalves e Rodriguez (2015) faz a proposta de incluir a etapa de julgamento por especialistas no processo preditivo, como exposto na Figura 2:

Figura 2 - Processo de previsão de demanda com a incorporação de julgamentos.



Fonte: adaptado de Staudt, Gonçalves e Rodriguez (2015).

É no primeiro passo, definição do problema, onde se determina o que será previsto, o nível de detalhamento e o horizonte de previsão, levando em consideração a disponibilidade dos dados, acuraria, custo das análises e preferencias gerenciais. Na etapa de obtenção e tratamento de dados, inicialmente é feito uma avaliação dos fatores (internos e externos) que podem influenciar as vendas, posteriormente é feita a obtenção dos dados e o tratamento desses. Após isso é feita a seleção do(s) método(s) quantitativos a serem utilizados, com base nas

medidas de erro. O próximo passo é incorporar os julgamentos dos especialistas aos resultados encontrados no passo anterior. O último passo é, portanto, realizar o monitoramento das previsões com base em uma medida de erro, quando os erros passarem do limite estabelecido pela empresa, o processo deve ser revisitado e um novo método quantitativo, escolhido (Staudt; Gonçalves; Rodriguez, 2015).

Em síntese, a integração entre previsão estatística e intervenção humana constitui prática recorrente em ambientes caracterizados por volatilidade, mudanças estruturais ou influência significativa de fatores institucionais (Arvan *et al.*, 2019). A literatura diferencia ajustes informais, baseados exclusivamente na experiência individual, de abordagens estruturadas de integração, nas quais o julgamento é incorporado de maneira sistemática ao processo de previsão. Tal distinção é relevante porque a eficácia da integração depende do grau de formalização do processo, reduzindo vieses cognitivos e promovendo maior consistência decisória (Staudt; Gonçalves; Rodriguez, 2015).

3.5 Estudos empíricos anteriores

Por toda sua relevância estratégica para as organizações, é possível encontrar diversos estudos empíricos acerca de aplicações de previsão de demanda. O quadro 1 apresenta uma síntese de 4 dessas pesquisas, destacando o objetivo geral dos estudos, os itens apresentados no referencial teórico, descrição da aplicação contida nos estudos, quais técnicas de previsão de demanda foram utilizadas e uma breve descrição dos resultados alcançados. Os estudos foram obtidos através de consulta na base de dados *Web of Science*, com o termo de pesquisa “demand forecast” e no portal de periódicos da CAPES com o termo “previsão de demanda” AND “indústria”. Escolheram-se os estudos com aplicações voltadas para indústria e que aplicaram mais de uma técnica de previsão, seja para fins de comparação ou para integração de técnicas.

Quadro 1 - Estudos empíricos anteriores.

Autor (Ano)	Título	Objetivo geral	Ref. Teórico	Aplicação	Técnica utilizada	Resultado
Lemos e Fogliatto (2008)	Integração de métodos quantitativos e qualitativos de previsão para desenvolvimento de um sistema de previsão de demanda de novos produtos	Apresentação de uma metodologia para previsão de demanda de novos produtos com integração de métodos qualitativos e	Integração de métodos de previsão; Previsão de novos produtos	Lançamento de um produto novo no setor de distribuição de energia.	Método de analogia: Integração de técnicas. Quantitativa: extrapolação de séries temporais. Qualitativa: opinião de	A precisão das previsões resultou em baixa acurácia. Entretanto, apesar do grande erro das previsões

Autor (Ano)	Título	Objetivo geral	Ref. Teórico	Aplicação	Técnica utilizada	Resultado
		quantitativos de previsão.			especialistas (Delphi)	com o método selecionado, estas apresentaram menor erro que as dos especialistas da empresa.
Borsato e Corso (2019)	Aplicação de Inteligência Artificial e ARIMA na Previsão de Demanda no setor metal mecânico	Realizar a aplicação de métodos de previsão de demanda em uma empresa que atua no setor metal mecânico, comparando o modelo ARIMA com o modelo de Redes Neurais Artificiais (RNA).	Indústria 4.0; Estocasticidade dos dados; Métodos de previsão de demanda	Prever a demanda de uma indústria do ramo metal mecânico.	ARIMA e Algoritmos de RNA	O método de RNA apresentou melhor desempenho do que o ARIMA na comparação do erro de previsão.
Gomes et al. (2023)	Aplicação de Machine learning e séries temporais para previsão de demanda: um estudo de caso em uma empresa de bens de consumo	Impulsionar a acuracidade da previsão de demanda de uma empresa de bens de consumo, através da implementação de modelos de séries temporais e “ <i>machine learning</i> ”	Previsão de demanda. Aferição da acuracidade.	Aplicação em uma empresa de médio porte que produz bens de consumo	Aplicação de diversos modelos de séries temporais e diversos algoritmos de ML	Diminuição do erro médio em 19%.
Lv et al. (2024)	Agricultural equipment demand forecast based on data decomposition and integration	Desenvolver um método integrado para previsão de demanda capaz de performar bem para o mercado de tratores agrícolas.	Métodos de previsão de demanda; Integração entre métodos	Prever a demanda de um trator de grande porte de uma fabricante chinesa.	A previsão foi feita utilizando o método GSCV-SVR-Prophet combined prediction.	O modelo proposto apresentou melhores resultados do que os modelos de redes neurais artificiais, que são comumente mais utilizados.

Fonte: elaborado pelo autor (2025).

Quanto aos objetivos gerais, os estudos de Lemos e Fogliatto (2008) e Lv et al. (2024) buscam desenvolver uma metodologia para a previsão de demanda através da integração de métodos já existentes. Ambos os trabalhos sustentam que os métodos já conhecidos na literatura não entregam boas previsões quando aplicadas no mercado da empresa estudada. Já os outros dois estudos, Borsato e Corso (2019) e Gomes et al. (2023), aplicam algoritmos e técnicas disponíveis na literatura a fim de comparar, entre elas, qual tem o melhor desempenho na empresa-alvo do estudo.

Quanto ao referencial teórico, todos os estudos apresentaram um tópico de apresentação dos métodos de previsão de demanda, discutindo sobre definições de métodos quantitativos e qualitativos, conceituando os métodos de séries temporais e os algoritmos de *machine learning* e falando dos benefícios da integração entre os métodos. Além disso foram apresentados os métodos para a aferição da acuracidade ou avaliação da *performance* de um método. O estudo de Lemos e Fogliatto (2008) se destacou por ter um tópico voltado para previsão de demanda para novos produtos e Borsato e Corso (2019) discorreram sobre a Indústria 4.0.

Os 4 estudos apresentados tiveram aplicações voltadas para uma indústria de manufatura, com a empresa-alvo desse estudo. O estudo de Lv et al. (2024) se destaca por apresentar um método de previsão de demanda adaptado para as particularidades do mercado de máquinas agrícolas, mais especificamente para o de tratores. Os autores defendem que esse mercado possui particularidades que costumam impactar negativamente a acuracidade dos métodos tradicionais. Borsato e Corso (2019) realizam o estudo em uma indústria metalmeccânica, fazendo a previsão para as diversas famílias de produtos da empresa.

Os estudos apresentados por Lemos e Fogliatto (2008), Borsato e Corso (2019) e Gomes et al. (2023) trouxeram a discussão acerca da comparação de acurácia de diversos métodos, elegendo, ao final, aquele método que melhor performou no âmbito de sua pesquisa. Todos esses autores compararam métodos de previsão por séries temporais e métodos que utilizam algoritmos de aprendizado de máquina (*machine learning*), técnica que provém do campo de estudo da inteligência artificial. Já Lv et al. (2024) utilizou técnicas para decompor a série histórica de modo a normalizar os números para, posteriormente, utilizar a aplicação de aprendizado de máquina para a previsão.

Quanto aos resultados, apenas o estudo de Lemos e Fogliatto (2008) não apresentou uma boa acurácia após a implantação, contudo, o resultado ainda foi mais satisfatório do que o método puramente qualitativo utilizado anteriormente. O estudo de Borsato e Corso (2019) e

Gomes et al. (2023) concluíram que os algoritmos de *machine learning* tiveram melhor desempenho do que as técnicas de séries temporais. Já Lv et al. (2024) concluiu que o modelo apresentado no artigo apresentou melhores resultados do que os modelos de redes neurais artificiais.

Lemos e Fogliatto (2008) apresentaram um modelo de integração entre técnicas quantitativas e qualitativas de previsão de demanda, apresentando um modelo que pode ser replicado para outros trabalhos que busquem essa integração

Comparativamente, os estudos de Borsato e Corso (2019) e Gomes et al. (2023) se assemelham a explorar a comparação entre técnicas e eleger, com base no erro médio, qual se adequa mais à realidade estudada. Contudo, o primeiro foca em apenas uma técnica de séries temporais e uma de *machine learning*, enquanto o segundo compara uma quantidade maior. Apesar da diferença da metodologia dos trabalhos, os resultados convergem para uma maior acuracidade para as técnicas que utilizam inteligência artificial.

Finalmente, o estudo de Lv et al. (2024) aborda, especificamente, os desafios de previsão de demanda para uma empresa que está inserida na cadeia do agronegócio. O estudo foi realizado em uma empresa chinesa fabricante de tratores e se destaca por utilizar o método de decomposição de dados chamado EMD (Empirical Mode Decomposition), que quando aplicado em uma série de dados, os agrupa de acordo com padrões de semelhança. Em cada grupo é aplicada uma análise de periodicidade para que esses grupos sejam classificados em dados com padrões cíclicos daqueles que apresentam comportamento mais imprevisível. Posteriormente, aplica-se dois modelos de previsão diferentes: o Prophet, para os dados cíclicos e o SVR para os dados imprevisíveis. Finalmente, utilizam a validação cruzada para chegar à previsão final.


O uso de modelos de previsão por indústrias é, como demonstrado nessa seção, uma prática comum. Contudo, pode-se concluir que, diante da infinidade de técnicas e de suas aplicações, a previsão de demanda em uma determinada empresa têm um grande potencial de trazer ineditismo ao mundo acadêmico. Dessa forma, a presente pesquisa, que busca desenvolver um framework que utilize métodos quantitativos e qualitativos em uma indústria brasileira de implementos agrícolas, se faz relevante para a comunidade acadêmica, já que propõe a aplicação de técnicas amplamente utilizadas no meio científico em uma empresa pertencente a um setor de alta relevância econômica.

4 PLANO DE AÇÃO

Essa seção apresenta o processo da solução proposta nesse estudo, com o detalhamento de cada etapa e as saídas esperadas ao fim da aplicação da etapa. Por fim, um quadro resumo é apresentado.

O processo-modelo proposto neste estudo é composto por sete etapas e foi desenvolvido com base no modelo de previsão apresentado por Montgomery, Jennings e Kulachi (2016). A esse modelo base, foram incorporadas duas novas etapas: a primeira foi a inclusão do julgamento de especialistas, conforme sugerido por Staudt, Gonçalves e Rodriguez (2015), o que objetiva complementar as análises quantitativas com *insights* qualitativos provenientes da experiência prática de especialistas. A segunda contribuição consiste na adição de uma nova etapa: o levantamento de variáveis causais. Essa etapa tem como finalidade identificar fatores externos que influenciam diretamente a demanda, conforme defendido por Ackermann e Sellitto (2022), os quais destacam que a consideração de variáveis causais pode aumentar significativamente a acuracidade dos modelos quantitativos. Essa necessidade é ainda mais latente para uma empresa inserida no setor de máquinas e implementos agrícolas, caracterizado por uma demanda altamente sensível a múltiplos fatores, como apontado do estudo de Lv et al. (2024). Além disso, no quarto passo do processo, propõe-se a escolha do modelo qualitativo a ser utilizado, juntamente com o quantitativo, considerando-se os dados obtidos nas etapas anteriores. Essa abordagem permite uma combinação mais coerente entre método e contexto, fortalecendo a robustez das previsões. Para assegurar a adequação contínua dos modelos e variáveis escolhidos, incorpora-se um processo de realimentação baseado no monitoramento de performance, o qual sinaliza, por meio de critérios pré-definidos, quando revisar escolhas dos métodos, atualizar o conjunto de variáveis ou, até mesmo, iniciar novamente o processo inteiro. A figura 3 detalha o processo proposto:

Figura 3 - Processo-modelo proposto.



Fonte: elaborado pelo autor (2025).

4.2 Detalhamento das etapas

Esta subseção descreverá os passos do processo proposto, bem como as saídas esperadas após a conclusão da etapa.

4.2.1 Definição de problema

Nesta primeira etapa é definido o objetivo da previsão, o horizonte de previsão, o intervalo de previsão e o nível de detalhamento da previsão (se a previsão será feita por modelo ou família, por exemplo). A coleta de dados para essa etapa será feita através de uma entrevista semiestruturada com a direção e a gerência comercial.

Ao final dessa etapa, espera-se obter as seguintes saídas:

- a) Objetivo da previsão;
- b) Horizonte da previsão;
- c) Periodicidade da previsão;
- d) Intervalo de previsão; e
- e) Nível de detalhamento.

4.2.2 Levantamento de variáveis causais

Na segunda etapa é feito o levantamento de possíveis variáveis que podem influenciar na demanda da empresa. Para a obtenção dessas informações, foram conduzidas entrevistas com os representantes comerciais e alguns clientes, buscando entender quais fatores afetam na venda de equipamentos, além de consultar se esses agentes fazem previsão de demanda e como eles a realizam.

Ao final da segunda etapa, espera-se obter:

- a) Lista com possíveis variáveis causais, para serem testadas; e
- b) Aspectos considerados no processo de previsão de demanda dos clientes e dos vendedores, quando houver.

4.2.3 Obtenção e tratamento dos dados

Nesta etapa é feita a coleta dos dados relacionados à série temporal de vendas da empresa e às possíveis variáveis causais. Para Staudt, Gonçalves e Rodriguez (2015) é imprescindível a realização da limpeza nos dados coletados, para retirar eventos influentes que são de natureza não repetitiva (como promoções, por exemplo), outliers e valores faltantes. Os dados de vendas são obtidos através de relatórios gerenciais retirados do ERP da empresa.

Desta forma, ao final dessa etapa espera-se:

- a) Base de dados consolidada.

4.2.4 Seleção dos métodos quantitativos e qualitativos

Esta etapa é crucial para o bom desempenho da solução proposta. Através de uma pesquisa documental serão escolhidos os métodos quantitativos que, segundo a literatura, são mais indicados a serem aplicados na série de vendas. O método escolhido deve ser capaz de processar os fatores de média, sazonalidade, ciclo e tendência, levantados por Veríssimo et al. (2012) como características presentes em uma série histórica. Se mais de um método for aplicável à série, o método escolhido deverá ser aquele com menor MSE, considerando a amostra de treino e validação, conforme indicado por Staudt, Gonçalves e Rodriguez (2015). Quanto ao modelo qualitativo, é escolhido aquele com mais aderência à realidade da empresa.

O objetivo final dessa etapa é:

- a) Determinar o método quantitativo a ser aplicado; e
- b) Determinar o método qualitativo a ser aplicado.

4.2.5 Previsão quantitativa

Na quinta etapa, realiza-se a previsão quantitativa conforme o método selecionado na etapa anterior e os parâmetros definidos na etapa 1. A operacionalização é realizada em Python, aplicando os algoritmos utilizados para cada método escolhido em rotinas reprodutíveis para o cálculo das projeções.

Ao final dessa etapa, espera-se obter os resultados da previsão quantitativa.

4.2.6 Incorporação de julgamentos

Com o resultado da previsão é realizada a incorporação de julgamento dos especialistas, de maneira estruturada sugerida no estudo de Staudt, Gonçalves e Rodriguez (2015), para garantir que o processo tenha bom resultado.

Ao final, a previsão quantitativa é substituída pela previsão ajustada pelos especialistas e será o resultado desse modelo.

4.2.7 Monitoramento da performance

A última etapa se refere ao processo contínuo de monitoramento da performance da solução proposta. Os resultados reais de venda do período devem ser confrontados com o resultado da previsão e aferido o MAE e o WAPE, que devem estar dentro da tolerância apontada pela gestão da empresa. Caso contrário, o processo deve ser reiniciado e escolhido um novo modelo quantitativo com um erro menor.

4.3 Quadro resumo

O quadro 1 sumariza as etapas do processo proposto e relaciona os resultados esperados em cada uma delas.

Quadro 2 - Resumo das etapas do processo e seus resultados.

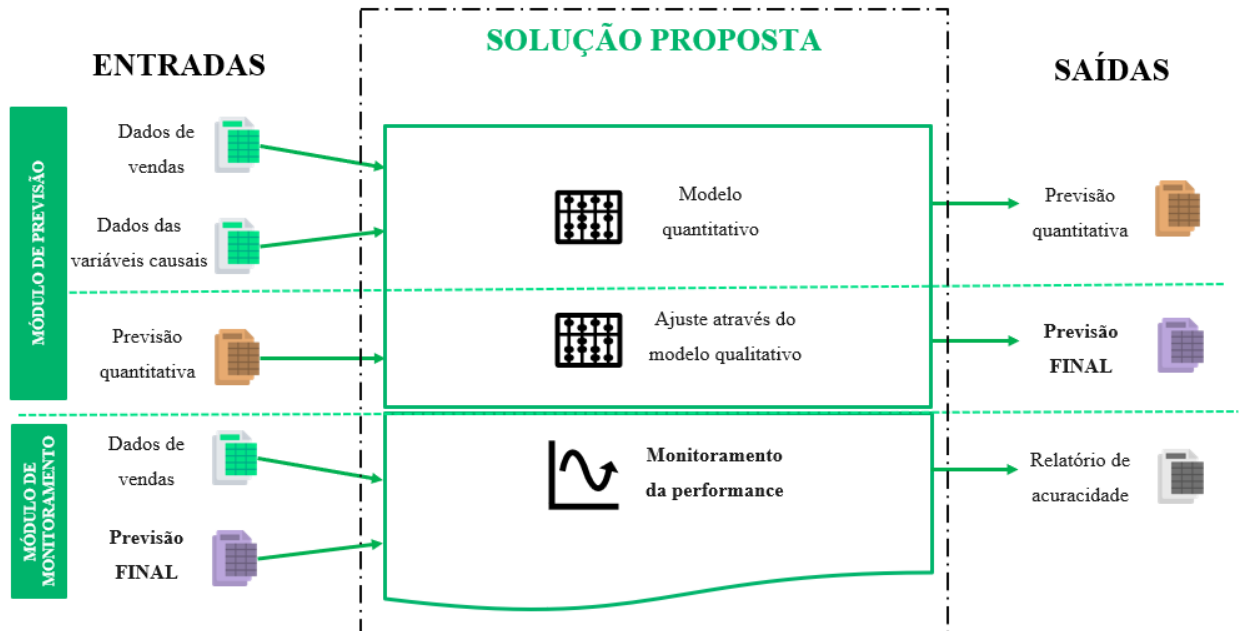
Nº etapa	Descrição	Resultados esperados
1	Definição do problema	Objetivo da previsão; horizonte da previsão; intervalo de previsão; periodicidade da previsão e nível de detalhamento
2	Levantamento de variáveis causais	Lista com possíveis variáveis causais e aspectos considerados na previsão de clientes e vendedores
3	Obtenção e tratamento dos dados	Base de dados consolidada
4	Seleção dos métodos quantitativos e qualitativos	Método quantitativo e qualitativo escolhido
5	Previsão quantitativa	Previsão feita
6	Incorporação do julgamento por especialistas	Previsão ajustada
7	Monitoramento da performance	Monitoramento do MAE e WAPE da previsão

Fonte: elaborado pelo autor (2025).

4.4 Solução de previsão de demanda proposta

Atwani, Hlyal e Alami (2024) defendem que o processo de previsão de demanda é proativo, servindo como ferramenta crucial para que as empresas possam se antecipar e se preparar para possíveis mudanças de mercado. Com base nessa afirmação, pode-se concluir que o processo de previsão deve ser tão assertivo quanto dinâmico. Assim, este trabalho propõe uma solução tecnológica para a previsão de demanda estruturada em dois módulos: previsão e monitoramento, conforme apresentado na figura 4:

Figura 4 - Framework da solução de previsão de demanda



Fonte: elaborado pelo autor (2025).

A solução foi estruturada em ambiente Web, disponibilizada aos gestores da empresa como ferramenta de suporte ao planejamento. O framework proposto organiza-se em dois módulos principais: módulo de previsão e módulo de monitoramento, configurando uma arquitetura modular e integrada.

O módulo de previsão integra o processo quantitativo e o processo qualitativo de forma sequencial. Os dados históricos de vendas e as variáveis causais, resultantes das etapas anteriores do processo, alimentam o modelo quantitativo selecionado. Esse modelo gera a previsão estatística inicial, que constitui a base para a etapa subsequente de ajuste qualitativo. O modelo qualitativo incorpora as informações gerenciais e contextuais não refletidas diretamente nos dados históricos, resultando na geração da previsão final. Essa integração estabelece um encadeamento entre modelagem estatística e intervenção humana, caracterizando o sistema como abordagem híbrida aplicada à previsão de demanda.

O módulo de monitoramento avalia continuamente a performance das previsões geradas. Para isso, utiliza como entradas os dados de vendas realizadas e a previsão final, calculando indicadores de erro, como MAE (erro médio absoluto) e WAPE (erro absoluto total dividido pelo total real). Os resultados são apresentados em relatório de acuracidade, fornecendo aos tomadores de decisão uma visão objetiva da qualidade das previsões. Essa etapa

permite acompanhar a consistência do processo preditivo ao longo do tempo e fornece subsídios para eventual revisão de parâmetros ou métodos adotados.

Essa estrutura diferencia a solução proposta por formalizar a integração entre modelo quantitativo e julgamento gerencial dentro de um processo sistematizado, alinhado à literatura que aponta a combinação estruturada entre previsão estatística e intervenção humana como prática recorrente e eficaz na indústria (Arvan et al., 2019).

4.5 Impactos esperados

Como visto anteriormente, hoje as metas de venda e faturamento são feitas através de conversas e comparações simples com meses anteriores, sem um processo definido e baseado em técnicas de mercado. A ferramenta passa a consolidar históricos, sinais de mercado e variáveis causais (preços, crédito, clima, política), convertendo percepções qualitativas em insumos mensuráveis. Espera-se que diversos processos, sejam eles operacionais ou administrativos, possam otimizar seu planejamento com base nos números gerados pelas previsões.

Em suprimentos, a operação oscila entre comprar com base na carteira ou recorrer a médias históricas, que tende a apresentar falhas quando a pendência é curta ou o consumo é concentrado. A ferramenta fornece os dados necessários para que a equipe de compras antecipe a necessidades por item, ou fornecedor, considerando sazonalidade e lead times, gerando plano de compras preditivo. A expectativa é reduzir compras emergenciais, rupturas e oscilações de estoque típicas do uso ingênuo de médias.

Na produção, a variabilidade do mix e a customização pressionam linhas, horas extras e estoques. Com previsões por família/região e horizonte adequado, o Plano Mestre de Produção passa a refletir o mix provável, permitindo nivelamento de carga, janelas de congelamento mais realistas e sequenciamento mais estável.

Para o financeiro, o ganho vem de projeções consistentes de faturamento e caixa, coerentes com o plano de produção e a carteira prevista (não apenas realizada), com faixas de incerteza e gatilhos de revisão. Isso viabiliza negociação de prazos, planejamento de capital de giro e maior aderência entre orçamento e realizado.

O principal diferencial da solução proposta está na adoção de método híbrido e estruturado, combinando modelagem quantitativa e qualitativa. O que, segundo Lemos e Fogliatto (2008), contribui para maior consistência decisória, mesmo em cenários de variabilidade e incerteza. Além disso, a solução foi construída considerando as especificidades do setor de implementos agrícolas, o que se aproxima da proposta de Lv et al. (2024), que

afirma que os métodos já conhecidos da literatura tendem a não funcionar bem no contexto do agronegócio.

5 AVALIAÇÃO CRÍTICA DOS IMPACTOS ESPERADOS

A presente seção dedica-se à análise crítica da aplicação do plano de ação, apresentando como as etapas propostas foram operacionalizadas no contexto da organização e quais resultados foram obtidos. Para tanto, a discussão será organizada em dois blocos: inicialmente, a aplicação prática do plano de ação, evidenciando como as fases do processo foram implementadas; em seguida, os resultados obtidos e a respectiva discussão crítica.

5.1 Aplicação do plano de ação

Esta subseção apresenta a aplicação prática do plano de ação proposto, descrevendo as etapas executadas, as ações realizadas em cada fase e as respectivas saídas obtidas.

5.1.1 Definição de problema

Segundo Montgomery, Jennings e Kulachi (2016), a definição do problema é uma etapa onde se deve, junto do que os autores chamam de cliente da previsão, estabelecer uma compreensão clara sobre como a previsão será utilizada, qual a forma desejada da previsão (por exemplo, se são necessárias previsões mensais), o horizonte temporal, a frequência de atualização (intervalo de previsão), e nível de detalhamento (se será feito a nível de família de produto ou de unidade de produto, por exemplo). Desta forma, realizou-se uma reunião presencial com a Diretoria da empresa e a Gerência comercial para discutir os pontos levantados pelos autores. O roteiro da entrevista semiestruturada encontra-se no Apêndice B.

Quanto ao objetivo de previsão, foi pontuado pelo diretor a necessidade de um planejamento financeiro e de operações mais acertado, garantindo que estratégias sejam traçadas nos setores de suprimentos, gestão da produção, comercial e financeiro, para garantir um custo operacional mais baixo e otimização de recursos. A resposta do diretor corrobora com o exposto no trabalho de Lemos e Fogliatto (2008), onde foi defendido que as previsões de demanda fomentam estratégias, ao colaborar com a gestão da alocação de recursos, eficiência na produção, alto nível de serviço ao cliente e demandas mais precisas aos fornecedores.

Definiu-se que as previsões contemplarão um horizonte de três meses, sendo revisadas mensalmente. Desse modo, a cada período as estimativas serão atualizadas com base nos dados mais recentes, o que permite maior alinhamento às variações do mercado, que, de

acordo com a Gerente Comercial, é extremamente volátil e sensível às variáveis econômicas e ambientais, por exemplo.

As previsões serão elaboradas por família de produtos. Para tanto, os itens foram classificados em duas categorias: carretas para transporte geral, utilizadas em atividades de colheita e no apoio às operações agrícolas; e carretas tanque, destinadas ao abastecimento de água e ao combate a focos de incêndio.

Além disso, considerando as diferenças estruturais entre os mercados atendidos pela empresa, a Diretoria definiu que as previsões também fossem elaboradas de forma regionalizada. Essa abordagem permite capturar as particularidades de cada mercado e aprimorar a sensibilidade do modelo às dinâmicas locais, garantindo que as estimativas reflitam com maior precisão as variações de demanda entre as regiões.

Finalmente, de forma complementar às previsões regionais e por família, definiu-se também a elaboração de uma previsão consolidada para o total de vendas mensais. Essa previsão tem caráter complementar e visa atender às áreas que operam com visão agregada da demanda, como produção e suprimentos, que necessitam planejar capacidade e materiais com base no volume global previsto, independentemente da distribuição regional. O que corrobora com Montgomery, Jennings e Kulachi (2016), que defendem que definição do nível de detalhamento da previsão deve estar alinhada ao propósito gerencial que ela pretende atender: previsões mais desagregadas tendem a capturar variações locais, enquanto previsões agregadas fornecem maior estabilidade e utilidade para o planejamento estratégico e operacional.

5.1.2 Levantamento de variáveis causais

A análise de fatores externos relacionados às vendas, como preço, estratégias de promoção e comportamento de concorrentes, pode resultar em estimativas mais precisas do que aquelas obtidas exclusivamente por métodos baseados em séries temporais. Além disso, a previsão de demanda mostra-se fortemente associada a variáveis do ambiente econômico, como indicadores macroeconômicos e taxas de juros nacionais (Pavlyshenko, 2019; Ackermann; Sellitto, 2022). Partindo dessas premissas, realizou-se reuniões com a equipe comercial a fim de mapear quais as variáveis, na opinião dos vendedores, poderiam afetar o desempenho das vendas.

Para garantir a maior acurácia da ação, todos os 13 representantes comerciais foram consultados. Os resultados obtidos estão expostos no Quadro 3:

Quadro 3 - Lista de variáveis

Variável	Descrição	Justificativa	Frequência de citação
Janela	Período do ano de maior demanda, segundo ciclos agrícolas	Indicador de sazonalidade que reflete os ciclos de plantio e colheita da região.	13
PV	Preço de venda	Em um mercado altamente competitivo, o preço constitui um fator decisivo para a concretização das vendas.	11
Evento	Realização de feiras e exposições agroindustriais	Esses eventos favorecem a geração de novos negócios e a prospecção de clientes.	10
Crédito_Rural	Crédito disponibilizado por programas governamentais	O acesso facilitado a linhas de crédito rural pode impulsionar a aquisição de máquinas e equipamentos.	6
Tx_Selic	Taxa básica de juros da economia brasileira	A taxa Selic impacta diretamente os juros dos financiamentos bancários, podendo estimular ou reduzir as vendas.	5
Prazo	Tempo médio de entrega	Prazos de entrega elevados podem comprometer a concretização de negócios.	5
Dólar	Cotação do dólar em reais	A valorização do dólar pode afetar negativamente produtores que importam insumos, mas beneficiar aqueles voltados à exportação.	4
Preço_soja	Valor de comercialização da saca de soja	A valorização da soja motiva produtores a expandirem sua produção agrícola.	3
Precipitação	Volume de chuvas em milímetros em determinada região	Variável ambiental diretamente associada à produtividade agrícola em diversas localidades.	2
IPCA	Índice Nacional de Preços ao Consumidor Amplo (inflação)	Índice oficial de inflação que orienta o poder de compra do consumidor final.	2
Preço_café	Valor de comercialização da saca de café	A elevação do preço do café tende a estimular o aumento da produção pelos produtores.	2

Fonte: elaborado pelo autor (2025).

A janela agrícola foi citada por todos os vendedores. Foi descrita por eles como o período do ano de maior demanda em função dos ciclos de plantio e colheita, onde as revendas realizam a compra ou, em algumas regiões, a programação de compra, para estarem abastecidos e atenderem aos agricultores.

O preço de venda foi o segundo mais citado, apenas dois representantes não o pontuaram como possível variável causal. O produto da empresa-alvo do estudo foi apontado por 7 representantes como o mais caro do mercado, o que justifica a escolha deles pelo preço. Ainda segundo eles, mesmo sendo um produto de boa qualidade, há aqueles clientes que preferem

preço mais baixo, e, nesses casos, negócios são perdidos. Na mesma linha, o prazo de entrega, apesar de ter sido citado apenas por 5 representantes, também atua como um fator interno que influencia o desempenho de vendas. Essas duas variáveis corroboram com o estudo de Pavlyshenko (2019), que argumentou que fatores internos (como o preço) pode influenciar a venda.

Para 10 representantes realização de eventos agroindustriais, como feiras e exposições, tem papel relevante na geração de novos negócios. Todos citaram a feira Agrishow, realizada anualmente na cidade de Ribeirão Preto, no estado de São Paulo, como a principal, a nível nacional, além de outras feiras regionais que tem um papel fundamental, segundo os representantes, na venda.

O crédito rural foi citado por 6 vendedores, uma vez que é um importante mecanismo de incentivo à aquisição de máquinas e implementos agrícolas, já que é um mercado que possui uma certa dependência de programas de incentivo econômico por parte do governo, como o Plano Safra, por exemplo (Lima; Santos; Amato Neto, 2017).

A Selic - Sistema Especial de Liquidação e de Custódia, que é a taxa básica de juros da economia brasileira, foi citada por 5 representantes, principalmente nas regiões onde os agricultores dependem mais de financiamentos para a realização de compras de máquina. O estudo realizado por Farago *et al.* (2016) evidenciou uma correlação moderada entre o valor da taxa Selic e o custo de produção agrícola. O IPCA, um outro índice macroeconômico, foi apontado por 2 representantes.

Para Barros (2019) a cotação do dólar impacta de maneira distinta os produtores do agronegócio: para aqueles que dependem de insumos importados, a valorização da moeda americana eleva os custos de produção, já para os produtores exportadores, a alta do dólar pode representar aumento de receita e, conseqüentemente, maior capacidade de investimento em novos equipamentos. Corroborando com o exposto, o valor do Dólar foi citado por 4 representantes.

O preço da soja possui foi citado apenas por 3 representantes, todos atuantes na região Centro-Oeste. Já o preço do café foi citado por 2 representantes, que atuam na região de Minas Gerais e Espírito Santo. Ambas as variáveis são regionais e foram apontadas como forte influenciadoras dos números de venda.

A precipitação pluviométrica foi citada por 2 representantes e, segundo defendido no trabalho de Assad e Assad (2024) é uma variável ambiental diretamente relacionada à produtividade agrícola: tanto a falta quanto o excesso de chuvas podem afetar a produção.

5.1.3 Obtenção e tratamento dos dados

A obtenção dos dados consiste na coleta dos históricos das variáveis a serem previstas bem como das possíveis variáveis preditoras. Contudo, além disso, deve ser feito um planejamento de como esses dados serão armazenados, coletados e tratados futuramente, garantindo a confiabilidade e a integridade das informações (Montgomery; Jennings; Kulachi, 2016).

Nesse sentido, foram coletados os dados referentes à variável foco da previsão (vendas), bem como das variáveis causais definidas na etapa anterior. O Quadro 4 apresenta um resumo das variáveis utilizadas, destacando suas respectivas fontes de obtenção.

Quadro 4 – Dicionário de dados: variáveis utilizadas, fontes, unidades de medida e tipo

Variável	Fonte de obtenção	Unidade de medida	Tipo de variável
Vendas	Relatórios internos / Sistema ERP	Unidades	Quantitativa discreta (dependente)
Janela	Entrevistas com representantes comerciais	Dummy (0 = Mês de baixa, 1 = mês de alta)	Qualitativa binária
PV (Preço de venda)	Relatórios internos / Sistema ERP	R\$ (valor unitário)	Quantitativa contínua
Evento	Relatórios internos	Dummy (0 = não ocorreu, 1 = ocorreu)	Qualitativa binária
Crédito_Rural	Matriz de Dados do Crédito Rural – Banco Central do Brasil	R\$ (valor total contratado)	Quantitativa contínua
Tx_Selic	Banco Central do Brasil	% ao ano	Quantitativa contínua
Prazo	Relatórios internos de logística/ERP	Dias	Quantitativa discreta
Dólar	Banco Central do Brasil	R\$/US\$	Quantitativa contínua
Preço_soja	CEPEA/ESALQ	R\$/saca (60kg)	Quantitativa contínua
Preço_café	CEPEA/ESALQ	R\$/saca (60kg)	Quantitativa contínua
Precipitação	INMET	mm/mês	Quantitativa contínua
IPCA	IBGE	% ao mês	Quantitativa contínua

Fonte: elaborado pelo autor (2025).

Após a obtenção dos dados, deu-se início à fase de tratamento. Para Montgomery, Jennings e Kulachi (2016), o tratamento dos dados envolve lidar com valores ausentes, potenciais outliers e outros problemas relacionados à qualidade das informações. Ainda de acordo com os autores, é necessária a realização de análises preliminares para obter uma

compreensão inicial do comportamento da variável e orientar a escolha dos métodos de previsão mais adequados.

A variável dependente Vendas e as variáveis PV e Prazo, foram obtidas a partir do relatório intitulado “*Ranking de Região – Vendedores por Produtos*”, extraído do sistema ERP da empresa. Os dados foram estruturados de forma agregada por mês e ano, seguindo o formato ano/mês, de modo a possibilitar análises temporais consistentes. Escolheu-se o período de 79 meses, compreendido entre janeiro de 2019 e julho de 2025. Além disso, as informações foram segmentadas por região geográfica (Norte, Nordeste, Centro-Oeste e Sudeste) e por família de produtos (Carretas ou Tanques), conforme definido pela Diretoria e Gerência Comercial. No processo de verificação, constatou-se que não havia registros ausentes. Para fins de análise, o valor da variável Vendas foi agregado por soma, enquanto para PV e Prazo foi considerada a média simples.

A variável Janela foi construída a partir das entrevistas semiestruturadas com os representantes comerciais, que identificaram os períodos do ano considerados de maior demanda em função dos ciclos agrícolas. Para adequação ao modelo, a variável foi operacionalizada como *dummy*, assumindo valor igual a 1 nos meses classificados como de maior demanda e 0 nos meses de menor demanda.

A variável Evento foi tratada de forma semelhante: com base nos dados fornecidos pelo setor de Marketing, a variável foi tratada como *dummy*, assumindo valor 1 para os meses em que houve a realização de uma feira ou exposição e valor 0 nos meses em que não houve. A variável assumia 1 apenas na região onde o evento foi realizado.

Outra variável que também foi regionalizada foi a Crédito_Rural. Os dados foram obtidos através da Matriz de Dados do Crédito Rural, disponível no sítio eletrônico do Banco Central do Brasil. Os resultados são apresentados por contrato, contudo, há a informação da cidade para onde foi disponibilizado, bem como da data de liberação do crédito. Com base nessas duas informações, realizou-se o tratamento, somando os valores disponibilizados por ano/mês e por região.

A variável Taxa Selic foi obtida a partir das séries históricas disponibilizadas pelo Banco Central do Brasil (BACEN), representando a taxa básica de juros da economia brasileira. Os dados foram coletados em periodicidade mensal e incorporados ao banco de dados no mesmo formato temporal das demais variáveis (ano/mês).

A variável IPCA foi obtida partir das séries históricas disponibilizadas pelo Instituto Brasileiro de Geografia e Estatística (IBGE), que o divulga mensalmente. Já a variável Dólar foi construída a partir da série histórica da taxa de câmbio oficial (R\$/US\$), disponibilizada

pelo Banco Central do Brasil (BACEN). Para fins deste estudo, ambos os dados foram coletados em periodicidade mensal e incorporados à base no formato ano/mês.

A variável Precipitação foi construída a partir dos relatórios de séries históricas disponibilizados pelo Instituto Nacional de Meteorologia (INMET), os quais apresentam dados individualizados por estação meteorológica, cada uma identificada por um número específico. Esse código de identificação permitiu vincular cada estação à respectiva cidade, estado e, posteriormente, à região geográfica. Para o tratamento da variável, os valores de precipitação (em milímetros) foram agregados por região, no formato ano/mês, por meio da soma dos totais mensais registrados em todas as estações correspondentes. Esse procedimento possibilitou representar o volume de chuvas de forma regionalizada e alinhada à periodicidade das demais variáveis do modelo.

Finalmente, as variáveis Preço_soja e Preço_café foram obtidas a partir das séries históricas disponibilizadas pelo CEPEA/ESALQ. Os valores, expressos em reais por saca de 60 kg, foram coletados em periodicidade mensal e organizados no formato ano/mês. Ambas as variáveis foram tratadas como quantitativas contínuas e incorporadas à base de dados de forma alinhada às demais variáveis utilizadas no estudo.

Como resultado, a base de dados foi estruturada em formato tabular, organizada em periodicidade mensal, seguindo o dicionários de variáveis apresentado no Quadro 4. Cada linha da base representa uma observação referente a uma região e a um período específico (ano-mês), contendo como variável dependente o volume de vendas e, como variáveis independentes, os fatores causais selecionados ao longo do processo metodológico.

A estrutura da planilha contempla os seguintes campos principais: identificador temporal (ano_mês), identificação regional (REGIAO), variável alvo (vendas) e conjunto de variáveis explicativas de natureza econômica, mercadológica e sazonal. Entre as variáveis utilizadas encontram-se indicadores macroeconômicos (como taxa de juros, câmbio e inflação), variáveis setoriais (como preço de commodities agrícolas), variáveis de sazonalidade e indicadores internos relacionados a políticas comerciais.

A consolidação dos dados ocorre por meio da organização mensal por região, garantindo consistência temporal e comparabilidade entre os recortes analisados. As informações são previamente higienizadas, com tratamento de valores ausentes, padronização de nomenclaturas e verificação de coerência temporal, assegurando que o conjunto de dados utilizado no treinamento e validação dos modelos esteja alinhado às premissas metodológicas estabelecidas.

Considerando que a previsão foi realizada de forma segregada por família de produtos, foram estruturadas bases de dados independentes para cada uma delas. Assim, os dados

referentes à família Carretas e à família Tanques foram organizados separadamente, mantendo a estrutura de variáveis, porém com a variável dependente específica para cada grupo. No Apêndice C consta uma amostra da base de dados utilizada neste estudo, contendo as 60 primeiras observações. A estrutura apresentada preserva todas as variáveis descritas no dicionário de dados e mantém o formato empregado no treinamento e validação dos modelos.


5.1.4 Seleção dos métodos quantitativos e qualitativos

Para Montgomery, Jennings e Kulachi (2016), a etapa consiste na escolha de um ou mais modelos adequados ao problema estudado e na estimação de seus parâmetros a partir dos dados históricos. Adicionalmente, os autores explicam que a escolha é baseada na aplicação dos métodos escolhidos nos dados históricos, realizando a divisão da base em segmentos de treino e teste, o que permite estimar a capacidade preditiva dos modelos em novos cenários e comparar alternativas concorrentes.

Adicionalmente, Pellegrini e Fogliatto (2001), defendem que existem outros fatores que devem ser levado em consideração na escolha do modelo de previsão mais apropriado, onde pode-se citar a característica da série temporal (sazonalidade e aleatoriedade, por exemplo), aspectos que influenciam a demanda, agregação temporal dos dados e intervalo das previsões.

Dessa forma, iniciou-se o processo de seleção pela análise da série histórica de vendas. O Gráfico 1 plota os dados de vendas por mês para cada uma das 4 regiões onde a empresa atua:

Gráfico 1 - Vendas por região



Fonte: elaborado pelo autor (2025).

Ao analisar o gráfico, pode-se concluir que há a presença de sazonalidade nas vendas de todas as regiões. Observa-se picos e vales de demanda, que se repetem na mesma época do ano durante o período de análise. Para as regiões Sudeste e Nordeste, percebe-se que os picos são mais pronunciados. O Sudeste apresenta maior volatilidade, picos muito altos e quedas bruscas, indicando uma sazonalidade mais forte do que nas demais regiões.

Além disso, observa-se também a existência de tendência. A região Sudeste demonstra um crescimento acentuado ao longo do período estudado, o Nordeste também apresenta tendência de crescimento, apenas de mais moderado. As vendas do Norte e do Centro-Oeste demonstram uma leve tendência negativa, o que demonstra uma estagnação no número de vendas.

Finalmente, percebe-se a grande relevância dos mercados do Nordeste e do Sudeste para a empresa. As duas regiões juntas são responsáveis por 80,34% de toda a venda da empresa, durante o período analisado, conforme a Tabela 1:

Tabela 1 – Participação de cada região no total de vendas

Região	Qtde Vendida	Participação
Sudeste	7.621	43,78%
Nordeste	6.364	36,56%
Norte	1.871	10,75%
Centro-Oeste	1.551	8,91%

Fonte: elaborado pelo autor (2025).

5.1.4.1 Seleção dos métodos quantitativos

Diversos estudos recentes têm apontado limitações nos métodos tradicionais de séries temporais, sobretudo em contextos de alta variabilidade e complexidade. Tais abordagens apresentam dificuldades em capturar padrões não lineares, efeitos de promoções, variações regionais e ciclos de curto prazo. Em contraposição, modelos baseados em inteligência artificial, mostram-se mais adequados por integrarem variáveis externas, tais como clima, preços, calendário e eventos promocionais (Honjo; Zhou; Shimizu, 2022).

De forma complementar, Aktepe, Yanik e Ersöz (2021) analisaram a previsão de demanda de peças de reposição em uma indústria de máquinas para construção, comparando modelos de regressão linear e não linear com métodos de inteligência artificial. O estudo evidenciou que os métodos estatísticos tradicionais, embora úteis, não capturam

adequadamente variáveis externas relevantes (sejam elas econômicas, ambientais ou internas à empresa). Ainda segundo os autores, em setores caracterizados por alta variabilidade e múltiplos fatores explicativos, as abordagens de inteligência artificial oferecem maior robustez preditiva.

Diante do exposto, este trabalho utilizará dois métodos de inteligência artificial para a realização da previsão quantitativa, uma vez que diversas variáveis externas foram pontuadas pelos representantes comerciais como influenciadoras na demanda. Além disso, como exposto por Lv et al. (2024), o mercado de máquinas e implementos agrícolas configura-se como um sistema complexo, influenciado por múltiplos fatores.

O primeiro método de inteligência artificial selecionado é o *Gated Recurrent Unit* (GRU), uma variação das redes neurais recorrentes (RNN). O GRU foi desenvolvido como uma alternativa mais rápida de ser treinada, em comparação à outras técnicas, uma vez que possui um menor número de parâmetros internos e, conseqüentemente, maior eficiência computacional, preservando a capacidade de capturar dependências temporais de médio e longo prazo (Honjo; Zhou; Shimizu, 2022).

O *Light Gradient Boosting Machine* (LGBM) é uma implementação otimizada do algoritmo *Gradient Boosting Decision Tree* (GBDT), projetada para lidar com grandes volumes de dados e bases de alta dimensionalidade. Seu diferencial está na utilização das técnicas que reduzem a dimensionalidade por meio do agrupamento de variáveis mutuamente exclusivas. O LightGBM consegue acelerar significativamente o processo de treinamento sem comprometer a acurácia, o que o torna especialmente adequado para aplicações em que há grande quantidade de observações e variáveis explicativas esparsas, como é o caso de problemas de previsão de demanda com múltiplos fatores causais (Ke et al., 2017).

Para Atwani, Hlyal e Alami (2024), embora os métodos de inteligência artificial apresentem resultados satisfatórios, observa-se uma tendência crescente de adoção de modelos híbridos, que combinam técnicas estatísticas e de IA. Seguindo essa perspectiva, este trabalho incorporou também um método de séries temporais para a realização das previsões. O Prophet, desenvolvido por Taylor e Letham (2018), é um modelo baseado em decomposição aditiva que integra três componentes principais: tendência, sazonalidade e eventos específicos. Tais componentes estão presentes na série de vendas da empresa estudada.

O uso de três técnicas distintas de previsão traz consigo o desafio de conciliar os resultados em um único direcionamento. A combinação de previsões surge como solução a esse problema, através da agregação de diferentes modelos em uma previsão consensual. Além de facilitar o processo decisório, essa abordagem apresenta vantagens estatísticas relevantes, uma vez que a combinação tende a superar os resultados obtidos por previsões individuais (Chan; Pauwels, 2023).

5.1.4.2 Seleção do método qualitativo

Conforme destacado por Staudt, Gonçalves e Rodriguez (2015), quando o julgamento humano é incorporado de forma estruturada à previsão quantitativa, há tendência de aumento da acurácia. O estudo dos autores mostrou que os ajustes realizados por especialistas reduziram os erros das previsões em média em 5%, sendo os maiores ganhos observados em séries com elevada variabilidade. Além disso, os resultados evidenciam que ajustes fundamentados em informações adicionais tendem a trazer benefícios superiores aos ajustes pequenos e intuitivos.

5.1.5 Previsão quantitativa

Partindo da base de dados já higienizada na etapa de tratamento, a série foi segmentada nas quatro regiões (Norte, Nordeste, Centro-Oeste e Sudeste), permitindo que cada uma apresentasse sua própria leitura de tendência e sazonalidade. Essa segmentação considerou que as variáveis causais foram apontadas por representantes regionais, podendo não refletir a realidade de outras localidades. Como exemplo, o preço do café possui relevância apenas nas regiões onde a cafeicultura é expressiva.

Segundo Petropoulos et al. (2018), a seleção de modelos deve se apoiar em validação temporal. A série histórica foi dividida em dois blocos: treino, no qual cada modelo foi ajustado, e validação, mantido fora do processo de ajuste. O conjunto de treino foi composto pelas observações históricas anteriores ao período de teste, enquanto o conjunto de validação contemplou os períodos mais recentes, simulando o cenário real de previsão. Essa abordagem evita vazamento de informação, uma vez que dados futuros não foram utilizados no processo de treinamento. Após o ajuste no conjunto de treino, cada modelo gerou previsões para o período de validação, sendo o desempenho comparado por meio das métricas de acurácia.

O desempenho foi avaliado por meio das métricas MAE (erro médio absoluto, em unidades de venda) e WAPE (erro absoluto total dividido pelo total real, em percentual). O MAE permite interpretação direta do erro médio em termos operacionais, enquanto o WAPE

facilita comparações entre regiões e períodos com diferentes volumes de venda. O modelo que apresentou menor erro no período de validação foi selecionado como o mais adequado para cada região.

Seguindo o estabelecido por Chan e Pauwels (2023), as previsões dos modelos também foram combinadas por média ponderada, na qual os pesos refletem o desempenho relativo de cada método. Ainda segundo os autores, recomenda-se utilizar o MAE para cálculo dos pesos, por apresentar maior robustez a outliers quando comparado a medidas quadráticas. Assim, para cada modelo i , o peso foi determinado conforme:

$$\varepsilon_i = \frac{\frac{1}{MAE_i}}{\frac{1}{MAE_{LGBM}} + \frac{1}{MAE_{GRU}} + \frac{1}{MAE_{Prophet}}}$$

Foram avaliadas duas combinações: o Ensemble3, que integrou LGBM, GRU e Prophet, e o Ensemble2, que combinou LGBM e Prophet. As previsões combinadas foram calculadas por média ponderada dos respectivos modelos individuais.

$$\hat{Y}_{Ensembled3} = \varepsilon_{LGBM} \cdot \hat{Y}_{LGBM} + \varepsilon_{GRU} \cdot \hat{Y}_{GRU} + \varepsilon_{Prophet} \cdot \hat{Y}_{Prophet}$$

$$\hat{Y}_{Ensembled2} = \varepsilon_{LGBM} \cdot \hat{Y}_{LGBM} + \varepsilon_{Prophet} \cdot \hat{Y}_{Prophet}$$

O método de previsão selecionado variou conforme a região analisada. Para cada série, foram testados os diferentes modelos e, a partir das métricas de erro MAE e WAPE, foi escolhido aquele que apresentou o menor valor, garantindo maior precisão nos resultados. Esse processo é reavaliado a cada nova rodada de previsão, de modo que todos os métodos continuarão sendo aplicados às séries, e a previsão final é definida com base no desempenho do modelo que apresentar o menor erro no período de validação.

Com a validação feita, gerou-se a projeção trimestral, conforme determinado pela Diretoria e Gerência Comercial, para os meses-alvo (agosto, setembro e outubro de 2025), utilizando 5 modelos: LGBM, GRU, Prophet, Ensemble2 e Ensemble3. O procedimento é sequencial: prevê-se o próximo mês e, em seguida, usa-se essa previsão como parte do histórico para projetar o mês seguinte, e assim por diante.

5.1.6 Incorporação de julgamentos

Para Arvan *et al.* (2019), o processo de ajuste qualitativo de uma previsão é geralmente composto por duas etapas, inicialmente deve ser decidido se realmente há a

necessidade de ajustes na previsão quantitativa. Caso se entenda que sim, deve haver a determinação do tamanho do ajuste e então aplicar as mudanças à previsão.

Staudt, Gonçalves e Rodriguez (2015), estabelecem que os especialistas devem ter conhecimento de mercado e informações contextuais que não são capturadas pelo modelo. Além disso, a fim de evitar vieses, os julgamentos devem ser formalizados, devendo haver justificativas para cada ajuste, e limites máximos de ajustes devem ser determinados.

Dessa forma, o resultado da previsão quantitativa foi apresentado aos representantes comerciais e à Gerente, que se encarregaram de fazer os ajustes seguindo o rito definido no trabalho de Staudt, Gonçalves e Rodriguez (2015).

5.1.7 Monitoramento da performance

O monitoramento da performance é realizado ao final de cada mês, por meio da comparação entre as previsões geradas e os resultados efetivamente observados. Nesse processo, serão calculadas as métricas MAE e WAPE, de modo a avaliar a precisão das estimativas. A escolha desses métodos se deu por serem o MAE expressa o erro médio em unidades, de fácil interpretação gerencial, enquanto o WAPE pondera os erros em relação ao volume total de vendas, oferecendo uma medida mais equilibrada em contextos sazonais ou de baixa escala, como é o caso dos dados utilizados nesse estudo (Panarese et al., 2022).

A revisão mensal é fundamental para atestar a eficiência da solução proposta e garantir sua aderência às dinâmicas do mercado. Caso seja identificado que o modelo perdeu precisão de forma consistente, deverá ser reiniciado todo o processo de seleção e avaliação, considerando a aplicação de novos métodos quantitativos e qualitativos que possam aprimorar o desempenho da previsão.

No período de elaboração deste trabalho, apenas o mês de agosto pôde ser submetido a esse monitoramento; ao fim do mês, os valores reais foram inseridos na solução e as métricas calculadas, confirmando que o modelo mantinha sua validade. Dessa forma, o monitoramento contínuo das previsões garante que a solução proposta não se limite a uma aplicação pontual, mas se configure como um processo dinâmico e sustentável, capaz de se adaptar às mudanças do mercado e preservar a confiabilidade das estimativas ao longo do tempo.

5.1.8 Construção da solução

Para Siebert, Groß, Schroth (2021), o Python consolidou-se como uma das linguagens de programação preferidas por cientistas de dados, em razão de sua ampla gama de bibliotecas e da flexibilidade para aplicações em análise e modelagem de séries temporais.

Seguindo esse entendimento, solução proposta foi implementada em Python, linguagem escolhida pela ampla disponibilidade de bibliotecas voltadas à análise de séries temporais e aprendizado de máquina. Para o cálculo das previsões quantitativas foram utilizados pacotes como *pandas* e *numpy* (tratamento e manipulação dos dados), *scikit-learn* (modelos de regressão e métricas de desempenho), *lightgbm* (implementação do gradient boosting), *prophet* (modelo aditivo para séries temporais) e *tensorflow/keras* (rede neural GRU).

Para a utilização por parte do usuário final, desenvolveu-se um ambiente web utilizando a biblioteca *Streamlit*, que prezou pela simplicidade e pela facilidade de uso. Nesse ambiente, o usuário insere os dados, o código processa as previsões e apresenta os resultados quantitativos de forma automática. Adicionalmente, foi criada uma aba para a realização dos ajustes qualitativos, de modo a incorporar o julgamento de especialistas, bem como uma área de monitoramento dos erros, na qual é possível consultar o histórico da série de vendas e das variáveis explicativas.

5.2 Resultados e discussões

Esta subseção expõe os resultados obtidos a partir da aplicação do plano de ação, bem como a análise crítica de seus impactos, destacando implicações práticas, benefícios alcançados e limitações observadas.

5.2.1 Desempenho dos modelos

A Tabela 2 expõe o resultado da aplicação na série de validação para a família de carretas e a Tabela 3 para a família de tanques:

Tabela 2 – MAE e WAPE para a família de carretas

Método	Nordeste		Sudeste		Norte		Centro-Oeste		Total	
	MAE (Un)	WAPE (%)	MAE (Un)	WAPE (%)	MAE (Un)	WAPE (%)	MAE (Un)	WAPE (%)	MAE (Un)	WAPE (%)
Ensemble2	12,4	13,2	64	40,1	15,4	54,6	9,0	101,8	93,8	27,9
Ensemble3	13,2	14,1	59	37,5	15,0	53,1	7,2	82,2	90,5	30,1
Prophet	18,8	20,0	66	41,7	17,8	63,2	5,0	56,9	97,0	32,3
LGBM	21,4	22,8	72	45,1	12,4	43,8	22,4	253,9	76,8	25,6

GRU	22,0	23,5	55	34,8	15,5	55,0	6,6	74,9	107,5	35,8
------------	------	------	----	------	------	------	-----	------	-------	------

Fonte: elaborado pelo autor (2025).

Tabela 3 – MAE e WAPE para a linha de tanques

Método	Nordeste		Sudeste		Norte		Centro-Oeste		Total	
	MAE (Un)	WAPE (%)	MAE (Un)	WAPE (%)	MAE (Un)	WAPE (%)	MAE (Un)	WAPE (%)	MAE (Un)	WAPE (%)
Ensemble2	1,7	35,7	1,7	74,8	1,2	50,5	3,5	61,3	3,4	26,8
Ensemble3	2,1	43,8	1,6	72,1	1,2	48,7	3,5	61,0	3,9	30,3
Prophet	2,2	45,8	1,7	76,3	1,4	56,7	3,8	66,0	3,6	28,4
LGBM	2,3	46,8	1,6	73,3	1,2	47,0	4,7	81,0	7,9	46,3
GRU	2,7	55,9	1,5	66,9	1,2	46,9	3,9	67,1	6,0	60,8

Fonte: elaborado pelo autor (2025).

A análise dos resultados mostra que o desempenho dos métodos variou conforme a região e a família de produtos. No Nordeste e Sudeste, que concentram cerca de 80% das vendas, os erros foram menores, indicando que as variáveis escolhidas explicam melhor o comportamento do mercado nessas regiões. Isso também pode estar ligado ao maior volume de dados disponíveis, o que colabora positivamente com a robustez das estimativas.

As regiões Norte e Centro-Oeste apresentaram um cenário distinto. Embora os erros absolutos (MAE) não tenham sido altos, os erros relativos (WAPE) foram elevados. Isso pode ser explicado pelo baixo volume de vendas, onde qualquer desvio se potencializa em termos percentuais, conforme apontado por Panarese et al. (2022).

Ao analisar os resultados consolidados do total de vendas, observa-se que os erros foram menores, tanto em termos de MAE quanto de WAPE, quando comparados aos valores regionais. Esse comportamento confirma a tendência destacada por Montgomery, Jennings e Kulachi (2016), segundo a qual previsões mais agregadas apresentam maior estabilidade e menor variabilidade dos erros, em virtude do efeito de compensação entre regiões.

Em relação ao modelo mais adequado por região, não se verificou a supremacia de um único método. O Ensemble2 foi o mais adequado no Nordeste, tanto para Carretas quanto para Tanques. No Sudeste, o GRU se destacou, o que corrobora com os achados de Honjo, Zhou e Shimizu (2022), confirmando sua capacidade de lidar com séries mais complexas e voláteis. No Norte, o melhor desempenho foi do LGBM, mostrando boa adaptação às variáveis disponíveis. Já no Centro-Oeste, os resultados foram mais variados: o Prophet teve melhor resultado em Carretas, enquanto o Ensemble3 foi superior em Tanques. Para a previsão

agregada, o modelo LGBM performou melhor na família de Carretas e o Ensemble2 para a família de Tanques. O Quadro 5 resume o modelo com melhor desempenho por família e região:

Quadro 5 – Modelo quantitativo utilizado

Região	Família	Modelo Escolhido	MAE (Un)	WAPE (%)
Nordeste	Carretas	Ensemble2	12,46	13,27
	Tanques	Ensemble2	1,76	35,74
Sudeste	Carretas	GRU	55	34,85
	Tanques	GRU	1,53	66,98
Norte	Carretas	LGBM	12,41	43,87
	Tanques	LGBM	1,18	46,99
Centro-Oeste	Carretas	Prophet	5,04	56,95
	Tanques	Ensemble3	3,58	61,08
Total	Carretas	LGBM	76,8	25,8%
	Tanques	Ensemble2	3,4	26,8
	Geral	Ensemble2	86,54	27,64%

Fonte: elaborado pelo autor (2025).

Entre as famílias de produtos, observou-se que os modelos seguiram padrões semelhantes, mas os Tanques apresentaram maior dificuldade de explicação pelas variáveis selecionadas. Apesar dos baixos valores de MAE, os WAPEs permaneceram elevados, como, por exemplo, na região Norte, o erro médio foi de apenas 1 unidade, mas representou 49,99% em termos relativos; no Sudeste, 1,66 unidade correspondeu a 72,71% de WAPE. Esses resultados sugerem que as variáveis causais identificadas pelos representantes capturam de forma mais eficaz o mercado de Carretas, enquanto o comportamento do mercado de Tanques se mostra menos previsível, possivelmente por sua menor escala ou até por um conhecimento mais limitado desse segmento por parte dos vendedores.

Ao relacionar esses achados com os estudos empíricos apresentados na seção 3.5, observa-se convergência com as conclusões de Borsato e Corso (2019) e Gomes et al. (2023), que destacam que o desempenho dos modelos varia conforme o contexto de aplicação. Assim como nesses trabalhos, não foi identificado um modelo universalmente superior em todas as situações; ao contrário, verificou-se que a redução ou aumento do erro dependeu das características específicas da série analisada. Em alguns recortes, modelos baseados em *machine learning* apresentaram menor erro; em outros, combinações ou ajustes mostraram desempenho mais consistente.

Esses resultados reforçam a estratégia metodológica adotada neste trabalho: selecionar dinamicamente o modelo mais adequado para cada região e família, sempre com base no menor erro observado. Como não houve um método universalmente superior em todos os contextos, o monitoramento contínuo torna-se indispensável para assegurar previsões confiáveis e possibilitar ajustes sempre que a precisão dos modelos apresente sinais de deterioração.

5.2.2 Resultado da previsão

A Tabela 4 traz o resultado da previsão quantitativa:

Tabela 4 – Resultado da previsão quantitativa

Ano/Mês	Nordeste		Sudeste		Norte		Centro-Oeste		Total
	Carretas	Tanques	Carretas	Tanques	Carretas	Tanques	Carretas	Tanques	
2025/08	99	4	92	2	27	3	7	7	240
2025/09	85	6	87	2	24	3	7	6	219
2025/10	83	5	84	2	21	2	7	5	210

Fonte: elaborado pelo autor (2025).

Os resultados da previsão para o trimestre indicaram uma redução gradual no volume total de vendas, passando de 240 unidades em agosto para 219 em setembro e 210 em outubro de 2025. O que está alinhado com a sazonalidade do período, normalmente nos últimos meses do ano, há uma queda nas vendas. Essa queda foi puxada principalmente pelas vendas de carretas nas regiões Nordeste e Sudeste, que, apesar da redução, permaneceram responsáveis por mais de 80% do total previsto. Já as regiões Norte e Centro-Oeste mantiveram participação marginal, com volumes absolutos reduzidos, o que reforça o peso estratégico das regiões mais representativas.

Observa-se que a venda de tanque para o Centro-Oeste não mostrou variação no trimestre. Essa estabilidade pode refletir o baixo volume histórico de vendas na região, mas também pode indicar uma limitação do modelo em capturar variações em mercados de menor escala.

Na etapa de julgamento por especialistas, o representante da região Norte e os responsáveis pelo estado do Mato Grosso e Mato Grosso do Sul, não enviaram suas contribuições em tempo hábil para a conclusão deste trabalho. Dessa forma, a Diretoria e a Gerência de Vendas, optaram por não alterar os valores projetados para o Norte, mantendo o

resultado da previsão quantitativa. Para o Centro-Oeste, foram considerados apenas os ajustes realizados pelo representante de Goiás, conforme consta no Quadro 6:

Quadro 6 – Ajustes da previsão na região Centro-Oeste

Ano/Mês	Previsto		Ajuste		Justificativa
	Carretas	Tanques	Carretas	Tanques	
2025/08	7	7	5	6	Geralmente a venda de taques acontece em pares, para facilitar carregamento.
2025/09	7	6	8	10	Expectativa de fechar uma venda grande para um cliente importante.
2025/10	7	5	7	5	Não houve ajuste.

Fonte: elaborado pelo autor (2025)

A análise dos ajustes qualitativos realizados para o Centro-Oeste evidencia como o julgamento dos especialistas complementou a previsão quantitativa. Em agosto de 2025, houve um ajuste na quantidade de Tanques, para um número par, já que, segundo o representante, essa é uma prática para facilitar o carregamento. Para setembro, foi pontuado que está em negociação uma venda expressiva, para um cliente importante. Já em outubro, não foram realizados ajustes, permanecendo os valores previstos inicialmente. Esses exemplos demonstram que o julgamento qualitativo permite incorporar informações de mercado não captadas pelas séries históricas, ajustando a previsão de acordo com a experiência dos representantes e fatores contextuais específicos, assim como defendido por Staudt, Gonçalves e Rodriguez (2015).

O resultado dos ajustes realizados no Sudeste está disposto no Quadro 7:

Quadro 7 – Ajustes da previsão na região Sudeste.

Ano/Mês	Previsto		Ajuste		Justificativa
	Carretas	Tanques	Carretas	Tanques	
2025/08	92	2	92	0	Não está tendo cotação de tanques.
2025/09	87	2	87	2	Não houve ajuste.
2025/10	84	2	100	2	Abertura de uma nova filial de um cliente importante, expectativa de venda alta. Os vendedores acharam elevada a quantidade de tanques.

Fonte: elaborado pelo autor (2025)

O ajuste realizado pelos vendedores que atuam na região sudeste resultou em poucas alterações. Assim como na região sudeste, os ajustes foram realizados por conta de informações de mercado. Como, por exemplo, a abertura de uma filial de um cliente importante em uma cidade onde o mercado é bem aquecido, irá resultar numa compra inicial para composição de estoque.

No Nordeste, a previsão depois do ajuste está disposta no Quadro 8:

Quadro 8 – Ajustes da previsão na região Nordeste.

Ano/Mês	Previsto		Ajuste		Justificativa
	Carretas	Tanques	Carretas	Tanques	
2025/08	99	4	99	2	O preço de venda dos tanques está acima da média.
2025/09	85	6	85	2	Espera-se chuva acima da média, tendência de poucos incêndios.
2025/10	83	5	83	5	Não houve ajuste.

Fonte: elaborado pelo autor (2025)

Observa-se que os ajustes qualitativos para o Nordeste refletiram condições conjunturais, como preço de venda elevado e expectativa de chuvas acima da média, fatores que impactaram a demanda por tanques.

O fato de não terem sido realizados ajustes qualitativos em outubro em duas das regiões analisadas sugere que a contribuição dos representantes é mais significativa quando se trata de informações recentes, obtidas no contato cotidiano com os clientes. Isso reforça a natureza do julgamento qualitativo como complemento à previsão quantitativa, uma vez que permite incorporar sinais de mercado de curto prazo, muitas vezes não captados pelas séries históricas. Essa conclusão corrobora com o estudo de Arvan *et al.* (2019), que defende o uso do julgamento humano e da ‘percepção prática’ agrega valor às previsões geradas pelos modelos quantitativos, tornando a experiência dos especialistas um componente essencial no processo de previsão de vendas.

Em resumo, a Tabela 5 traz o valor final da previsão, após a realização dos ajustes pelos especialistas:

Tabela 5 – Previsão final

Ano/Mês	Nordeste		Sudeste		Norte		Centro-Oeste		Total
	Carretas	Tanques	Carretas	Tanques	Carretas	Tanques	Carretas	Tanques	
2025/08	99	2	92	0	27	3	5	6	234
2025/09	85	4	87	2	24	3	8	10	223
2025/10	83	5	100	2	21	2	7	5	225

Fonte: elaborado pelo autor (2025)

Para o mês de agosto, os ajustes diminuíram o número total de produtos vendidos, já para os outros dois meses seguintes, os ajustes propiciaram um pequeno aumento na quantidade prevista pelo modelo quantitativo.

5.2.3 Construção da solução

A aplicação desenvolvida tem por objetivo operacionalizar, de forma padronizada e reproduzível, o processo-modelo proposto nesse trabalho. A interface, construída em *Python*, utilizando a biblioteca *Streamlit*, integra métodos escolhidos quantitativos escolhidos (Prophet, LGBM e GRU) e permite comparar, selecionar e disponibilizar automaticamente a melhor previsão por região, com base em um no desempenho de cada modelo na série de validação, conforme estabelecido anteriormente. A Figura 5 mostra a tela inicial da solução:

Figura 5 - Página inicial da solução

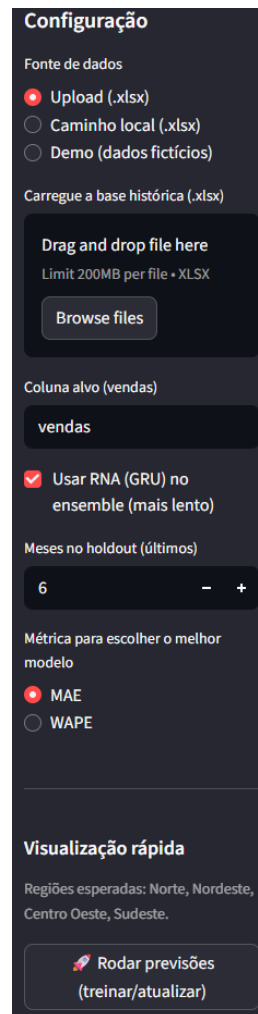


Fonte: elaborado pelo autor (2025)

A escolha de operar em ambiente web, via *Streamlit*, foi feita visando simplificar a execução e garantir a repetibilidade e a praticidade do processo. O fluxo foi desenhado para uso recorrente, com atualização mensal da base e cálculo das previsões, conforme definido pela Diretoria e Gerência comercial.

No que se refere às configurações, o usuário define a fonte dos dados (upload, caminho local ou conjunto de demonstração), a coluna-alvo de vendas e a utilização (ou não) da rede GRU no ensemble. O tamanho da série de validação (holdout) é configurável: o usuário pode escolher quantos meses o modelo deve utilizar para fazer a validação, refletindo a necessidade de avaliação comparável ao contexto mais recente. Posteriormente, o usuário escolhe a métrica de seleção do modelo quantitativo a ser utilizado entre MAE e WAPE. Os campos de configuração podem ser vistos na Figura 6:

Figura 6 – Parâmetros de configuração



The image shows a dark-themed configuration panel titled "Configuração". It contains several sections:

- Fonte de dados:** Three radio buttons are present: "Upload (.xlsx)" (selected), "Caminho local (.xlsx)", and "Demo (dados fictícios)".
- Carregue a base histórica (.xlsx):** A file upload area with the text "Drag and drop file here", "Limit 200MB per file • XLSX", and a "Browse files" button.
- Coluna alvo (vendas):** A dropdown menu showing "vendas".
- Usar RNA (GRU) no ensemble (mais lento):** A checked checkbox.
- Meses no holdout (últimos):** A numeric input field set to "6", with minus and plus icons for adjustment.
- Métrica para escolher o melhor modelo:** Two radio buttons: "MAE" (selected) and "WAPE".
- Visualização rápida:** Text indicating "Regiões esperadas: Norte, Nordeste, Centro Oeste, Sudeste." and a button labeled "Rodar previsões (treinar/atualizar)".

Fonte: elaborado pelo autor (2025)

O usuário fará o *upload* da base, previamente preparada, com as informações da variável a ser prevista (venda) e com as informações das variáveis causais validadas anteriormente. Conforme está exposto, o arquivo deve estar em .xlsx, extensão padrão do Microsoft Excel. Ao final da configuração e do carregamento do arquivo, o usuário clica no botão “Rodar previsões” e a previsão é feita.

A Figura 7 traz a visualização após a previsão:

Figura 7 – Resultados




Fonte: elaborado pelo autor (2025)

Após a previsão ser feita, duas tabelas ficam disponíveis para visualização. A primeira tabela da interface apresenta as previsões finais por região juntamente com a identificação do método utilizado. Adicionalmente, uma segunda tabela traz os resultados do período de validação por região (MAE e WAPE), permitindo verificar, de forma transparente, o desempenho obtido no período recente e, por consequência, a qualidade relativa das escolhas do sistema. Essa visualização foi pensada para que a acurácia do modelo seja acompanhada, conforme estabelecido no processo-modelo. Por fim, todo o resultado pode ser exportado em CSV, para que seja realizado a etapa de ajuste por especialistas.

De forma adicional, a solução ainda traz um gráfico com as informações da série histórica de venda e de uma variável causal, conforme apresentado na Figura 8:

Figura 8 – Gráfico de série histórica



Fonte: elaborado pelo autor (2025)

O usuário escolhe a região e qual variável deseja ser plotada. No mesmo gráfico, é exposto a série histórica de vendas (eixo primário) e as previsões do modelo selecionado, além de uma variável adicional escolhida pelo usuário (eixo secundário). Essa sobreposição facilita a leitura contextualizada das variações de vendas e sua possível relação com determinantes externos (ex.: inflação, crédito, preço de commodities), o que é particularmente útil para a etapa de discussão e para a incorporação de julgamento de especialistas no relatório.

5.2.4 Discussão dos resultados

No âmbito da realização deste trabalho, foi possível confrontar as previsões geradas com os resultados efetivamente observados em dois dos três meses projetados. A Tabela 6 apresenta os valores previstos e realizados para cada região e família de produto, com destaque para as diferenças absolutas e percentuais.

Tabela 6 – Previsto vs. Realizado

Região	Família	Agosto				Setembro			
		Previsto	Realizado	MAE	WAPE	Previsto	Realizado	MAE	WAPE
Nordeste	Carretas	99	96	3	3,13%	85	81	4	4,94%
	Tanques	2	5	3	60,00%	4	17	13	76,47%
Sudeste	Carretas	92	93	1	1,08%	87	127	40	31,50%
	Tanques	0	1	1	100,00%	2	1	1	100,00%
Norte	Carretas	27	14	13	92,86%	24	4	20	500,25%
	Tanques	3	0	3	-	3	2	1	50,00%
Centro-Oeste	Carretas	5	2	3	150,00%	8	7	1	14,29%
	Tanques	6	6	0	0,00%	10	0	10	-
Total	Carretas	223	205	18	8,78%	204	219	15	6,84%
	Tanques	11	12	1	8,33%	19	20	1	5,00%
	Geral	234	217	17	7,83%	223	239	16	6,69%

Fonte: elaborado pelo autor (2025)

A análise dos dados da Tabela 6 evidencia que os erros foram significativamente menores do que aqueles observados no período de validação. Os resultados do período de validação mostraram um WAPE médio de 27,64% e um MAE de 86,54 unidades, enquanto nos dois meses analisados o erro consolidado o WAPE geral foi de 6,69% e o MAE de 16 unidades. Esse resultado reforça a utilidade prática da solução proposta, demonstrando que a incorporação das variáveis causais e dos julgamentos qualitativos contribuiu para aproximar as estimativas do comportamento real do mercado.

Contudo, evidenciou-se uma limitação no uso da métrica WAPE: em situações nas quais o volume realizado é igual a zero, o cálculo torna-se inviável, uma vez que o denominador da fórmula se anula. Nesses casos, optou-se por reportar apenas o MAE, métrica que se mantém interpretável mesmo em mercados de baixa escala. Essa constatação reforça a importância de utilizar indicadores complementares de desempenho, sobretudo em contextos de vendas reduzidas ou intermitentes.

Ao analisar os resultados com base nas previsões por região, pode-se perceber que, assim como na validação, os erros médios foram menores nas regiões Nordeste e Sudeste. Já no Norte e no Centro-Oeste, embora os desvios em unidades tenham sido pequenos, os valores de WAPE se mostraram mais elevados, consequência do baixo volume de vendas nessas localidades. Essa disparidade sugere uma maior aderência da solução escolhida para os mercados onde a empresa estudada tem mais volume de venda, o que representa nos mercados que a previsão deve ser utilizada com mais cautela e acompanhada de julgamentos qualitativos mais robustos para as regiões Norte e Centro-Oeste.

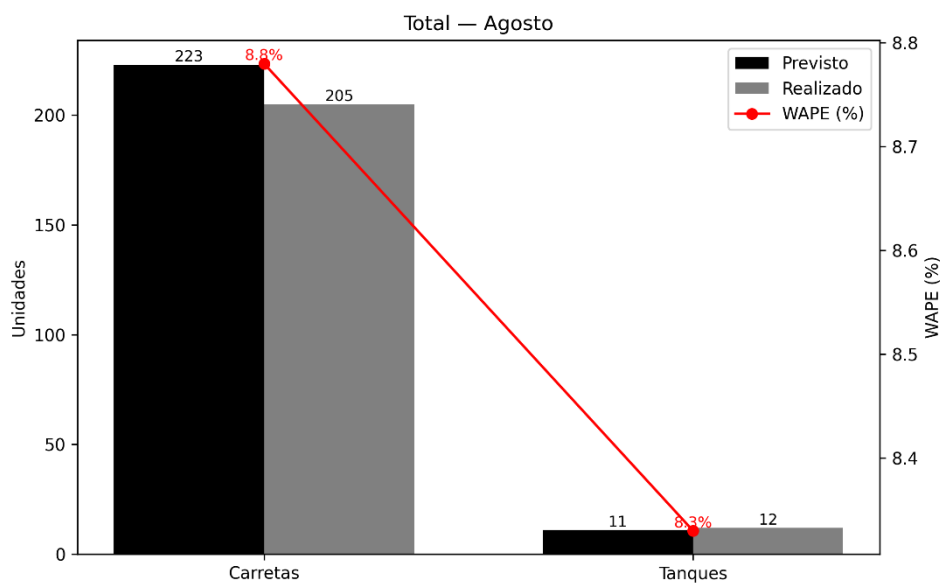
Ao analisar o resultado por família de produtos percebe-se que, para a linha de carretas, principal responsável pelo faturamento da empresa, as previsões apresentaram melhor desempenho, com erros sistematicamente inferiores aos da linha de tanques. Isso indica que as variáveis selecionadas capturam de forma mais eficaz os determinantes de demanda desse segmento. Já a linha de tanques apresentou maior instabilidade, com WAPE relativamente elevado, mesmo em casos de baixo MAE.

Essa discrepância observada entre as famílias de produto, reforça a discussão apresentada por Lv et al. (2024), que defendem a necessidade de adaptação metodológica às particularidades do setor agrícola. Enquanto a família de Carretas apresentou redução mais consistente do erro em regiões com maior maturidade de mercado, a de Tanques registrou maior instabilidade percentual, especialmente em cenários de baixo volume. Tal diferença sugere que

a previsibilidade está associada não apenas à técnica empregada, mas também ao grau de consolidação do mercado e à regularidade da demanda.

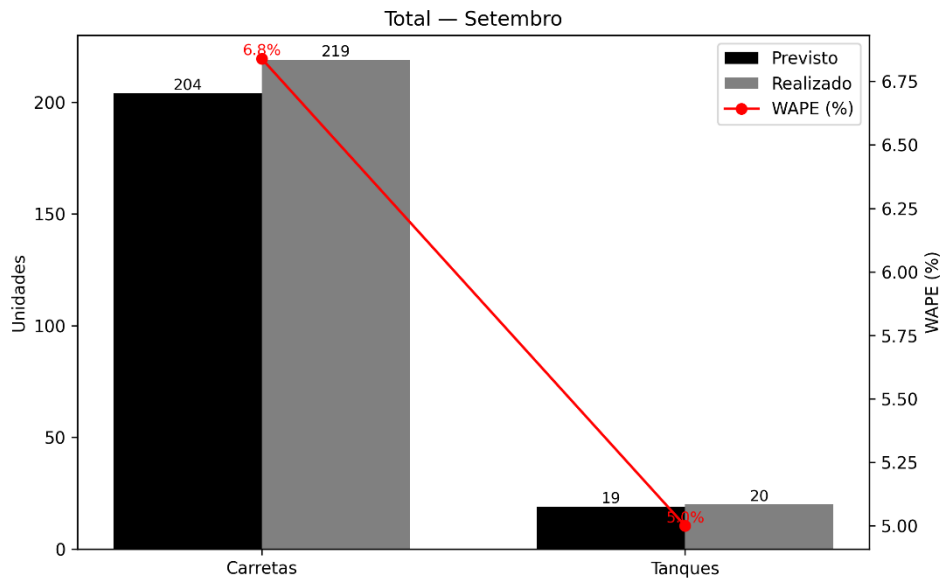
Os Gráficos 2 e 3 apresentam o desempenho consolidado das previsões para os meses de agosto e setembro, respectivamente. Os valores foram obtidos pela soma das previsões e das vendas realizadas das famílias Carretas e Tanques. O WAPE exibido corresponde ao erro percentual calculado a partir desses valores totais, permitindo avaliar a acurácia da solução em nível agregado.

Gráfico 2 - Total Previsto vs. Realizado em agosto



Fonte: elaborado pelo autor (2025).

Gráfico 3 - Total Previsto vs. Realizado em setembro



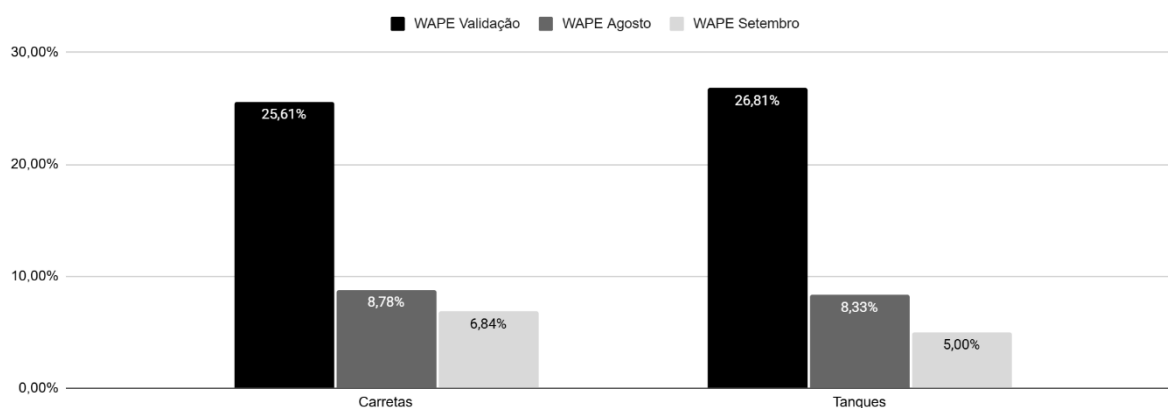
Fonte: elaborado pelo autor (2025).

Ao analisar os números totais, percebe-se o potencial da solução como ferramenta de planejamento global, permitindo antecipar necessidades de insumos, dimensionar a capacidade produtiva e projetar o fluxo de caixa com maior segurança. Além disso, a estabilidade observada nas previsões totais indica que a ferramenta pode ser utilizada como referência para o acompanhamento do desempenho da empresa, servindo como indicador complementar às previsões regionais e por família de produtos.

De modo semelhante ao apontado por Lemos e Fogliatto (2008), os resultados indicam que a integração estruturada entre modelagem quantitativa e avaliação sistemática contribui para redução relativa do erro quando comparada a abordagens menos estruturadas. Ainda que persistam variações regionais e familiares, observa-se melhora na consistência das previsões ao se adotar processo comparativo baseado em métricas objetivas e reavaliação periódica.

Observa-se, também, uma redução das métricas de erro nos meses de agosto e setembro de 2025, quando comparado com o período de validação (janeiro a julho de 2025), conforme Gráfico 4.

Gráfico 4 - Comparação do WAPE



Fonte: elaborado pelo autor (2025).

Tal redução pode ser explicada por características sazonais e estruturais do mercado de implementos agrícolas. Tradicionalmente, o primeiro semestre apresenta maior variabilidade nas vendas, influenciada por fatores externos como o lançamento do Plano Safra, a liberação de crédito rural, a realização de feiras agroindustriais. Esses elementos introduzem componentes aleatórios nas séries históricas, elevando os erros de previsão. No segundo semestre, essas interferências tendem a diminuir, tornando o comportamento da demanda mais estável e, conseqüentemente, mais previsível pelos modelos aplicados.

Os resultados também se alinham às conclusões de Lv *et al.* (2024), que defendem que técnicas desenvolvidas sob medida para a indústria inserida na cadeia de suprimentos do agronegócio tendem a apresentar desempenho superior às soluções padronizadas de mercado. A solução proposta nesta dissertação foi construída considerando as particularidades do setor de implementos agrícolas, incorporando segmentação regional, variáveis causais específicas e seleção dinâmica de modelos conforme desempenho observado. Assim, os achados desta pesquisa corroboram a evidência de que a adaptação metodológica ao contexto setorial constitui fator determinante para melhoria da acurácia preditiva.

Deve-se ressaltar que a solução proposta demonstrou maior assertividade justamente nas regiões e na família de produtos com maior representatividade no total de vendas da empresa estudada. O bom desempenho observado no Nordeste e no Sudeste, responsáveis por mais de 80% do faturamento, bem como na linha de carretas, que concentra a maior parte da produção, reforça a utilidade prática da ferramenta. Em síntese, os resultados confirmam que a solução proposta não apenas supera o método empírico anteriormente utilizado pela empresa,

mas também se mostra aplicável aos segmentos mais estratégicos do negócio, ainda que apresente limitações em mercados de menor escala.

5.2.5 Impactos observados

Após realizar a implantação do processo proposto e obter as primeiras previsões, promoveu-se uma reunião com os mesmos gestores que foram entrevistados no início do estudo com o objetivo de identificar os impactos obtidos.

Para a coordenadora de suprimentos, a previsão retirou a subjetividade dos processos de planejamento de compras. Como exposto na seção 2.2, o processo anterior funcionava em períodos de alta demanda, mas se mostrava ineficaz em momentos de retração, onde a carteira de vendas não era suficiente para estruturar uma programação de compras, como é o caso do segundo semestre. Com a previsão de demanda, foi possível planejar as compras para os períodos de baixa com base em dados quantitativos e não mais em estimativas subjetivas. A gestora ressaltou que agora consegue focar apenas nos itens efetivamente previstos, direcionando os recursos para o que será realmente necessário, parando de comprar itens que não estão presentes na previsão. De maneira específica, foi citada a possibilidade de passar a programar compras de longo prazo, especialmente para o final do ano, quando muitos fornecedores entram em férias coletivas, como é o caso do momento em que esse estudo está sendo aplicado. Segundo ela, as previsões já em execução para esse período permitirão negociar com antecedência e garantir o abastecimento de materiais mesmo durante as paralisações, algo que antes era feito com base em estimativas pouco confiáveis.

Para a gerente de vendas, a implantação da solução de previsão de demanda propiciou um avanço significativo nas estratégias comerciais da empresa. Ainda segundo a gestora, antes da utilização da previsão, não existia um critério estruturado para o estabelecimento de metas. A partir dos resultados gerados pelo modelo, tornou-se possível definir estabelecimento de metas por região e por representante comercial, com base no potencial de venda apontado pela previsão. Essa mudança possibilitou uma gestão mais orientada por dados e contribuiu para a identificação de discrepâncias de desempenho entre os vendedores. Além disso, a ferramenta possibilitou analisar o comportamento das vendas por linha de produto, permitindo o desenvolvimento de estratégias comerciais direcionadas para cada família e região.

Segundo o gerente de produção, as primeiras previsões feitas pela solução foram utilizadas para uma readequação do quadro de pessoal, necessária devido a flutuações no nível

de produção. O gestor relatou que a previsão trouxe maior clareza ao planejamento mensal de fabricação, que antes dependia fortemente das informações do setor comercial e da carteira de pedidos. Outro ponto levantado diz respeito à preparação da produção para os momentos de pico de vendas, tornando possível a fabricação de produtos para estoque nos períodos que antecedem janelas importantes de vendas, minimizando o gasto com horas extras nesse período. Adicionalmente, o gestor ressaltou que o processo de previsão promoveu maior integração entre os setores de suprimentos, comercial e produção, elevando a eficiência operacional e fortalecendo o fluxo de informações entre as áreas.

Por fim, o Diretor pontuou que a solução trouxe melhorias significativas para a empresa como um todo, na prática foi possível identificar a necessidade de aumentar a atuação e fortalecer a inteligência comercial nas regiões Norte e Centro-Oeste, já que, conforme apresentado, o erro dos resultados das previsões nessas regiões foi mais alto do que nas demais. No que diz respeito aos eventos em que a empresa participa como expositora, os resultados apresentados foram utilizados como base para o planejamento de 2026, de onde se retirou aqueles eventos que não fomentaram as vendas. A previsão de vendas também foi utilizada no planejamento financeiro, sendo utilizada para a realização de simulações de relatórios contábeis, como o Demonstrativo de Resultado do Exercício (DRE).

De modo geral, os relatos dos gestores evidenciam que a aplicação prática do processo e da solução desenvolvida resultou em ganhos perceptíveis para as diversas áreas da empresa, reduzindo a subjetividade nas decisões, aprimorando o uso dos recursos e fortalecendo a comunicação entre departamentos. Ainda assim, alguns pontos de melhoria foram destacados durante as reuniões. A gerente comercial pontuou que, durante a fase de julgamento por especialistas, alguns representantes apresentaram dificuldade em avaliar criticamente os resultados da previsão, especialmente aqueles que atuam em mais de uma região geográfica. Há casos, por exemplo, de representantes que cobrem simultaneamente estados de diferentes regiões, como Mato Grosso e Rondônia, ou Maranhão e Tocantins. Diante disso, foi sugerido que as previsões futuras sejam geradas com base em regiões comerciais a serem definidas pela empresa, de modo a alinhar o modelo de previsão à estrutura real de atuação dos vendedores e facilitar a participação dos especialistas no processo de julgamento.

6 CONCLUSÕES

Este trabalho teve como objetivo geral desenvolver uma solução de previsão de demanda para uma indústria de implementos agrícolas, considerando as especificidades desse segmento, caracterizado por elevada complexidade de mercado e forte influência de fatores sazonais e externos. Dessa forma, o estudo buscou suprir uma lacuna existente na literatura, visto que há poucos trabalhos voltados ao contexto de empresas fabricantes de implementos agrícolas, e trazer melhorias para a gestão da empresa, que contava com um processo de previsão de demanda empírico e pouco estruturado.

O primeiro objetivo específico foi atingido durante o Capítulo 4, onde foi estruturado o plano de ação, detalhando as etapas do modelo proposto, suas saídas e os impactos esperados. Nessa fase, foi proposto um processo-modelo de previsão de demanda, com base em processos clássicos existentes na literatura. Partindo do processo proposto por Montgomery, Jennings e Kulachi (2016), inseriu-se outras etapas para que houvesse maior aderência à realidade da empresa estudada, além de combinar a precisão de métodos quantitativos com a experiência dos profissionais que atuam no dia a dia do mercado de implementos agrícolas.

Para o atingimento do segundo objetivo específico, identificar os elementos mais relevantes para a construção do modelo de previsão, considerando abordagens qualitativas e quantitativas, foram realizadas entrevistas semiestruturadas com a equipe, onde foram selecionadas variáveis causais externas (como taxa Selic, IPCA, crédito rural e precipitação) e internas (eventos, sazonalidade, prazo de entrega e preço de venda) que influenciam diretamente a demanda dos produtos. Após essa etapa, procedeu-se à escolha dos métodos quantitativos e qualitativos a serem utilizados na pesquisa, fundamentada em uma pesquisa documental conduzida em artigos acadêmicos, que serviu de base teórica para a definição dos modelos mais adequados ao contexto estudado.

Para o atingimento do terceiro objetivo específico, foi desenvolvida uma solução, implementada em linguagem Python e integrada a uma interface Streamlit, onde são feitas as etapas de previsão e monitoramento de performance, tornando o processo acessível e padronizado para uso pelos gestores da empresa. A previsão quantitativa é feita com base em uma abordagem comparativa entre algoritmos de IA, LightGBM e GRU, e um método de séries temporais, o Prophet. Além desses métodos já existentes, foram desenvolvidas duas combinações do tipo ensemble, denominadas Ensemble2 e Ensemble3, que ponderaram as previsões individuais com base no erro médio absoluto (MAE) de cada modelo. As séries

históricas foram tratadas e divididas em conjuntos de treino e validação, e a escolha do modelo final considerou o menor erro percentual (WAPE) em cada família e região.

Ao aplicar a solução proposta e realizar a previsão de vendas para as famílias de carretas e tanques para os meses de agosto, setembro e outubro de 2025, o quarto objetivo específico foi atingido. No âmbito deste trabalho, foi possível comparar os erros de previsão de dois dos três meses previstos, uma vez que os resultados reais de outubro ainda não estavam disponíveis. Para agosto e setembro, o WAPE médio geral foi de 6,69% e o MAE de 16 unidades, demonstrando erros significativamente menores quando comparado ao período de validação do modelo, que foi entre janeiro e julho de 2025. Ao aferir os impactos observados, através de uma reunião com os gestores da empresa, observou-se melhorias práticas nos processos de gestão da empresa: o setor de suprimentos fez programação de compras junto aos fornecedores com base na previsão, direcionando apenas para o que está previsto vender no período; a produção pôde nivelar o quadro de pessoal e antecipar a fabricação em períodos de pico; e o setor comercial passou a definir metas regionais com base em previsões realizadas.

A partir da aplicação prática e da análise dos resultados, constatou-se que o objetivo geral foi alcançado, uma vez que a solução desenvolvida considerou as especificidades da empresa estudada e do mercado em que está inserida. O desempenho observado demonstrou aderência satisfatória às séries analisadas e já proporcionou aplicações gerenciais concretas. A ferramenta implementada reduziu a dependência de julgamentos empíricos isolados, conferindo maior previsibilidade ao planejamento comercial, operacional e financeiro.

Sob o ponto de vista acadêmico, o estudo contribui ao desenvolver e aplicar um processo estruturado de previsão de demanda que combina métodos quantitativos e avaliação sistematizada em um contexto industrial inserido na cadeia de suprimentos do agronegócio brasileiro. Ao validar empiricamente a solução proposta, o trabalho oferece evidências de aplicabilidade em ambiente real, podendo servir de referência para outras organizações que busquem aprimorar seus processos de previsão, elevar a eficiência operacional e fortalecer sua atuação em um segmento de elevada relevância econômica.

Os achados evidenciam que a principal contribuição desta pesquisa reside na construção de uma abordagem híbrida estruturada e adaptada ao contexto da indústria de implementos agrícolas. Diferentemente da aplicação isolada de um único modelo preditivo, a solução integrou múltiplos algoritmos, validação temporal e seleção orientada por métricas objetivas de desempenho, permitindo que o método mais adequado variasse conforme a região

e a família analisada. Tal evidência reforça o argumento de que não há técnica universalmente superior, conforme apontado por Borsato e Corso (2019) e Gomes *et al.* (2023), sendo o desempenho condicionado às características específicas da série e do ambiente de aplicação.

Reconhece-se como limitações deste estudo a ausência de algumas variáveis internas relevantes, como dados estruturados sobre políticas de preço, condições de pagamento e campanhas promocionais, que não estavam integralmente disponíveis nos registros fornecidos pela empresa. Além disso, a solução apresentou menor poder explicativo nas regiões de menor atuação comercial, onde o volume de vendas reduzido limita a capacidade dos métodos quantitativos de identificar padrões consistentes de demanda, e onde o conhecimento tácito da equipe comercial ainda não está plenamente consolidado.

Como recomendações para estudos futuros, sugere-se inicialmente a ampliação da base de dados com a incorporação sistemática de variáveis internas estratégicas, especialmente aquelas relacionadas à política comercial e incentivos de venda, bem como maior detalhamento temporal dessas informações. Adicionalmente, investigações futuras podem aprofundar o nível de desagregação espacial da previsão, realizando estimativas por unidade federativa ou microrregião, o que permitiria capturar com maior precisão as especificidades locais da demanda.

Recomenda-se também a implementação de processos automatizados de coleta e atualização de dados por meio de integração com APIs públicas (como Banco Central, IBGE e CEPEA), reduzindo a dependência de inserções manuais e aumentando a escalabilidade da solução. Por fim, sugere-se a aplicação da metodologia proposta em outros contextos mercadológicos, especialmente em setores com diferentes níveis de volatilidade e sazonalidade, permitindo testar sua robustez e adaptabilidade. A replicação do modelo em ambientes distintos pode contribuir para consolidar evidências sobre a eficácia de abordagens híbridas contextualizadas no processo de previsão de demanda.

REFERÊNCIAS

- ACKERMANN, A. E. F.; SELBITTO, M. A. Métodos de previsão de demanda: uma revisão da literatura. **Innovar**, v. 32, n. 85, p. 83-99, 2021.
- AKTEPE, A.; YANIK, E.; ERSÖZ, S. Demand forecasting application with regression and artificial intelligence methods in a construction machinery company. **Journal of Intelligent Manufacturing**, v. 32, p. 1587–1604, 2021.
- ALVES, C. C.; HOEPERS, E.; CORAZZA, E. J.; SANTOS, G. J.; CRISTOFOLINI, R.; CRUZ, A. C. Aplicação de métodos estatísticos com suavização exponencial dupla e tripla para previsão de demanda na gestão de estoques. **Revista Produção Online**. Florianópolis, SC, v. 19, n. 3, p. 1001-1026, 2019.
- ARMSTRONG, J. S.; GREEN, K. C. Demand Forecasting: Evidence-Based Methods. **SSRN Electronic Journal**, 2005. DOI: 10.2139/ssrn.3063308. Disponível em: <https://ssrn.com/abstract=3063308>. Acesso em: 08 set. 2025.
- ARVAN, M; FAHIMNIA, B; REISI, M; SIEMSEN, E. Integrating human judgement into quantitative forecasting methods: A review. **Omega**, v. 86, p. 237–252, 2019.
- ASSAD, E D.; ASSAD, M. L. R. C. L. Mudanças do clima e agropecuária: impactos, mitigação e adaptação — desafios e oportunidades. **Estudos Avançados**, São Paulo, v. 38, n. 112, p. 271-292, 2024. DOI: 10.1590/s0103-4014.202438112.015.
- ATWANI, M; HLYAL, M; ALAMI, J. E. AI-Based Demand Forecasting Models: A Systematic Literature Review. **International Journal of Industrial Engineering & Production Research**, v. 35, n. 2, p.1-20, 2024.
- BATISTA, A.; LOPES, A. C. V.; COSTA, J. R. M. Gestão de custos na produção agrícola: um estudo na cultura da soja. In: XIX Congresso Brasileiro de Custos. 2022. **Anais...** João Pessoa: ABC, 2022.
- BARROS, Geraldo. Agronegócio e o dólar. **Centro de Estudos Avançados em Economia Aplicada – CEPEA/Esalq/USP**, 27 nov. 2019. Disponível em: <<https://www.cepea.org.br/br/opinio-cepea/agronegocio-e-o-dolar.aspx>>. Acesso em: 15 set. 2025.
- BORSATO, R.; CORSO, L. L. Aplicação de Inteligência Artificial e ARIMA na Previsão de Demanda no setor metal mecânico. **Scientia cum industria**, v. 7, n. 2, p. 165-176. 2019.
- CALOBA, G. M.; CALOBA, L. P; SALIBY. E. Cooperação entre redes neurais artificiais e técnicas “clássicas” para previsão de demanda de uma série de vendas de cerveja na Austrália. **Pesquisa Operacional**, v.22, n.3, p.345-358, 2002.
- CEPEA - Centro de Pesquisa Avançada em Economia Aplicada. **PIB-Agro/CEPEA: Após dois trimestres em queda, PIB do agro reage no 3º tri, e recuo esperado para 2024 diminui para 2,49%**. Disponível em: <<https://www.cepea.esalq.usp.br/br/releases/pib-agro->

cepea-apos-dois-trimestres-em-queda-pib-do-agro-reage-no-3-tri-e-recuo-esperado-para-2024-diminui-para-2-49.aspx#:~:text=Pesquisadores%20do%20Cepea%20indicam%20que,agricultura%20%22dentro%20da%20porteira%22.>. Acesso em: 04 mar. 2025.

CHAN, F; PAUWELS, L. Optimal Forecast Combination with Mean Absolute Error Loss. *CAMA Working Paper* 59/2023, Australian National University, Novembro 2023. Disponível em: <https://crawford.anu.edu.au/sites/default/files/2025-01/59_2023_chan_pauwels_0.pdf> Acesso em: 05 set. 2025.

FARAGO, F. E; OLIVEIRA, D. M; KAPP JUNIOR, C; VOICHCOSKI, G. M. Custos de Produção de Sete Culturas Brasileiras e a Taxa Selic. *Revista ADMPG*, v. 9, n. 1, 2016.

GOMES, G.; RODRIGUES, A. L. V; BOUZON, M.; STAUDT, F. H. Aplicação de Machine learning e séries temporais para previsão de demanda: um estudo de caso em uma empresa de bens de consumo. *Brazilian Journal of Development*. Curitiba, v.9, n.8, p. 23110-23132, 2023.

GUTH, S. C.; SALVADOR, A. B. Características da formação do preço de venda no segmento comercial de implementos agrícolas. *Estudos do CEPE*, n. 45, p. 18-34, 2017.

HONJO, K.; ZHOU, X.; SHIMIZU, S. CNN-GRU based deep learning model for demand forecast in retail industry. In: **International Joint Conference on Neural Networks (IJCNN)**, 2022. Proceedings [...]. IEEE, 2022.

KE, G. et al. LightGBM: A Highly Efficient Gradient Boosting Decision Tree. In: **Advances in Neural Information Processing Systems (NeurIPS)**, 2017. Disponível em: <https://papers.nips.cc/paper/2017/file/6449f44a102fde848669bdd9eb6b76fa-Paper.pdf>. Acesso em: 5 set. 2025.

KUMAR, L.; KHEDLEKAR, S.; KHEDLEKAR, U. K. A comparative assessment of holt winter exponential smoothing and autoregressive integrated moving average for inventory optimization in supply chains. *Supply Chain Analytics*, v. 8, n. 100084, p. 100084, 2024.

LIMA, V. A.; SANTOS, I. C.; AMATO NETO, J. A indústria de máquinas agrícolas no Brasil: uma análise evolucionária no período de 1985-2015. In: XVII Congresso Latino-Iberoamericano de Gestión Tecnológica. *Anais...* Ciudad de México: ALTEC, 2017.

LUKOSEVICIUS, A. P. Executar é preciso, planejar não é preciso: proposta de framework para projetos de pesquisa. *Administração Ensino e Pesquisa*, v. 19, n. 1, p. 32–65, 2018.

LV, F; LIU, F.; ZHANG, S; ZHANG Y. Agricultural equipment demand forecast based on data decomposition and integration. *International journal of innovative computing, information & control*, v. 20, n. 03, p. 739, 2024.

MONTGOMERY, D. C.; JENNINGS, C. L.; KULAHCI, M. Introduction to time series analysis and forecasting. 2nd ed. Hoboken: John Wiley & Sons, 2016.

MOROFF, N. U.; KURT, E.; KAMPHUES, J. Machine Learning and Statistics: A Study for assessing innovative Demand Forecasting Models. **Procedia computer science**, v. 180, p. 40–49, 2021.

PANARESE, A.; SETTANNI, G.; VITTI, V.; GALIANO, A. Developing and preliminary testing of a machine learning-based platform for sales forecasting using a gradient boosting approach. **Applied Sciences**, v. 12, n. 21, p. 11054, 2022. DOI: <https://doi.org/10.3390/app122111054>

PAVLYSHENKO, B. M. Machine learning models for sales times series forecasting. **Data**, v. 4, n. 15, 2019.

PELLEGRINI, F. R; FOGLIATTO, F. S. Passos para implantação de sistemas de previsão de demanda - Técnicas de Estudo de Caso. **Revista Produção**, v. 11, n. 1, p. 43-64, 2001.

PETROPOULOS, F; KOUTENTEZES, N; NIKOLOPOULOS, K; SIEMSEN, E. Judgmental selection of forecasting models. **Journal of operations management**, v. 60, n. 1, p. 34–46, 2018.

PINATTI, E. Efeitos das cotações do dólar comercial e do índice pluviométrico sobre os preços do boi gordo no estado de são paulo, no período após o plano real. **Rev. de Economia Agrícola**. São Paulo, v. 55, n. 1, p. 77-88, 2008.

PRODANOV, C. C.; FREITAS, E. C. **Metodologia do trabalho científico: métodos e técnicas da pesquisa e do trabalho acadêmico**. 2a ed. Novo Hamburgo: Universidade FEEVALE, 2013.

SIEBERT, J.; GROSS, J.; SCHROTH, C. A systematic review of Python packages for time series analysis. **arXiv preprint** arXiv:2104.07406, 2021. Disponível em: <https://arxiv.org/pdf/2104.07406>. Acesso em: 15 set. 2025.

STAUDT, F. H.; GONÇALVES, M. B.; RODRIGUEZ, C. M. T. Procedimento para implantar um modelo de previsão de demanda com incorporação de julgamento de especialistas. **Production**, v. 26, n. 2, p. 459–475, 2015.

TAYLOR, S. J.; LETHAM, B. Forecasting at scale. **PeerJ Preprints**, v. 6, p. e3190v2, 2018. Disponível em: <https://peerj.com/preprints/3190.pdf>. Acesso em: 8 set. 2025.

VERÍSSIMO, A. J.; ALVES, C. C.; HENNING, E.; AMARAL, C. E.; CRUZ, A.C. Métodos estatísticos de suavização exponencial holt-winters para previsão de demanda em uma empresa do setor mecânico. **Revista Gestão Industrial**. Ponta Grossa, v. 8, n. 4, 2016

APÊNDICE A – ROTEIRO DA ENTREVISTA SEMIESTRUTURADA (DIAGNÓSTICO DA SITUAÇÃO)

1. Objetivo da entrevista:

Compreender o funcionamento da empresa e o contexto atual dos processos que dependem da previsão de demanda, identificando como as áreas comercial, de produção e de suprimentos realizam o planejamento de suas atividades e quais limitações enfrentam.

2. Perguntas:

Bloco 1 – Caracterização da empresa e do mercado

1. Como a empresa está estruturada em termos de setores e responsabilidades?
2. Como se caracteriza o mercado em que a empresa atua?
3. Quais são os principais produtos fabricados e comercializados?
5. Como ocorre o planejamento interno entre as áreas comercial, de produção e de suprimentos?
6. De que forma as informações sobre vendas, pedidos e estoque são compartilhadas entre os setores?

Bloco 2 – Processo atual de previsão de demanda

9. Como é realizado atualmente o processo de previsão de demanda na empresa?
10. Como as informações de previsão são utilizadas pelas áreas de produção, comercial e suprimentos?
11. Quais são as principais limitações do processo atual?

APÊNDICE B – ROTEIRO DA ENTREVISTA SEMIESTRUTURADA (ETAPA DE DEFINIÇÃO DE PROBLEMA)

1. Objetivo da entrevista:

Levantar informações junto à diretoria e à gestão comercial, a fim de realizar etapa de definição de problema do processo-modelo proposto. As perguntas foram baseadas no trabalho de Montgomery, Jennings e Kulachi (2016).

2. Perguntas:

- 1) Qual é o principal propósito da previsão de demanda para a empresa?
- 2) Com que horizonte de tempo as previsões precisam ser geradas (ex.: mensal, trimestral, anual)?
- 3) Com que frequência as previsões devem ser atualizadas para atender às necessidades de cada área?
- 4) Qual o nível de detalhamento desejado para a previsão (por modelo, família de produto, região geográfica ou total consolidado)?

APÊNDICE C – ESTRUTURA DA BASE DE DADOS (AMOSTRA ILUSTRATIVA)

ano_mes	REGIAO	vendas	PV	prazo	EVENTO	TX SELIC	DÓLAR	precipitação	ipca	Crédito Rural	Sazona	Preço_Cafe	Ciclo café
2019/01	Centro-Oeste	25	11.932,14	16,14	0	6,4	5,06	11650,4	0,32	1,19	0	411,0171	0
2019/01	Nordeste	42	12.614,67	42,03	0	6,4	5,06	6354	0,32	0,31	0	411,0171	0
2019/01	Norte	16	10.046,67	59,22	0	6,4	5,06	15936,6	0,32	0,32	0	411,0171	0
2019/01	Sudeste	63	11.309,09	31,91	0	6,4	5,06	12545,4	0,32	1,57	0	411,0171	0
2019/02	Centro-Oeste	11	10.180,00	65,5	0	6,4	5,09	14425,8	0,43	1,63	0	407,6995	0
2019/02	Nordeste	58	10.553,34	22,15	0	6,4	5,09	10084,6	0,43	0,41	0	407,6995	0
2019/02	Norte	18	10.950,23	16,85	0	6,4	5,09	15259	0,43	0,31	0	407,6995	0
2019/02	Sudeste	66	10.437,88	16,15	0	6,4	5,09	26522	0,43	1,9	1	407,6995	0
2019/03	Centro-Oeste	9	9.857,14	8,29	1	6,4	5,07	15318,4	0,75	2,2	0	395,6084	0
2019/03	Nordeste	42	11.804,78	8,91	0	6,4	5,07	17983,2	0,75	0,55	0	395,6084	0
2019/03	Norte	10	13.080,50	10	0	6,4	5,07	20575,2	0,75	0,37	1	395,6084	0
2019/03	Sudeste	50	11.048,15	10,15	0	6,4	5,07	22611,4	0,75	1,61	1	395,6084	0
2019/04	Centro-Oeste	10	11.800,00	10,71	0	6,4	4,6	10062,4	0,57	3,1	0	384,3529	0
2019/04	Nordeste	47	11.522,17	50,23	0	6,4	4,6	14196,2	0,57	0,73	0	384,3529	0
2019/04	Norte	8	10.614,29	11,57	0	6,4	4,6	17722,4	0,57	0,54	1	384,3529	0
2019/04	Sudeste	124	9.705,93	18,03	0	6,4	4,6	13886,6	0,57	1,9	1	384,3529	0
2019/05	Centro-Oeste	23	10.276,67	20,27	1	6,4	4,56	3935,4	0,13	3,36	0	389,0368	0
2019/05	Nordeste	38	14.341,56	39,38	1	6,4	4,56	6992,6	0,13	1,06	0	389,0368	0
2019/05	Norte	27	10.131,82	31,36	1	6,4	4,56	12581,8	0,13	0,56	1	389,0368	0
2019/05	Sudeste	74	9.644,97	24,36	1	6,4	4,56	10393,4	0,13	2,55	0	389,0368	0

ano_mes	REGIAO	vendas	PV	prazo	EVENTO	TX SELIC	DÓLAR	precipitação	ipca	Crédito Rural	Sazona	Preço_Cafe	Ciclo café
2019/06	Centro-Oeste	9	9.285,71	8,57	0	6,4	4,91	560,8	0,01	3,17	0	411,9363	0
2019/06	Nordeste	43	11.837,07	13,52	0	6,4	4,91	7301,2	0,01	1,17	1	411,9363	0
2019/06	Norte	6	11.350,00	14,5	0	6,4	4,91	5505,8	0,01	0,77	0	411,9363	0
2019/06	Sudeste	17	9.903,85	26,23	0	6,4	4,91	3146,2	0,01	2,75	0	411,9363	0
2019/07	Centro-Oeste	5	8.687,50	16	0	6,4	3,87	663,6	0,19	2,39	0	423,6678	0
2019/07	Nordeste	128	12.306,31	10,87	0	6,4	3,87	6721,8	0,19	0,91	1	423,6678	0
2019/07	Norte	10	12.000,00	10,17	0	6,4	3,87	4220,2	0,19	0,54	0	423,6678	0
2019/07	Sudeste	68	9.655,77	30,42	0	6,4	3,87	3141,4	0,19	2,56	0	423,6678	0
2019/08	Centro-Oeste	22	10.262,50	12,88	0	5,9	5,39	420,6	0,11	3,05	1	408,7432	0
2019/08	Nordeste	114	12.849,40	8,87	0	5,9	5,39	4376	0,11	1,01	1	408,7432	0
2019/08	Norte	19	10.967,65	21,88	0	5,9	5,39	2744,6	0,11	0,78	0	408,7432	0
2019/08	Sudeste	26	10.906,96	28,29	0	5,9	5,39	3788,8	0,11	3,3	0	408,7432	0
2019/09	Centro-Oeste	14	11.842,50	9	0	5,9	5,25	2255,2	-0,04	3	1	430,6295	0
2019/09	Nordeste	58	12.175,56	14,67	0	5,9	5,25	2481	-0,04	0,92	0	430,6295	0
2019/09	Norte	12	11.450,00	26,5	0	5,9	5,25	3798,6	-0,04	0,67	1	430,6295	0
2019/09	Sudeste	40	9.867,50	15,9	0	5,9	5,25	7857,6	-0,04	3,89	0	430,6295	0
2019/10	Centro-Oeste	31	10.420,21	19,07	0	5,4	4,92	6486	0,1	3,1	1	421,5857	0
2019/10	Nordeste	72	11.053,46	12,05	0	5,4	4,92	3327,2	0,1	1,18	0	421,5857	0
2019/10	Norte	39	12.229,00	15,08	0	5,4	4,92	7797,6	0,1	0,82	1	421,5857	0
2019/10	Sudeste	51	11.941,54	25,81	0	5,4	4,92	8592,6	0,1	3,4	0	421,5857	0
2019/11	Centro-Oeste	14	12.295,00	14,8	0	4,9	4,45	10058	0,51	2,37	0	475,113	0
2019/11	Nordeste	37	12.007,83	15	0	4,9	4,45	2976,4	0,51	0,9	0	475,113	0
2019/11	Norte	13	11.292,86	21,29	0	4,9	4,45	10456,6	0,51	0,74	0	475,113	0

ano_mes	REGIAO	vendas	PV	prazo	EVENTO	TX SELIC	DÓLAR	precipitação	ipca	Crédito Rural	Sazona	Preço_Cafe	Ciclo café
2019/11	Sudeste	59	9.950,58	16	0	4,9	4,45	23134,4	0,51	3	1	475,113	0
2019/12	Centro-Oeste	7	9.650,00	40,71	0	4,9	3,41	15535,8	1,15	2,65	0	545,1705	0
2019/12	Nordeste	39	11.863,79	11,86	0	4,9	3,41	3746,8	1,15	0,87	0	545,1705	0
2019/12	Norte	7	11.010,00	6,4	0	4,9	3,41	13694,2	1,15	0,84	0	545,1705	0
2019/12	Sudeste	88	10.498,36	45,55	0	4,9	3,41	24701,2	1,15	2,85	0	545,1705	0
2020/01	Centro-Oeste	8	12.014,29	11,29	0	4,4	5,32	16337,8	0,21	1,4	0	493,0327	1
2020/01	Nordeste	48	11.213,98	18,32	0	4,4	5,32	13226,2	0,21	0,48	0	493,0327	1
2020/01	Norte	20	12.645,00	10,4	0	4,4	5,32	17322,4	0,21	0,44	1	493,0327	1
2020/01	Sudeste	83	10.704,61	17,09	0	4,4	5,32	35112,8	0,21	1,86	0	493,0327	1
2020/02	Centro-Oeste	27	9.879,26	11,78	0	4,4	5,1	17228	0,25	1,87	0	481,905	1
2020/02	Nordeste	43	11.222,09	76,74	0	4,4	5,1	10003,2	0,25	0,51	0	481,905	1
2020/02	Norte	9	11.677,78	12,56	0	4,4	5,1	16143,4	0,25	0,32	0	481,905	1
2020/02	Sudeste	82	10.285,98	22,72	0	4,4	5,1	34152,4	0,25	1,6	1	481,905	1
2020/03	Centro-Oeste	8	10.050,00	29,38	1	4,15	5,07	11626,4	0,07	2,73	0	556,2841	1
2020/03	Nordeste	65	11.550,31	22,98	0	4,15	5,07	19532,6	0,07	0,74	0	556,2841	1
2020/03	Norte	25	11.803,20	30,24	0	4,15	5,07	16964,4	0,07	0,62	0	556,2841	1