



MINISTÉRIO DA EDUCAÇÃO
Universidade Federal de Ouro Preto
Instituto de Ciências Exatas e Aplicadas
Colegiado do curso de Engenharia de Produção



Análise comparativa entre modelos de séries temporais e machine learning para previsão de demanda no varejo: um estudo de caso.

Mateus Fraga Ferreira

João Monlevade, MG
2026

Mateus Fraga Ferreira

Análise comparativa entre modelos de séries temporais e machine learning para previsão de demanda no varejo: um estudo de caso.

Trabalho de conclusão de curso apresentado ao curso de Engenharia de Produção do Instituto de Ciências Exatas e Aplicadas da Universidade Federal de Ouro Preto, como parte dos requisitos necessários para a obtenção do título de Bacharel em Engenharia de Produção.

Orientador: Prof. Dra. Maressa Nunes Ribeiro Tavares

João Monlevade, MG

2026

SISBIN - SISTEMA DE BIBLIOTECAS E INFORMAÇÃO

F383a Ferreira, Mateus Fraga.

Análise comparativa entre modelos de séries temporais e machine learning para previsão de demanda no varejo [manuscrito]: um estudo de caso. / Mateus Fraga Ferreira. - 2026.

44 f.: il.: color., gráf., tab..

Orientadora: Profa. Dra. Maressa Nunes Ribeiro Tavares.

Monografia (Bacharelado). Universidade Federal de Ouro Preto. Instituto de Ciências Exatas e Aplicadas. Graduação em Engenharia de Produção .

1. Análise de regressão. 2. Análise de séries temporais. 3. Aprendizado do computador. 4. Comércio varejista. 5. Controle de estoque. 6. Controle de produção. 7. Oferta e demanda - Previsão. I. Tavares, Maressa Nunes Ribeiro. II. Universidade Federal de Ouro Preto. III. Título.

CDU 658.5:519.2

Bibliotecário(a) Responsável: Flavia Reis - CRB6/2431



FOLHA DE APROVAÇÃO

Mateus Fraga Ferreira

**Análise comparativa entre modelos de séries temporais e
machine learning para previsão de demanda no varejo: um
estudo de caso**

Monografia apresentada ao Curso de Engenharia de Produção da Universidade Federal de Ouro Preto como requisito parcial para obtenção do título de bacharel em Engenharia de Produção

Aprovada em 02 de julho de 2026

Membros da banca

Dra. - Maressa Nunes Ribeiro Tavares - Orientador(a) (Universidade Federal de Ouro Preto)

Dr. - Sérgio Evangelista Silva - (Universidade Federal de Ouro Preto)

Me. - Thairone Ezequiel de Almeida - (Universidade Federal de Ouro Preto)

Maressa Nunes Ribeiro Tavares, orientadora do trabalho, aprovou a versão final e autorizou seu depósito na Biblioteca Digital de Trabalhos de Conclusão de Curso da UFOP em 09/07/2026



Documento assinado eletronicamente por **Maressa Nunes Ribeiro Tavares, PROFESSOR DE MAGISTERIO SUPERIOR**, em 16/07/2026, às 11:04, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site http://sei.ufop.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **1140957** e o código CRC **BEF7504E**.

Agradecimentos

Agradeço primeiramente à Universidade Federal de Ouro Preto (UFOP) e ao Instituto de Ciências Exatas e Aplicadas, por toda a infraestrutura e pelo corpo docente que tornaram esta formação possível. À minha orientadora, Prof. Dra. Maressa Nunes Ribeiro Tavares, pela paciência, pela confiança no meu trabalho e por ter me guiado com maestria, exigência e sabedoria ao longo de todo o desenvolvimento desta pesquisa. Aos meus pais e aos meus irmãos, que são a minha base. Obrigado por todo o sacrifício, pelo apoio incondicional e por vibrarem com cada uma das minhas conquistas. Agradeço também ao meu cachorro, pelas madrugadas de companhia silenciosa enquanto eu ajustava os códigos e escrevia este texto. Aos meus amigos, que tornaram a rotina de cálculos, provas e trabalhos muito mais leve e suportável. Por fim, aos meus colegas da Comrades, pelas trocas de conhecimento diárias na área de dados e auditoria, que sem dúvida afiaram a minha visão analítica e contribuíram indiretamente para a maturidade técnica que apliquei neste modelo.

“Em Deus nós confiamos. Todos os outros devem trazer dados.”

— W. Edwards Deming

Resumo

A gestão eficiente de estoques no setor varejista é um fator crítico para a competitividade, sendo diretamente dependente da acuracidade da previsão de demanda. O presente trabalho tem como objetivo realizar uma análise comparativa da performance de diferentes modelos de previsão, avaliando suas habilidades e limitações em um estudo de caso prático. A metodologia compara três abordagens em ordem crescente de complexidade: um modelo de baseline (Média Móvel), um modelo de suavização exponencial (Holt-Winters) e um modelo causal de Machine Learning. O modelo de Machine Learning, baseado em Regressão Linear Dinâmica, é enriquecido com um robusto conjunto de variáveis exógenas, incluindo dados climáticos (temperatura e precipitação), feriados, ciclos de pagamento e um sistema de classificação hierárquica (tiers) desenvolvido para quantificar o impacto de eventos esportivos e locais. A análise foi aplicada em uma empresa do setor varejista de João Monlevade, MG, avaliando dois produtos com perfis de demanda distintos: cerveja e arroz. Os resultados indicaram que a Regressão Linear Dinâmica apresentou o melhor desempenho geral entre os modelos avaliados, embora os erros ainda evidenciem a complexidade da previsão de demanda diária no varejo.

Palavras-chaves: Previsão de Demanda. Séries Temporais. Machine Learning. Engenharia de Produção. Varejo.

Abstract

Efficient inventory management in the retail sector is a critical factor for competitiveness, being directly dependent on the accuracy of demand forecasting. This study aims to conduct a comparative analysis of the performance of different forecasting models, evaluating their capabilities and limitations in a practical case study. The methodology compares three approaches in increasing order of complexity: a baseline model (Moving Average), an exponential smoothing model (Holt-Winters) and a causal Machine Learning model. The Machine Learning model, based on Dynamic Linear Regression, is enriched with a robust set of exogenous variables, including climate data (temperature and precipitation), holidays, payment cycles, and a hierarchical classification system (tiers) developed to quantify the impact of sports and local events. The analysis was applied to a retail company in João Monlevade, MG, evaluating two products with distinct demand profiles: beer and rice. The results indicated that Dynamic Linear Regression showed the best overall performance among the models evaluated, although the errors still highlight the complexity of forecasting daily demand in retail.

Keywords: Demand Forecasting. Time Series. Machine Learning. Production Engineering. Retail.

Lista de abreviaturas e siglas

CV Coeficiente de Variação

ERP *Enterprise Resource Planning* (Planejamento dos Recursos da Empresa)

INMET Instituto Nacional de Meteorologia

MAE *Mean Absolute Error* (Erro Médio Absoluto)

MAPE *Mean Absolute Percentage Error* (Erro Médio Absoluto Percentual)

ML *Machine Learning* (Aprendizado de Máquina)

OOT *Out-of-Time*

PCP Planejamento e Controle da Produção

PMP Plano-Mestre de Produção

RLM Regressão Linear Múltipla

RMSE *Root Mean Squared Error* (Raiz Quadrática do Erro Médio)

UFOP Universidade Federal de Ouro Preto

Lista de símbolos

- α Parâmetro de suavização do nível (Holt-Winters)
- β Parâmetro de suavização da tendência (Holt-Winters)
- γ Parâmetro de suavização da sazonalidade (Holt-Winters)
- n Tamanho da amostra / Número de observações
- R^2 Coeficiente de Determinação

Sumário

1	INTRODUÇÃO	1
1.1	Objetivos	3
1.1.1	Objetivo geral	3
1.1.2	Objetivos específicos	3
1.2	Contribuições	3
1.3	Organização do Trabalho	4
2	REVISÃO DA LITERATURA	5
2.1	Planejamento e Controle da Produção (PCP)	5
2.2	Previsão de Demanda	6
2.3	Modelos Quantitativos de Previsão	6
2.3.1	Modelo de Baseline: Média Móvel	7
2.3.2	Modelo Holt-Winters	7
2.4	Modelos de <i>Machine Learning</i> Aplicados à Previsão de Demanda	8
2.4.1	Features Autorregressivas	10
2.5	Métricas de Avaliação de Modelos	10
2.5.1	Root Mean Squared Error (Raiz Quadrática do Erro Médio)	10
2.5.2	Mean Absolute Error (Erro Médio Absoluto)	11
2.5.3	Mean Absolute Percentage Error (Erro Médio Absoluto Percentual)	11
2.5.4	Coefficiente de Determinação (R^2)	11
2.5.5	Estratégia de Validação e Avaliação de Desempenho	12
3	METODOLOGIA	14
3.1	Metodologia	14
3.1.1	Caracterização Metodologica	14
3.1.2	Objeto de Estudo e coleta de dados	15
3.1.3	Definição das Variáveis e Features	16
3.1.4	Processo de Coleta, Integração e Tratamento dos Dados	17
3.1.5	Estratégia de Separação dos Dados	20
3.1.6	Implementação do Modelo de Machine Learning	20
4	RESULTADOS	22
4.1	Análise Descritiva das Séries Históricas	22
4.1.1	Análise de Tendência Linear	22
4.1.2	Perfil de Demanda: Arroz	23
4.1.3	Perfil de Demanda: Cerveja	25

4.2	Média Móvel	27
4.3	Holt-Winters	29
4.4	Modelo de Machine Learning: Regressão Linear Dinâmica	30
4.4.1	Regressão Linear Dinâmica: Arroz	32
4.4.2	Regressão Linear Dinâmica: Cerveja	36
4.5	Síntese Comparativa dos Resultados	39
5	CONSIDERAÇÕES FINAIS	41
	REFERÊNCIAS	44

1 Introdução

No cenário econômico contemporâneo, o setor varejista enfrenta um ambiente altamente competitivo, marcado pela expansão do comércio eletrônico, pela constante evolução do comportamento dos consumidores e pela necessidade de respostas cada vez mais rápidas às demandas do mercado. Nesse contexto, [Fildes, Ma e Kolassa \(2022\)](#) afirmam que o planejamento das empresas varejistas depende de previsões de demanda obtidas por métodos e processos integrados a sistemas de suporte à previsão (*Forecasting Support Systems – FSS*). Segundo os autores, previsões mais precisas contribuem para a melhoria do desempenho organizacional ao fornecer informações mais confiáveis para a tomada de decisões estratégicas e operacionais. Conforme destacam [Slack, Brandon-Jones e Johnston \(2018\)](#), a administração da produção trata da forma como as organizações criam e entregam bens e serviços, sendo responsável pela gestão dos recursos necessários para transformar entradas em produtos e serviços capazes de atender às exigências do mercado. Assim, a capacidade de uma empresa de disponibilizar a quantidade adequada de produtos no momento certo é determinante para seu desempenho operacional.

O PCP é responsável por coordenar os recursos necessários para atender aos planejamentos estratégicos, táticos e operacionais de uma empresa. Dessa forma, atua como elemento integrador entre os diferentes níveis organizacionais, traduzindo os objetivos estratégicos em ações concretas no chão de fábrica ou, no contexto varejista, no chão de loja. De maneira semelhante, [Fildes, Ma e Kolassa \(2022\)](#) destacam que as previsões de demanda subsidiam decisões nos níveis estratégico, tático e operacional, sendo fundamental que exista compatibilidade entre esses três níveis para garantir a consistência do processo de planejamento. Essa visão reforça o entendimento de [Tubino \(2007, p. 3\)](#), para quem "um sistema produtivo será tão mais eficiente quanto consiga sincronizar a passagem de estratégias para táticas e de táticas para operações de produção e venda dos produtos solicitados".

Segundo [Fildes, Ma e Kolassa \(2022\)](#), a demanda por determinados produtos do varejo é fortemente influenciada pela temperatura e por outras condições climáticas. Dessa forma, fatores meteorológicos podem provocar alterações significativas no comportamento do consumidor, tornando a inclusão dessas variáveis relevante para melhorar a precisão dos modelos de previsão de demanda.

A importância da previsão de demanda acurada no varejo é sustentada pela necessidade de otimização operacional em um setor caracterizado por margens de lucro reduzidas. Segundo [Fisher e Raman \(2018\)](#), pequenas variações na precisão da previsão podem resultar em impactos significativos nos resultados financeiros e na liquidez das empresas, o que justifica a transição de métodos baseados puramente na intuição para abordagens fundamentadas em ciência de dados e análise preditiva ([FISHER; RAMAN, 2018](#)).

Uma previsão incorreta pode acarretar duas consequências diretas: o excesso de estoque ou a ruptura de estoque. Essas situações resultam, respectivamente, na imobilização de capital e na perda de vendas, além da insatisfação do cliente. O planejamento e o controle das atividades da cadeia de suprimentos/logística dependem de estimativas acuradas dos volumes de produtos e serviços a serem processados. Nesse sentido, a previsão do nível de demanda é vital, pois fornece os dados básicos para o planejamento e controle de todas as áreas funcionais, incluindo logística, marketing, produção e finanças (BALLOU, 2006).

A complexidade do cenário atual exige mais do que intuição. Conforme apontam Silva, Vieira e Pelegrina (2025), a busca pela eficiência operacional tornou a interseção entre controle de produção, gestão de estoque e previsão de demanda uma prioridade estratégica. Os autores reforçam que a aplicação de ferramentas computacionais, integrando modelos como Regressão Linear em linguagem Python é capaz de mitigar os problemas clássicos de excesso ou ruptura de estoque, proporcionando uma tomada de decisão baseada em dados robustos.

Muitas empresas do setor varejista, especialmente as de pequeno porte ou familiares, ainda baseiam suas decisões de compras em métodos empíricos ou na experiência acumulada de funcionários. Embora possam produzir resultados aceitáveis em alguns casos, esses métodos carecem de consistência.

Apesar da relevância da previsão de demanda para a gestão de estoques, ainda existe uma lacuna prática na adoção de métodos quantitativos em pequenos e médios varejistas, especialmente quando se considera a incorporação de variáveis externas ao processo preditivo. Em muitos casos, decisões de compra continuam sendo tomadas com base em experiência individual, sem avaliação sistemática da acurácia dos métodos utilizados. Além disso, modelos mais sofisticados nem sempre são superiores em contextos de alta volatilidade e bases históricas limitadas, o que reforça a necessidade de comparar empiricamente diferentes abordagens em um caso real.

Considerando esse cenário, a pesquisa orienta-se pela seguinte questão: *Como a aplicação de modelos quantitativos e de machine learning, considerando variáveis externas como feriados (incluindo datas locais, como o aniversário de João Monlevade), temperatura e eventos esportivos, pode aprimorar a precisão da previsão de demanda em supermercados, em comparação com o método atualmente utilizado?*

O presente estudo surge da necessidade de dotar os gestores de ferramentas de apoio à decisão fundamentadas em dados. A demanda no varejo não é linear; ela sofre influência de feriados, variações climáticas e até mesmo eventos futebolísticos, fatores que introduzem grande variabilidade e exigem atenção especial. A utilização de modelos quantitativos e de Machine Learning (Aprendizado de Máquina) justifica-se pela capacidade dessas abordagens de identificar padrões e incorporar múltiplas variáveis, proporcionando uma base analítica mais sólida para a tomada de decisão, com impactos positivos sobre custos e satisfação do cliente.

Assim, este trabalho contribui tanto para o campo acadêmico, ao aplicar modelos quantitativos e de [Machine Learning \(Aprendizado de Máquina\)](#) em um contexto real, quanto para a prática gerencial, ao oferecer subsídios para decisões mais assertivas de compra e gestão de estoque.

1.1 Objetivos

1.1.1 Objetivo geral

Avaliar o desempenho dos métodos de média móvel, Holt-Winters e Regressão Linear Dinâmica na previsão de demanda em um supermercado, comparando sua capacidade preditiva por meio de métricas de desempenho.

1.1.2 Objetivos específicos

Para o cumprimento do objetivo geral, definem-se os seguintes objetivos específicos:

- Caracterizar o comportamento das séries históricas de demanda dos produtos analisados, identificando padrões temporais e fatores relevantes ao consumo;
- Implementar e avaliar os modelos de Média Móvel, Holt-Winters e Regressão Linear Dinâmica para previsão de demanda;
- Comparar o desempenho dos modelos por meio das métricas MAE, RMSE, MAPE e R^2
- Investigar a contribuição de [Variáveis Exógenas](#), como calendário, clima, preço e eventos, para o desempenho do modelo de [Machine Learning \(Aprendizado de Máquina\)](#).

1.2 Contribuições

O trabalho contribui para a literatura ao integrar técnicas quantitativas e de machine learning aplicadas ao contexto do varejo supermercadista, oferecendo uma análise empírica sobre o impacto de variáveis externas como clima e eventos na demanda. Do ponto de vista prático, fornece uma base metodológica para gestores desenvolverem previsões mais precisas e tomarem decisões mais assertivas quanto à gestão de estoque, compras e reposição de produtos.

1.3 Organização do Trabalho

O presente trabalho está estruturado em cinco capítulos. O **Capítulo 1** apresenta a contextualização, os objetivos e as justificativas do estudo. O **Capítulo 2** aborda o referencial teórico sobre planejamento e controle da produção, previsão de demanda e modelos quantitativos e de *machine learning*. O **Capítulo 3** descreve os procedimentos metodológicos adotados, a coleta de dados e as técnicas de modelagem utilizadas. O **Capítulo 4** apresenta e discute os resultados obtidos com a aplicação dos modelos. Por fim, o **Capítulo 5** traz as conclusões, limitações e sugestões para trabalhos futuros.

2 Revisão da Literatura

2.1 Planejamento e Controle da Produção (PCP)

Conforme [Stevenson \(2015\)](#), a administração da produção envolve a gestão dos recursos necessários para criar bens e serviços, coordenando decisões estratégicas, táticas e operacionais. Nesse sentido, o PCP depende diretamente de previsões para definir capacidade, estoques, compras e políticas operacionais, garantindo que os recursos sejam alinhados à demanda futura. Essa gestão abrange todo o processo produtivo, desde o projeto e desenvolvimento de um produto ou serviço até sua entrega final ao cliente.

A função produção, portanto, corresponde à parte da organização responsável por executar essas atividades, sendo essencial para qualquer empresa, já que todas, em maior ou menor grau, produzem bens ou prestam serviços. Essa lógica se aplica diretamente ao setor varejista, foco deste trabalho. Como destaca [Slack, Brandon-Jones e Johnston \(2018\)](#), embora o título do cargo possa variar, um “gerente de loja em um supermercado” é, na prática, um gerente de produção, pois é responsável por administrar os recursos que garantem a operação e asseguram a entrega dos produtos e serviços aos consumidores.

O planejamento de longo prazo, ou nível estratégico, trata das decisões que moldarão a capacidade produtiva da empresa no futuro, com um horizonte de anos. Nesta fase, a organização utiliza previsões de vendas de longo prazo para elaborar seu Plano de Produção. Este plano define investimentos de grande porte, como a aquisição de novas máquinas ou a expansão de instalações, sendo crucial para o desempenho futuro da companhia ([TUBINO, 2007](#)). No médio prazo situa-se o planejamento tático. Com a capacidade produtiva já definida pela estratégia, o objetivo é operar o sistema da forma mais eficiente possível, em um horizonte de meses. A principal ferramenta deste nível é o Plano-Mestre de Produção (PMP), que busca ajustar o uso da capacidade instalada para atender às previsões de vendas de médio prazo e aos pedidos já firmados. É neste nível tático, como aponta [Tubino \(2007\)](#), que o gestor utiliza de “manobras” como ajustar horas extras ou terceirizar parte da produção, todas baseadas em uma estimativa acurada da demanda futura. Finalmente, o planejamento de curto prazo representa o nível operacional.

Com a tática de operação já definida pelo PMP, esta fase se concentra na execução das tarefas diárias e semanais, como a programação da produção e a entrega dos produtos. Neste nível, a flexibilidade é mínima, pois não há tempo hábil para grandes mudanças sem causar desalinhamentos no processo. [Tubino \(2007\)](#) ressalta que a falta de sincronia entre o tático e o operacional resulta na formação de estoques desnecessários. Isso reforça a importância de uma previsão de demanda precisa no nível tático, pois seus erros impactam diretamente a eficiência e os custos da operação.

2.2 Previsão de Demanda

[Stevenson \(2015\)](#) destaca que previsões acuradas são essenciais para o planejamento da produção e para a cadeia de suprimentos, pois influenciam diretamente decisões de capacidade, estoques, compras e programação. Previsões imprecisas tendem a gerar rupturas ou excesso de estoque, aumentando custos operacionais.

A centralidade dessa atividade é reforçada por [Tubino \(2007\)](#), que explica que é a partir da projeção de vendas futuras que a empresa consegue estruturar seus planos de capacidade, fluxo de caixa, metas de vendas e políticas de estoque. Desta forma, a capacidade de antever o comportamento do mercado é crucial para que os gestores atuem de forma proativa, minimizando o impacto negativo das flutuações e otimizando o uso dos recursos.

2.3 Modelos Quantitativos de Previsão

Os modelos quantitativos de previsão constituem um conjunto de ferramentas estatísticas e computacionais utilizadas para estimar cenários futuros. Em um contexto empresarial, a previsão é requerida em diversas situações, como determinar a quantidade de insumos para a produção ou o nível de estoque ideal para atender à demanda em um comércio varejista. Conforme destaca [Stevenson \(2015\)](#), o principal objetivo dos métodos de previsão de demanda, é adequar a oferta à demanda. É um equívoco comum supor que a previsão de demanda é ineficaz em ambientes de alta mudança.

Na verdade, como esclarecem [Hyndman e Athanasopoulos \(2021\)](#), todo ambiente está em constante mudança, e a função de um bom modelo de previsão não é assumir que o futuro será estático, mas capturar a natureza dessa mudança. Um modelo de previsão eficaz busca entender a dinâmica do sistema e a forma como as variáveis evoluem para projetar o comportamento futuro.

Estudos recentes aplicados ao varejo brasileiro reforçam a diferença de desempenho entre os métodos tradicionais e os modelos de aprendizado de máquina. [Nellessen et al. \(2025\)](#) avaliaram a previsão de demanda de 10 produtos de uma loja varejista utilizando os métodos SARIMA, Holt-Winters, XGBoost e MLP. Os autores chegaram à conclusão que os modelos tradicionais apresentaram desempenho superior em cenários de séries temporais curtas, sobretudo devido à limitação de dados para treinamento dos modelos de aprendizado de máquina ([NELLESSEN et al., 2025](#)). Esses resultados corroboram a literatura clássica ao indicar que, em bases reduzidas, os métodos estatísticos tendem a ser mais robustos e estáveis.

2.3.1 Modelo de Baseline: Média Móvel

Um dos métodos mais clássicos e simples para a análise de séries temporais é o da Média Móvel (MM). A utilização de médias móveis para suavizar dados e identificar tendências é um conceito fundamental que serve como base para diversas técnicas de decomposição de *Séries Temporais* desde a década de 1920 (HYNDMAN; ATHANASOPOULOS, 2021). Segundo Stevenson (2015), uma previsão de média móvel é aquela que utiliza uma série de valores de dados reais mais recentes para gerar uma previsão. A equação da média móvel é definida por:

$$F_t = MA_n = \frac{\sum_{i=1}^n A_{t-i}}{n} = \frac{A_{t-1} + A_{t-2} + \cdots + A_{t-n}}{n} \quad (2.1)$$

F_t = Previsão para o período t

MA_n = Média móvel de ordem n

A_{t-i} = Valor observado no período $t - i$

n = Número de períodos na média móvel

Apesar de sua utilidade como *Baseline (Modelo de Referência)*, Stevenson (2015) alerta que as médias móveis simples possuem limitações críticas em cenários dinâmicos. Segundo o autor, como todos os pontos de dados na janela móvel recebem o mesmo peso, o modelo sofre de "inércia", reagindo lentamente a mudanças recentes no nível da série. Isso resulta em previsões sistematicamente atrasadas (efeito lag) em presença de tendências de crescimento ou declínio, além da incapacidade matemática do modelo simples em replicar padrões de sazonalidade sem tratamentos prévios.

2.3.2 Modelo Holt-Winters

Conforme explicam Hyndman e Athanasopoulos (2021), o modelo de Holt-Winters é uma extensão do método de Holt desenvolvida para capturar a sazonalidade. O método compreende a equação de previsão e três equações de suavização para seus componentes principais: o nível (ℓ_t), a tendência (b_t) e a sazonalidade (s_t). Nesse contexto, o nível representa o valor base da série, a tendência indica sua direção de longo prazo e a sazonalidade captura os padrões repetitivos de frequência m .

O modelo possui duas variações: aditiva e multiplicativa. A sazonalidade aditiva é caracterizada por variações de magnitude constante ao longo do tempo, enquanto a multiplicativa, mais comum em dados de vendas, modela a variação sazonal como um fator proporcional ao nível da série. A escolha entre os dois métodos depende da análise da série temporal e da natureza de suas flutuações (HYNDMAN; ATHANASOPOULOS, 2021).

As equações de suavização do modelo Holt-Winters aditivo, conforme visto no conjunto de equações 2.2, são definidas por:

$$\text{Nível:} \quad \ell_t = \alpha(y_t - s_{t-m}) + (1 - \alpha)(\ell_{t-1} + b_{t-1}) \quad (2.2a)$$

$$\text{Tendência:} \quad b_t = \beta^*(\ell_t - \ell_{t-1}) + (1 - \beta^*)b_{t-1} \quad (2.2b)$$

$$\text{Sazonalidade:} \quad s_t = \gamma(y_t - \ell_{t-1} - b_{t-1}) + (1 - \gamma)s_{t-m} \quad (2.2c)$$

Em que m denota o período da sazonalidade (por exemplo, $m = 12$ para dados mensais) e os parâmetros de suavização α , β^* e γ variam entre 0 e 1. Segundo [Hyndman e Athanasopoulos \(2021\)](#), a lógica por trás dessas equações baseia-se em médias ponderadas:

- A **equação de nível (2.2a)** demonstra uma média ponderada entre a observação sazonalmente ajustada ($y_t - s_{t-m}$) e a previsão não sazonal para o tempo t , dada por $(\ell_{t-1} + b_{t-1})$.
- A **equação de tendência (2.2b)** é idêntica ao método linear de Holt, ponderando a variação do nível atual em relação ao anterior com a estimativa da tendência passada.
- A **equação de sazonalidade (2.2c)** apresenta uma média ponderada entre o índice sazonal atual, calculado por $(y_t - \ell_{t-1} - b_{t-1})$, e o índice sazonal da mesma estação no ano anterior (m períodos atrás).

Por fim, a forma componente para a previsão de h períodos à frente é dada por:

$$\hat{y}_{t+h|t} = \ell_t + hb_t + s_{t+h-m(k+1)} \quad (2.3)$$

onde k é a parte inteira de $(h-1)/m$. Este termo assegura que as estimativas dos índices sazonais utilizados para a previsão sejam provenientes do último ano da amostra disponível ([HYNDMAN; ATHANASOPOULOS, 2021](#)). A componente de nível, mostrada na equação 2.2a, é atualizada a cada período.

2.4 Modelos de *Machine Learning* Aplicados à Previsão de Demanda

A opção pela utilização de um modelo de Regressão Linear Múltipla (RLM), estruturado como uma Regressão Dinâmica através da inclusão de termos autorregressivos, fundamenta-se na necessidade de aliar capacidade preditiva à interpretabilidade dos resultados ([White Box \(Caixa-Branca\)](#)). Embora modelos de *machine learning* mais complexos, como Redes Neurais ou Gradient Boosting, possam oferecer alto poder de ajuste aos dados, estes frequentemente operam como "caixas-pretas", dificultando a compreensão isolada do impacto de cada variável explicativa sobre a variável dependente.

A aplicação de técnicas de regressão para previsão enquadra-se no paradigma do Aprendizado Supervisionado. Conforme definem [James et al. \(2013\)](#), essa abordagem consiste em construir um modelo estatístico para prever ou estimar uma saída (Y) com base em um ou mais inputs (X), tendo como objetivo minimizar uma função de perda redutível, aprendendo as relações subjacentes nos dados de treino para aplicá-las a novos dados não observados.

Conforme [Gujarati e Porter \(2011\)](#), a análise de regressão tem como objetivo estimar e prever o valor médio de uma variável dependente com base em variáveis explicativas conhecidas. O *machine learning* baseia-se na ideia de que sistemas podem aprender com dados e identificar padrões de forma autônoma. Em vez de serem explicitamente programados com regras fixas, os algoritmos de *machine learning* são treinados com grandes volumes de dados para construir modelos capazes de realizar previsões precisas ([GÉRON, 2019](#)).

Conforme destacam [Fildes, Ma e Kolassa \(2022\)](#), estudos recentes demonstram que algoritmos de *Machine Learning* podem superar métodos univariados tradicionais na previsão de demanda. Em um dos trabalhos revisados pelos autores, um modelo baseado em aprendizado de máquina apresentou desempenho superior aos métodos de referência (*benchmarks*), tanto nas previsões agregadas quanto na maioria das lojas analisadas.

No contexto da gestão varejista, o objetivo deste estudo não se limita apenas a prever a demanda futura, mas também a compreender a magnitude da influência de fatores exógenos, como variações de temperatura, ocorrência de eventos locais e dias de pagamento, sobre o comportamento do consumidor.

Essas variáveis afetam significativamente o comportamento de compra e podem ser modeladas para aumentar a acurácia da previsão de demanda. Para o modelo de *machine learning*, utiliza-se uma abordagem de Regressão Linear Múltipla. A estrutura fundamental do modelo busca estimar a demanda (Y_i) a partir de um conjunto de k variáveis exógenas (X), em que cada variável tem seu impacto quantificado por um coeficiente (β). Estes coeficientes ($\beta_1, \dots, \beta_k$) mensuram o impacto marginal de cada variável, indicando a variação esperada na demanda para cada unidade de aumento em X , mantendo-se as demais condições constantes. Já o termo β_0 representa o intercepto, ou seja, o nível base da demanda não explicado pelas variáveis incluídas. A fórmula para seu cálculo é dada por:

$$Y_i = \beta_0 + \beta_1 X_{1i} + \beta_2 X_{2i} + \dots + \beta_k X_{ki} + \varepsilon_i \quad (2.4)$$

Neste trabalho, as variáveis exógenas ($X_{1i}, \dots, X_{ki}$) incluem dados climáticos, feriados e o sistema de [Tiers \(Níveis/Camadas\)](#) para eventos, conforme detalhado na metodologia.

2.4.1 Features Autorregressivas

Para capturar o comportamento temporal das vendas, é comum adicionar *features* autorregressivas isto é, valores passados da própria variável de interesse. Por exemplo, a variável *Vendas_Semana_Anterior* (um *Efeito Lag (Atraso/Inércia)* de sete períodos) pode ser utilizada como uma preditora para as vendas atuais, capturando a sazonalidade semanal. Conforme Hyndman e Athanasopoulos (2021), essa técnica transforma o modelo de regressão em uma regressão dinâmica, combinando a análise causal com a memória dos modelos de séries temporais.

2.5 Métricas de Avaliação de Modelos

As métricas de avaliação de modelos são utilizadas para verificar a capacidade de um modelo em gerar previsões coerentes com a realidade observada. Elas permitem mensurar o desempenho preditivo de cada abordagem, oferecendo uma base objetiva para comparar seus resultados. A seguir, são apresentadas as principais métricas adotadas neste trabalho.

2.5.1 Root Mean Squared Error (Raiz Quadrática do Erro Médio)

A Raiz Quadrática do Erro Médio (*Root Mean Squared Error* - RMSE) é uma das métricas mais empregadas na avaliação de modelos de previsão. Ela mede a magnitude média do erro entre os valores previstos e os observados. A fórmula para seu cálculo é dada por:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (2.5)$$

na qual $\hat{y}_i$ representa o valor previsto, y_i o valor observado e n o número total de observações. O RMSE penaliza erros grandes de forma mais intensa, pois eleva as diferenças ao quadrado antes de calcular a média. Conforme Silva, Vieira e Pelegrina (2025) o RMSE sempre retornará valores positivos. Além disso, quanto mais próximo de zero estiver, melhor será a precisão do modelo. Dessa forma, um único erro discrepante exerce grande influência sobre o resultado final. Essa característica o torna sensível a *outliers*. O RMSE constitui uma métrica de avaliação coerente para modelos fundamentados na minimização da soma dos erros quadráticos, como a Regressão Linear Múltipla, uma vez que reflete diretamente a função objetivo otimizada por esses algoritmos

Por estar na mesma unidade da variável prevista, o RMSE permite uma interpretação direta. Um valor de RMSE significativamente menor que o desvio padrão da variável-alvo indica que o modelo possui poder preditivo relevante em relação a uma simples previsão pela média histórica.

2.5.2 Mean Absolute Error (Erro Médio Absoluto)

O Erro Médio Absoluto (*Mean Absolute Error* - MAE) expressa a média dos desvios absolutos entre os valores previstos e os observados, sem considerar o sentido do erro. Seu cálculo é dado por:

$$MAE = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i| \quad (2.6)$$

A principal vantagem do MAE é sua fácil interpretação. Como está na mesma unidade da variável prevista, um MAE de 35 significa que, em média, o modelo erra 35 unidades (sejam cervejas ou pacotes de arroz) para mais ou para menos em cada previsão. Essa métrica mede a precisão das previsões calculando a diferença absoluta média entre os valores previstos e os valores reais. É uma métrica simples e intuitiva para avaliar erros (SILVA; VIEIRA; PELEGRINA, 2025)

Diferente do RMSE, o MAE não eleva os erros ao quadrado, tratando todos de maneira linear. Assim, é menos sensível a *outliers*, oferecendo uma visão mais equilibrada da performance geral do modelo.

2.5.3 Mean Absolute Percentage Error (Erro Médio Absoluto Percentual)

O Erro Médio Absoluto Percentual (MAPE (*Mean Absolute Percentage Error*)) mede o erro percentual médio entre as previsões e os valores reais. Essa métrica facilita a interpretação dos resultados, pois expressa o erro em termos percentuais, permitindo comparar produtos e modelos com escalas distintas. Sua formulação é apresentada a seguir:

$$MAPE = \frac{100}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (2.7)$$

O MAPE é amplamente utilizado em contextos gerenciais, como o varejo, pois traduz diretamente o desvio percentual médio das previsões. Por exemplo, um MAPE de 8% indica que, em média, o modelo erra 8% em suas previsões de demanda (HYNDMAN; ATHANASOPOULOS, 2021).

2.5.4 Coeficiente de Determinação (R^2)

O Coeficiente de Determinação (R^2) avalia o quanto das variações observadas na variável dependente Y é explicado pelo conjunto das variáveis independentes X presentes no modelo (GUJARATI; PORTER, 2011). Sua expressão é:

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (2.8)$$

na qual $\bar{y}$ é a média dos valores observados. O valor de R^2 varia entre 0 e 1. Um $R^2 = 0,75$ indica que 75% da variância de Y é explicada pelas variáveis explicativas. Quanto mais próximo de 1, maior o poder explicativo do modelo. Entretanto, o R^2 tende a aumentar com a adição de novas variáveis, mesmo quando estas não são relevantes. Para corrigir esse viés, utiliza-se o R^2 ajustado, que penaliza a inclusão de variáveis desnecessárias. Assim, o valor ajustado só aumenta se a nova variável realmente contribui para a explicação de Y , tornando-o um indicador mais robusto da qualidade do ajuste.

2.5.5 Estratégia de Validação e Avaliação de Desempenho

Um dos desafios centrais na construção de modelos preditivos é evitar o fenômeno de superajuste (*overfitting*). Conforme explica (GÉRON, 2019), o *Overfitting (Sobreajuste)* ocorre quando o modelo se torna complexo demais para a quantidade e o ruído dos dados de treinamento disponíveis, perdendo a capacidade de generalizar para novas instâncias.

Considerando a natureza sequencial dos dados de vendas e a extensão limitada da série histórica disponível para este estudo de caso, métodos tradicionais de validação cruzada aleatória (*k-fold*) ou janelas de expansão curtas mostram-se inviáveis. A divisão aleatória violaria a ordem cronológica, causando vazamento de dados (*data leakage*), enquanto janelas de expansão iniciadas em períodos muito curtos poderiam sofrer viés devido a eventos atípicos (como a Copa do Mundo de 2022) presentes no início da série.

Dessa forma, neste trabalho será adotada a estratégia de validação *Hold-out* com corte temporal (*Out-of-Time (OOT)*). A série será segmentada respeitando a linearidade temporal:

- **Conjunto de Treinamento (70% iniciais):** Utilizado para o ajuste dos parâmetros dos modelos, permitindo que o algoritmo aprenda a sazonalidade e a tendência base.
- **Conjunto de Teste (30% finais):** Destinado exclusivamente à avaliação final, simulando o desempenho do modelo em um futuro desconhecido.

Essa abordagem, recomendada por Hyndman e Athanasopoulos (2021) para séries curtas, garante que a avaliação de acurácia reflita a capacidade real do modelo de prever eventos futuros sem ter tido contato prévio com eles.

A Tabela 2 apresenta um resumo das metodologias de previsão tratadas pelos autores de referência. O comparativo demonstra quais obras abordam desde os modelos clássicos até as técnicas de Machine Learning.

Tabela 2 – Abordagem dos métodos de previsão pelos autores de referência

Autor (Ano)	Média Móvel	Holt-Winters	Machine Learning
Tubino (2007)	✓	✓	✗
Gujarati e Porter (2011)	✗	✗	✗
Slack, Brandon-Jones e Johnston (2018)	✓	✓	✗
Géron (2019)	✗	✗	✓
Hyndman e Athanasopoulos (2021)	✓	✓	✓
Proposta de pesquisa (2026)	✓	✓	✓

Fonte: O Autor (2026).

3 Metodologia

3.1 Metodologia

A presente pesquisa caracteriza-se como um estudo de caso de natureza aplicada, com abordagem quantitativa e utilização de modelos estatísticos e de machine learning para previsão de demanda. O objetivo desta seção é detalhar as estratégias de coleta, organização e modelagem dos dados que são utilizadas para avaliar o desempenho dos métodos propostos.

Os dados primários utilizados neste estudo foram cedidos pela gestão da empresa varejista parceira. As informações históricas de volume comercializado e de preços foram extraídas pela própria equipe interna a partir do sistema de gestão integrada (ERP) da organização, sendo disponibilizadas para esta pesquisa por meio de relatórios brutos no formato .xlsx. O horizonte temporal delimitado compreende o período contínuo de 01 de janeiro de 2022 a 31 de agosto de 2025. Ao consolidar as informações em frequência diária para capturar efeitos de curtíssimo prazo, a base de dados final totalizou 1.339 observações para cada um dos produtos analisados (arroz e cerveja). Ressalta-se que, em conformidade com os termos de confidencialidade firmados, os dados de volume foram submetidos a um escalonamento linear, preservando o comportamento estatístico e a volatilidade original sem expor valores comerciais sensíveis.

3.1.1 Caracterização Metodológica

Quanto à natureza, esta pesquisa classifica-se como aplicada. Segundo [Gil \(2002\)](#), pesquisas com essa finalidade decorrem do desejo de conhecer com vistas a fazer algo de maneira mais eficiente ou eficaz, buscando soluções para problemas práticos imediatos.

Quanto aos procedimentos técnicos, adota-se o estudo de caso. Conforme define [Gil \(2002\)](#), o estudo de caso consiste no “estudo profundo e exaustivo de um ou poucos objetos, de maneira que permita seu amplo e detalhado conhecimento”. Esta escolha adequa-se ao objetivo de analisar especificamente a demanda de um supermercado em João Monlevade.

A abordagem do estudo é quantitativa, fundamentada na coleta e análise estatística de séries históricas de vendas, permitindo a aplicação de modelos matemáticos para a previsão de demanda.

A seleção dos modelos empregados neste estudo também se fundamenta em evidências empíricas recentes. [Nellessen et al. \(2025\)](#) demonstraram que, em ambientes varejistas com séries históricas curtas e baixa granularidade, modelos tradicionais como SARIMA e Holt-Winters frequentemente superam XGBoost e redes neurais artificiais. Como o presente trabalho opera em um contexto metodológico semelhante, a escolha dos modelos segue uma linha coerente com a literatura recente e com as melhores práticas identificadas no setor varejista brasileiro ([NELLESSEN et al., 2025](#)).

3.1.2 Objeto de Estudo e coleta de dados

O objeto de estudo é uma empresa consolidada do setor varejista, cujo nome é preservado por confidencialidade. Para a análise, foram selecionadas duas categorias de produtos com perfis de consumo distintos:

- **Cerveja (produto de oportunidade):** alta sazonalidade e forte dependência de fatores externos como temperatura, eventos e feriados.
- **Arroz (produto de necessidade):** item de consumo recorrente, usualmente associado na literatura e na prática varejista a uma demanda mais estável e menos sensível a variáveis exógenas.

A coleta e a estruturação dos dados primários seguiram um fluxo que envolveu desde a extração nos sistemas internos da empresa até a integração com bases de dados externas. Os aspectos operacionais desse processo são detalhados a seguir:

- **Sistema utilizado pela empresa e extração:** Os dados históricos de vendas e preços foram originados diretamente do sistema de gestão integrada (ERP) da empresa. A extração foi realizada de forma **manual por meio de relatórios gerenciais** diretamente do banco de dados da organização.
- **Arquivos extraídos e formato:** Os relatórios brutos foram gerados originalmente em formato **.xlsx** e, posteriormente, processados e integrados em uma base unificada.
- **Período e frequência diária:** O horizonte temporal delimitado para a pesquisa compreende o período de **01/01/2022 de Início a 31/08/2025**. Os dados foram consolidados em **frequência diária**, permitindo capturar os efeitos de dias específicos da semana, vésperas de feriados e comportamentos de curtíssimo prazo no varejo.
- **Quantidade de observações:** A base de dados final, após o emparelhamento do histórico de vendas das duas categorias com as variáveis exógenas coletadas, totalizou um montante de **1339** observações diárias para cada produto analisado.

A base de dados utilizada neste estudo foi construída a partir da coleta manual e da integração de múltiplas fontes, consolidadas em um arquivo no formato XLSX. Para assegurar a qualidade das informações, realizou-se uma etapa de limpeza, verificação de consistência e padronização das variáveis. Além do histórico de vendas, foram incorporadas variáveis exógenas capazes de representar fatores externos que influenciam o comportamento da demanda. Conforme destacam [Fildes, Ma e Kolassa \(2022\)](#), modelos de previsão podem incorporar variáveis explicativas, como o dia da semana, promoções e outros direcionadores (*drivers*) da demanda. Dessa forma, buscou-se selecionar atributos que refletissem características temporais, climáticas e comportamentais relevantes para o contexto do varejo estudado. A seguir, são detalhadas as variáveis utilizadas na construção dos modelos.

3.1.3 Definição das Variáveis e Features

Abaixo são detalhadas as variáveis explicativas e o tratamento dos dados utilizados no modelo:

1. **Dinâmica de Preços e Elasticidade:** Os preços diários foram incorporados para capturar a sensibilidade do consumidor a promoções. Seguindo a teoria microeconômica de [Pindyck e Rubinfeld \(2006\)](#), assume-se um coeficiente negativo ao preço, refletindo a relação inversa entre preço e quantidade demandada.
2. **Temperatura e Precipitação:** Devido à ausência de dados meteorológicos consolidados para o município de João Monlevade (pela inexistência de uma estação automática ativa do INMET na localidade), as variáveis climáticas foram obtidas a partir da estação meteorológica mais próxima disponível, a A521 (Belo Horizonte - Pampulha). Os dados horários foram agregados da seguinte forma:
 - **Temperatura média diária:** média das leituras horárias.
 - **Precipitação diária:** soma das leituras por dia.
3. **Eventos Locais:** Foi elaborado um levantamento de eventos regionais relevantes ocorridos na microrregião de João Monlevade. Cada evento foi classificado em níveis de impacto (tiers) conforme sua magnitude:
 - **Tier 0:** Nenhum evento relevante.
 - **Tier 1:** Eventos regionais de impacto moderado.
 - **Tier 2:** Eventos de maior escala em cidades vizinhas.
 - **Tier 3:** Grandes shows ou eventos locais de massa.

A classificação em Tiers foi adotada como uma estratégia de *Feature Engineering (Engenharia de Variáveis)* para mitigar a ausência de dados oficiais de contagem de público. Deixar o processamento 'aprender' a magnitude seria inviável, pois a data ou o nome do evento não carregam correlação matemática direta com o impacto social.

4. **Eventos de Futebol:** Considerando a relevância cultural do futebol no comportamento de consumo, foram incorporados jogos de Flamengo, Cruzeiro e Atlético-MG, classificados como:
 - **Tier 0:** Sem jogos relevantes.
 - **Tier 1:** Finais do Campeonato Mineiro.
 - **Tier 2:** Clássicos e semifinais nacionais.
 - **Tier 3:** Finais de campeonatos e jogos da Seleção Brasileira.
5. **Features Relacionadas à Data:** Foram criadas variáveis temporais que capturam padrões sazonais e cíclicos:
 - **Dia_da_Semana e Mês:** extraídos da data, tratados como variáveis categóricas.
 - **Feriado e Véspera_Feriado:** baseadas em calendário oficial nacional e municipal.
 - **Efeito_Pagamento:** variável binária com valor 1 nos sete primeiros dias de cada mês, representando o aumento de consumo após o recebimento dos salários.

3.1.4 Processo de Coleta, Integração e Tratamento dos Dados

Para garantir a confiabilidade do modelo preditivo e a integridade da análise, estruturou-se um fluxo de trabalho sistemático. Conforme ilustrado no fluxograma da Figura 1, o processo abrange desde a captação das informações brutas até a validação final dos algoritmos, desenrolando-se nas seguintes macrotarefas sequenciais:

1. **Fase de Coleta e Extração:** Conforme o topo do fluxograma, esta etapa ocorreu em frentes simultâneas de levantamento de dados:
 - *Extração das Vendas:* Obtenção do histórico diário de volume comercializado e preços no sistema de gestão (ERP) da empresa varejista.
 - *Coleta de Dados Meteorológicos:* Compilação de precipitação e temperatura média da estação A521.
 - *Coleta de Feriados:* Estruturação de um calendário unificado com as datas comemorativas nacionais, estaduais e municipais.
 - *Coleta de Eventos Regionais e Esportivos:* Mapeamento quantitativo (*tiers*) de grandes eventos e partidas de futebol com impacto no fluxo local.

2. **Integração das Bases de Dados:** Cruzamento das múltiplas fontes extrínsecas com o histórico interno de vendas, utilizando a data cronológica como chave primária de união.
3. **Tratamento e Limpeza dos Dados:** Identificação e correção de anomalias. Foi incluída a sinalização da variável de loja fechada, passo crítico para garantir que as métricas de erro percentual não sofram distorções matemáticas por divisões por zero durante a avaliação.
4. **Construção das Variáveis (*Feature Engineering*):** Criação de novas *features* temporais e sazonais (como vésperas de feriados, indicadores de fim de semana e o mapeamento de efeito de pagamento salarial).
5. **Base Final para Modelagem:** Consolidação do *dataset* limpo, enriquecido e alinhado cronologicamente, marcando a transição da engenharia de dados para a fase de previsão estatística.
6. **Separação Treinamento e Teste (OOT):** Divisão cronológica da base de dados (*Out-of-Time*), isolando um período histórico contínuo para treinar os algoritmos e uma janela futura inédita para simular o ambiente real de previsão.
7. **Modelagem e Treinamento dos Modelos:** Aplicação prática dos algoritmos de séries temporais sobre a base de treino para a extração dos padrões e sazonalidades de consumo.
8. **Avaliação do Desempenho dos Modelos:** Confronto direto entre as previsões geradas pelo modelo e os dados reais da base de teste, apurando a acurácia por meio de indicadores técnicos de erro.




Figura 1 – Fluxograma do processo de estruturação da base de dados e modelagem.

Fonte: O autor (2026).

3.1.5 Estratégia de Separação dos Dados

Para a validação dos modelos, adotou-se a estratégia *Out-of-Time* (OOT). Diferente de divisões aleatórias (como o *k-fold* tradicional), esse método preserva a integridade temporal da série, impedindo que informações futuras influenciem o treinamento (*data leakage*). Dessa forma, a base de dados, composta por 1.339 observações diárias, foi segmentada cronologicamente para simular um cenário real de previsão, respeitando a proporção de 70% para treinamento e 30% para teste:

- **Conjunto de Treinamento (70% iniciais):** Correspondendo a aproximadamente 937 dias (pouco mais de 2,5 anos), esta janela foi utilizada para o aprendizado e ajuste de parâmetros dos algoritmos. Esse volume histórico é metodologicamente fundamental para que o modelo aprenda com solidez a tendência base e os padrões sazonais, garantindo a exposição a pelo menos dois ciclos anuais completos de eventos, feriados e flutuações de demanda.
- **Conjunto de Teste (30% finais):** Destinado exclusivamente à avaliação final, este conjunto engloba cerca de 402 dias de dados inéditos. Essa proporção superior a um ano civil assegura que a capacidade de generalização do modelo seja atestada frente a todas as sazonalidades, meses e feriados de forma rigorosa, simulando com precisão o ambiente de incerteza da previsão futura.

3.1.6 Implementação do Modelo de Machine Learning

Após a etapa de preparação da base de dados e da definição da estratégia de validação *Out-of-Time* (OOT), procedeu-se ao treinamento do modelo de Regressão Linear Múltipla estruturado como uma Regressão Dinâmica. O processo compreendeu a geração de atributos autorregressivos, o pré-processamento das variáveis categóricas e numéricas, o treinamento do modelo e a avaliação de seu desempenho por meio das métricas MAE, RMSE, MAPE e R^2 . O Algoritmo 1 apresenta, de forma resumida, o fluxo adotado para construção, treinamento e avaliação do modelo desenvolvido neste trabalho.

Algoritmo 1: Procedimento para treinamento e avaliação do modelo de Machine Learning

Entrada: Base histórica de vendas**Saída:** Previsões de demanda e métricas de desempenho

- 1 Carregar e preparar a base de dados;
 - 2 Ordenar as observações cronologicamente;
 - 3 Definir a variável resposta;
 - 4 Gerar atributos autorregressivos (Lag_1 , Lag_7 , MM_3 , MM_7 , MM_{15});
 - 5 Remover registros com valores ausentes;
 - 6 Definir o conjunto de variáveis preditoras;
 - 7 Dividir a base em treinamento e teste utilizando a estratégia Out-of-Time;
 - 8 Aplicar codificação One-Hot às variáveis categóricas;
 - 9 Treinar o modelo de Regressão Linear Múltipla;
 - 10 Gerar previsões para o conjunto de teste;
 - 11 Corrigir previsões negativas;
 - 12 Calcular MAE, RMSE, MAPE e R^2 ;
 - 13 Determinar a importância das variáveis pelos coeficientes do modelo;
 - 14 Comparar valores observados e previstos;
-

Conforme apresentado no Algoritmo 1, o procedimento inicia-se com o carregamento e a preparação da base de dados, seguido pela construção dos atributos autorregressivos e pela separação cronológica da série temporal em conjuntos de treinamento e teste. Na sequência, realiza-se o pré-processamento das variáveis categóricas, o treinamento do modelo de Regressão Linear Múltipla, a geração das previsões e o cálculo das métricas de desempenho. Por fim, são analisados os coeficientes estimados pelo modelo, permitindo avaliar a contribuição das variáveis explicativas, bem como comparar os valores previstos com os valores observados.

4 Resultados

Neste capítulo, apresentam-se os resultados obtidos a partir da aplicação dos modelos de previsão propostos. A análise inicia-se pela caracterização das séries temporais, seguida pela avaliação do desempenho do modelo de baseline e, por fim, a comparação com as abordagens de maior complexidade.

4.1 Análise Descritiva das Séries Históricas

Para fundamentar a escolha e o ajuste dos modelos de previsão, é imperativo compreender a natureza estocástica das demandas diárias em estudo. Embora a literatura e a prática varejista frequentemente classifiquem o arroz como um produto de consumo estável, a análise estatística dos registros diários revelou um comportamento distinto no conjunto analisado, avaliado por meio do Coeficiente de Variação (CV). O CV é uma medida de dispersão relativa definida pela razão entre o desvio padrão (σ) e a média (μ) dos dados ($CV = \sigma/\mu$), cuja função é expressar a variabilidade de uma série em relação à sua magnitude, permitindo a comparação direta entre diferentes produtos.

No universo amostral deste estudo, o CV da série diária de arroz (60,76%) mostrou-se muito próximo ao observado para a cerveja (61,79%), indicando elevada dispersão relativa em ambos os produtos. Conforme ilustrado na Tabela 3, esse indicador evidencia que a demanda diária de arroz apresenta uma volatilidade consideravelmente superior à esperada pela teoria tradicional varejista, justificando a necessidade de abordagens de previsão robustas para séries temporais diárias de alta variabilidade.

Tabela 3 – Estatísticas descritivas das séries de demanda

Produto	Média	Desvio Padrão	CV (%)
Cerveja	1562,19	965,21	61,79%
Arroz	100,59	61,12	60,76%

Fonte: O autor (2026).

4.1.1 Análise de Tendência Linear

Com o objetivo de verificar a existência de tendência linear nas séries temporais analisadas, ajustou-se uma regressão linear simples entre a demanda observada e um índice temporal. Essa análise permite avaliar se a passagem do tempo, isoladamente, apresenta capacidade explicativa relevante sobre o comportamento das vendas.

Tabela 4 – Análise de tendência linear das séries de demanda

Produto	Inclinação	R^2	Interpretação
Arroz	-0,009	0,0035	Tendência linear praticamente nula
Cerveja	-0,633	0,0644	Leve tendência de queda, com baixo poder explicativo

Fonte: O autor (2026).


Os resultados apresentados na Tabela 4 indicam que as séries não apresentam tendência linear expressiva. Para o arroz, a inclinação de -0,009 e o R^2 de 0,0035 indicam uma tendência praticamente nula, uma vez que a passagem do tempo explica apenas 0,35% da variação observada na demanda. No caso da cerveja, embora a inclinação seja negativa, indicando uma leve tendência média de queda, o R^2 de 0,06436 demonstra que apenas 6,44% da variação da série é explicada pela tendência linear.

Dessa forma, conclui-se que a dinâmica das vendas não é predominantemente explicada por uma tendência global de crescimento ou queda ao longo do tempo. Esse resultado reforça a hipótese de que a variabilidade das séries está mais associada a oscilações de curto prazo, sazonalidades, fatores comportamentais e componentes aleatórios da demanda do que a uma tendência linear estrutural. Ressalta-se, entretanto, que a ausência de tendência linear expressiva não implica, por si só, estacionariedade da série, sendo necessária a aplicação de testes específicos para essa finalidade.

4.1.2 Perfil de Demanda: Arroz

Embora o arroz seja uma commodity de primeira necessidade, comumente associada a um consumo inelástico e estável, a análise quantitativa revelou uma dinâmica distinta para a série em estudo. Utilizando o software Excel, foi possível criar um gráfico para entender a demanda diária e o agrupamento de vendas por dia, para entender o comportamento do consumidor ao decorrer do mês. Conforme ilustrado na Figura 2, a demanda apresenta flutuações frequentes.


Figura 2 – Demanda Real Escalonada: Arroz (Jan/2022 a Ago/2025)



Fonte: O autor (2026).

A Figura 3 evidencia uma concentração significativa das vendas nos primeiros dias de cada mês, especialmente entre os dias 1 e 10. Observa-se uma redução gradual do volume vendido ao longo do período mensal, indicando que o comportamento da demanda não ocorre de forma homogênea no tempo. Esse padrão sugere influência do ciclo de recebimento salarial sobre o consumo, contribuindo para a elevada dispersão observada nas séries temporais e para a dificuldade dos modelos baseados apenas em memória temporal em capturar adequadamente as oscilações da demanda.

Figura 3 – Distribuição Temporal das Vendas de Arroz por Dia do Mês



Fonte: O autor (2026).

Observa-se que aproximadamente 48% das vendas concentram-se nos dez primeiros dias do mês, com um novo leve aumento notado entre os dias 28 e 31. Esse comportamento sugere a existência de ciclos de abastecimento doméstico diretamente associados ao calendário de recebimento salarial, que ocorre predominantemente no início do mês, mas também no último dia útil para parte dos consumidores. Tal dinâmica é compatível com o comportamento esperado em produtos de consumo recorrente, nos quais as famílias tendem a realizar compras de reposição atreladas ao seu fluxo financeiro.


4.1.3 Perfil de Demanda: Cerveja

Assim como observado na série de arroz, o perfil de demanda da cerveja exibe volatilidade acentuada e natureza estocástica complexa. Como produto de oportunidade, sua série temporal é marcada por picos bruscos de consumo e forte amplitude de variação ao longo do período. Nesse sentido, ao utilizar o mesmo software que foi utilizado para a geração de gráficos do arroz, foi possível entender um pouco mais da volatilidade diária da bebida alcoólica.

A Figura 4 demonstra que a instabilidade é um traço intrínseco deste item. Na literatura e na prática varejista, assume-se que tal comportamento sofra influência de fatores exógenos, como variações climáticas, feriados, finais de semana e eventos regionais. No entanto, a inspeção visual da série não permite determinar isoladamente a contribuição de cada fator para as oscilações observadas, o que justifica a aplicação de modelos capazes de incorporar variáveis externas ao processo preditivo.

A complexidade observada nesta série reforça a necessidade de modelos que superem a simples memória temporal, buscando capturar padrões que variáveis latentes ou externas possam introduzir no sistema de demanda.

Figura 4 – Demanda Real Escalonada: Cerveja (Jan/2022 a Ago/2025)




Fonte: O autor (2026).

A Figura 5 apresenta a distribuição percentual das vendas de cerveja ao longo do mês. Diferentemente do comportamento observado para o arroz, nota-se uma distribuição mais homogênea entre os dias, sem concentração expressiva nos primeiros dez dias do mês. Esse comportamento sugere que a variável exógena *Efeito_Pagamento* possivelmente exerce influência limitada sobre o desempenho do modelo de Machine Learning para este produto.

Tal resultado é coerente com a natureza da cerveja como produto de oportunidade, cujo consumo tende a sofrer maior influência de fatores comportamentais e contextuais, como temperatura, finais de semana, feriados e eventos sociais, em detrimento do calendário de recebimento salarial.

Figura 5 – Distribuição Temporal das Vendas de Cerveja por Dia do Mês



Fonte: O autor (2026).

4.2 Média Móvel

Dando início à fase de modelagem, aplicou-se o modelo de Média Móvel Simples para as séries temporais do arroz e da cerveja. Por ser um modelo baseado exclusivamente na média de observações passadas recentes, ele assume que a demanda futura será uma réplica da média do passado recente, sem considerar fatores externos. Este modelo atua como o *baseline* do projeto, servindo como o nível mínimo de desempenho que os modelos mais complexos, como o de *Machine Learning*, devem superar. A ferramenta utilizada para criação do modelo foi o Excel.

As previsões foram avaliadas sobre o conjunto de teste, correspondente aos 30% finais da série temporal, conforme a estratégia *Out-of-Time* definida na metodologia. As janelas de 3, 7 e 15 dias foram escolhidas por representarem diferentes níveis de suavização da demanda. A janela de 3 dias permite maior resposta às variações recentes, a de 7 dias contempla um ciclo semanal completo e a de 15 dias oferece uma visão mais suavizada do comportamento da série, embora possa reduzir a capacidade do modelo de reagir rapidamente a mudanças bruscas.

Os resultados consolidados na Tabela 5 revelam o baixo desempenho preditivo deste método frente à alta volatilidade reportada.

Tabela 5 – Comparativo de Métricas de Erro: Médias Móveis (MM)

Produto	Modelo	MAE	RMSE	MAPE
Cerveja	MM3	718,50	903,35	72,27%
Cerveja	MM7	818,06	1066,41	60,74%
Cerveja	MM15	841,74	1100,74	64,77%
Arroz	MM3	36,33	51,07	67,69%
Arroz	MM7	38,39	51,89	77,21%
Arroz	MM15	47,63	60,17	90,29%

Fonte: O autor (2026).

Observa-se que o aumento da janela promove maior suavização da série da cerveja, reduzindo parcialmente o erro percentual médio (MAPE). Entretanto, os valores de MAE e RMSE permaneceram elevados, indicando que o modelo apresenta dificuldades para acompanhar as oscilações da demanda. Para a cerveja, a janela de 7 dias apresentou o menor MAPE, embora a janela de 3 dias tenha obtido menores valores de MAE e RMSE. Esse comportamento indica que a escolha do melhor modelo pode variar conforme a métrica considerada. Para o arroz, a menor margem de erro foi obtida na janela de 3 dias, sugerindo que a média móvel perde desempenho conforme amplia o horizonte de suavização, especialmente diante da variabilidade observada na série.

De acordo com Ballou (2006), quando a incerteza da variável é elevada a ponto de as técnicas comuns levarem a resultados insatisfatórios, torna-se imperativo o uso de outras modalidades de previsão. Com erros percentuais médios (MAPE) superiores a 60%, confirma-se que a média móvel é insuficiente para a gestão eficiente destes itens, sugerindo a necessidade de modelos capazes de capturar relações temporais e variáveis exógenas.

4.3 Holt-Winters

Após a avaliação do modelo de Média Móvel, aplicou-se o modelo de Holt-Winters, também conhecido como suavização exponencial tripla. Diferentemente da Média Móvel, esse método considera componentes de nível, tendência e sazonalidade, permitindo maior capacidade de adaptação a séries temporais com padrões recorrentes. Considerando que os dados possuem periodicidade diária, adotou-se sazonalidade semanal de 7 períodos, buscando capturar possíveis diferenças de comportamento entre dias úteis e finais de semana. As previsões foram avaliadas sobre o conjunto de teste, correspondente aos 30% finais da série temporal, conforme a estratégia *Out-of-Time* definida na metodologia.

Os parâmetros de suavização do modelo Holt-Winters, representados por α , β e γ , foram ajustados com o auxílio da ferramenta Solver do Microsoft Excel, utilizando o método GRG Não Linear. Esse procedimento foi adotado para evitar a escolha arbitrária dos coeficientes, permitindo identificar a combinação de parâmetros que minimizasse o erro de previsão no conjunto de treinamento. A otimização foi realizada impondo-se as restrições teóricas $0 \leq \alpha \leq 1$, $0 \leq \beta \leq 1$ e $0 \leq \gamma \leq 1$, conforme a formulação clássica dos modelos de suavização exponencial.

Tabela 6 – Parâmetros adotados no modelo Holt-Winters

Produto	α	β	γ	Sazonalidade
Cerveja	0,280	0,004	0,019	7
Arroz	0,325	0,0001	0,093	7

Fonte: O autor (2026).

Observa-se que os valores de α foram moderados em ambas as séries, indicando que o modelo atribuiu peso relevante às observações recentes. Os baixos valores de β são coerentes com a análise preliminar de tendência linear, a qual indicou baixo poder explicativo da passagem do tempo sobre a variação das vendas. Por sua vez, os valores reduzidos de γ indicam atualização suavizada do componente sazonal semanal.

Tabela 7 – Métricas de erro do modelo Holt-Winters

Produto	MAE	RMSE	MAPE
Cerveja	445,34	632,67	41,11%
Arroz	30,53	42,90	56,61%

Fonte: O autor (2026).

Os resultados obtidos com o modelo Holt-Winters são apresentados na Tabela 7. Observa-se que o modelo apresentou desempenho superior ao baseline de Média Móvel em ambos os produtos, indicando que a incorporação dos componentes de nível, tendência e sazonalidade contribuiu para uma melhor representação do comportamento temporal das séries.

Para a cerveja, o Holt-Winters reduziu o MAPE de 60,74%, obtido pela melhor configuração de Média Móvel, para 41,11%. Também houve redução expressiva nas métricas absolutas, com MAE de 445 e RMSE de 632,67. Esse resultado indica que o modelo foi capaz de capturar parte dos padrões temporais da série, embora o erro percentual ainda permaneça elevado diante da alta volatilidade do produto.

No caso do arroz, o Holt-Winters também apresentou melhora em relação à Média Móvel. O MAPE foi reduzido de 67,69%, obtido pela MM3, para 56,61%, enquanto o MAE passou de 36,33 para 30,53 e o RMSE de 51,07 para 42,90. Apesar da melhora, o erro percentual ainda se manteve elevado, sugerindo que a sazonalidade semanal incorporada pelo modelo não é suficiente para capturar integralmente os padrões intramensais observados anteriormente, como a concentração das vendas nos primeiros dias do mês.

4.4 Modelo de Machine Learning: Regressão Linear Dinâmica

Após a aplicação dos modelos de Média Móvel e Holt-Winters, avaliou-se o desempenho de um modelo de Machine Learning baseado em Regressão Linear Dinâmica. A variável dependente adotada foi a demanda escalonada, representada pela variável *Unidade_Vendida_Mascarada*. Como variáveis explicativas, foram consideradas informações relacionadas ao funcionamento da loja, calendário, preço, feriados, efeito pagamento, temperatura média e memória temporal da própria série.

Vale destacar que, durante o processo de seleção de variáveis, o sistema de classificação hierárquica de eventos (Tiers), desenvolvido tanto para eventos regionais quanto para partidas de futebol (detalhado na Seção 3.1.3), foi testado como variável explicativa adicional em ambos os modelos. Os testes empíricos indicaram, contudo, que a inclusão dessas variáveis piorava o desempenho preditivo em relação à especificação sem elas, tanto para o arroz quanto para a cerveja.

Na versão final do modelo para a categoria arroz, foram utilizadas as variáveis *Loja_fechada*, *Mês*, *Feriado*, *Preço*, *Vespera_Feriado*, *Efeito_Pagamento*, *Temperatura_Media*, *Lag_1*, *Dia_Semana* e *MM3*. A variável *Lag_1* foi construída a partir da defasagem de um período da própria demanda, incorporando ao modelo a informação referente às vendas do dia anterior, enquanto a variável *MM3* corresponde à média móvel dos três dias anteriores, permitindo suavizar oscilações de curto prazo na série temporal. Embora outras variáveis autorregressivas, como *Lag_7*, *MM7* e *MM15*, também tenham sido avaliadas durante a etapa de experimentação, a configuração final foi definida com base no desempenho preditivo obtido em cada produto. Para a categoria cerveja, a configuração final do modelo de regressão dinâmica também incorporou variáveis exógenas como clima, calendário e preço, mas com uma distinção importante na captura da inércia temporal. Diferentemente do arroz, o modelo para a cerveja demonstrou maior ganho preditivo ao utilizar a variável *Lag_7*, capturando a sazonalidade semanal completa, em substituição à média móvel de curto prazo (*MM3*), refletindo o comportamento de consumo associado a ocasiões específicas de lazer e eventos sociais. Essa especificação reforça a natureza estocástica distinta da série de cerveja, cuja demanda é menos dependente de ciclos de abastecimento mensal e mais sensível à recorrência semanal e às variações climáticas.

Tabela 8 – Variáveis selecionadas para os modelos de regressão linear.

Variável	Arroz	Cerveja
Loja_fechada	✓	✓
Mês	✓	✓
Feriado	✓	✓
Preço	✓	✓
Véspera_Feriado	✓	✓
Efeito_Pagamento	✓	✓
Temperatura_Media	✓	✓
Dia_Semana	✓	✓
Lag_1	✓	✓
Lag_7		✓
MM3	✓	

Fonte: Elaborado pelo autor (2026).

Para a implementação computacional dos modelos, utilizou-se a linguagem Python, em conjunto com bibliotecas amplamente empregadas em aplicações de ciência de dados e aprendizado de máquina. A manipulação e organização da base de dados foram realizadas com as bibliotecas *Pandas* e *NumPy*, enquanto a construção das representações gráficas foi desenvolvida com a *Matplotlib*. O treinamento do modelo de regressão linear e o cálculo das métricas de desempenho foram conduzidos por meio da biblioteca *Scikit-Learn* (*sklearn*), empregando a classe *LinearRegression* e as funções *mean_absolute_error*, *mean_squared_error* e *r2_score*. Para assegurar a reprodutibilidade do processo de modelagem e evitar inconsistências entre as etapas de treinamento e teste, o pré-processamento das variáveis foi estruturado com as classes *Pipeline*, *ColumnTransformer* e *OneHotEncoder*, responsáveis pelo tratamento das variáveis categóricas (*Mês* e *Dia_Semana*) por meio da codificação binária (*one-hot encoding*).

As variáveis categóricas *Mês* e *Dia_Semana* foram transformadas por meio de codificação *one-hot*, gerando as chamadas variáveis *dummies*. Essas variáveis funcionam como indicadores binários, assumindo o valor 1 se a observação pertence àquela categoria específica e 0 caso contrário. No modelo, utilizou-se a primeira categoria de cada atributo como referência para evitar a redundância perfeita entre elas. Dessa forma, o modelo pôde estimar efeitos específicos associados aos meses do ano e aos dias da semana, preservando a interpretação dos coeficientes da Regressão Linear Múltipla. As demais variáveis foram utilizadas em sua forma numérica ou binária, conforme sua natureza original.

As previsões foram avaliadas no conjunto de teste, respeitando a estratégia *Out-of-Time* adotada na metodologia. Para evitar vazamento de informação, todas as variáveis autorregressivas foram construídas exclusivamente com valores passados da demanda.

4.4.1 Regressão Linear Dinâmica: Arroz

Após a aplicação dos modelos de Média Móvel e Holt-Winters, avaliou-se o desempenho da Regressão Linear Dinâmica para a série de arroz. Esse modelo incorpora, além da memória temporal da própria série, variáveis explicativas relacionadas ao calendário, preço, temperatura, feriados, efeito pagamento e dia da semana. O objetivo foi verificar se a inclusão desses fatores externos contribuiria para melhorar a previsão da demanda em relação aos modelos puramente temporais.

As previsões foram realizadas sobre o conjunto de teste, correspondente aos 30% finais da série temporal, conforme a estratégia *Out-of-Time* adotada na metodologia. A Tabela 9 apresenta as métricas obtidas pelo modelo.

Tabela 9 – Métricas de erro da Regressão Linear Dinâmica para o arroz


Produto	MAE	RMSE	MAPE	R^2
Arroz	24,44	32,54	47,99%	0,6112

Fonte: O autor (2026).

Observa-se que a Regressão Linear Dinâmica apresentou desempenho superior aos modelos anteriormente avaliados para a série de arroz. Em comparação com a Média Móvel de 3 dias, que apresentou MAPE de 67,69%, e com o Holt-Winters, cujo MAPE foi de 56,61%, o modelo de Machine Learning reduziu o erro percentual médio para 47,99%. Também houve redução nas métricas absolutas, com MAE de 24,44 e RMSE de 32,54.

Esse resultado indica que a inclusão de variáveis explicativas contribuiu para uma melhor representação do comportamento da demanda. Embora o MAPE ainda permaneça elevado, a redução dos erros sugere que a demanda do arroz não é explicada apenas por padrões temporais simples, sendo influenciada também por fatores associados ao calendário e ao comportamento de compra dos consumidores.

Figura 6 – Previsão da Regressão Linear Dinâmica para o arroz no conjunto de teste



Fonte: O autor (2026).

Conforme ilustrado na Figura 6, o modelo conseguiu acompanhar parte das oscilações observadas na série real, especialmente em períodos de variação moderada. No entanto, ainda apresentou limitações na previsão de picos mais intensos de demanda, comportamento esperado em séries diárias de varejo com alta volatilidade e ocorrência de eventos pontuais.

A análise dos coeficientes estimados também contribuiu para a interpretação do comportamento da demanda. A Tabela 10 apresenta as variáveis com maior importância absoluta no modelo.


Tabela 10 – Principais coeficientes da Regressão Linear Dinâmica para o arroz

Variável	Coeficiente	Importância Absoluta
Dia_Semana_7	85,51	85,51
Dia_Semana_6	75,54	75,54
Dia_Semana_5	72,48	72,48
Dia_Semana_3	68,14	68,14
Dia_Semana_2	67,53	67,53
Dia_Semana_4	66,58	66,58
Loja_fechada	-65,70	65,70
Efeito_Pagamento	34,86	34,86
Mês_9	18,46	18,46
Feriado	-16,53	16,53

Fonte: O autor (2026).

Os coeficientes indicam forte influência das variáveis associadas ao dia da semana. Os maiores impactos positivos foram observados nos dias 7 e 6, sugerindo maior volume de vendas nos dias finais do ciclo semanal. Esse resultado é coerente com a distribuição percentual das vendas ao longo da semana, apresentada na Figura 7. Ressalta-se que, na codificação utilizada, os valores de 1 a 7 representam, respectivamente, domingo, segunda-feira, terça-feira, quarta-feira, quinta-feira, sexta-feira e sábado.

Figura 7 – Distribuição Percentual das Vendas de Arroz ao Longo da Semana



Fonte: O autor (2026).

Nota: Na codificação utilizada, os valores de 1 a 7 representam, respectivamente, domingo, segunda-feira, terça-feira, quarta-feira, quinta-feira, sexta-feira e sábado .

A Figura 7 evidencia aumento gradual da participação das vendas ao longo da semana, com maior concentração nos dias 6 e 7. Esse padrão sugere que parte das compras de arroz ocorre em períodos específicos da semana, possivelmente associados ao abastecimento doméstico realizado em dias de maior disponibilidade dos consumidores.

Além do padrão semanal, a variável *Efeito_Pagamento* apresentou coeficiente positivo relevante. Esse resultado reforça a análise descritiva apresentada anteriormente, na qual foi observada concentração expressiva das vendas de arroz nos primeiros dias do mês. Assim, o comportamento da demanda parece estar relacionado tanto a ciclos semanais de compra quanto ao calendário financeiro dos consumidores.

A variável *Loja_fechada* apresentou coeficiente negativo elevado, como esperado, uma vez que dias sem funcionamento reduzem diretamente o volume vendido. Por outro lado, a variável *Preço* apresentou coeficiente de baixa magnitude, sugerindo baixa influência do preço na previsão da demanda do arroz dentro da base analisada. Esse comportamento pode estar associado à natureza do produto, caracterizado como item de necessidade básica e consumo recorrente.

Apesar do melhor desempenho relativo da Regressão Linear Dinâmica, o MAPE de 47,99% ainda indica uma margem de erro elevada. Isso sugere que, embora o modelo tenha capturado melhor os padrões temporais e exógenos da série, parte da variabilidade da demanda permanece não explicada. Essa limitação pode estar associada a fatores não observados na base, como promoções pontuais, rupturas de estoque, compras em maior volume por parte dos consumidores ou características específicas do comportamento local de consumo.

Dessa forma, para a série de arroz, a Regressão Linear Dinâmica apresentou o melhor desempenho entre os modelos avaliados, superando a Média Móvel e o Holt-Winters. O resultado reforça a importância da incorporação de variáveis de calendário e efeito pagamento na previsão de produtos de consumo recorrente, especialmente quando a demanda apresenta padrões intramensais e semanais relevantes.

4.4.2 Regressão Linear Dinâmica: Cerveja

Para a série de cerveja, aplicou-se a Regressão Linear Dinâmica com o objetivo de avaliar se a inclusão de variáveis exógenas e autorregressivas contribuiria para melhorar a previsão da demanda. Considerando a natureza do produto, associado a consumo de oportunidade, lazer e eventos sociais, esperava-se que variáveis relacionadas ao calendário, dia da semana, temperatura e feriados apresentassem relevância na explicação das vendas.

As previsões foram avaliadas sobre o conjunto de teste, correspondente aos 30% finais da série temporal, conforme a estratégia *Out-of-Time* adotada na metodologia. A Tabela 11 apresenta as métricas obtidas pelo modelo.

Tabela 11 – Métricas de erro da Regressão Linear Dinâmica para a cerveja


Produto	MAE	RMSE	MAPE	R^2
Cerveja	430,90	557,98	37,70%	0,5334

Fonte: O autor (2026).

Observa-se que a Regressão Linear Dinâmica apresentou o melhor desempenho entre os modelos avaliados para a série de cerveja. Em comparação com a Média Móvel de 7 dias, que apresentou MAPE de 60,74%, e com o Holt-Winters, cujo MAPE foi de 41,11%, o modelo de Machine Learning reduziu o erro percentual médio para 37,70%. Também houve redução expressiva nas métricas absolutas, com MAE de 430,90 e RMSE de 557,98.

Esse resultado indica que a incorporação de variáveis explicativas contribuiu para melhorar a capacidade preditiva do modelo. Embora a demanda de cerveja permaneça altamente volátil, a inclusão de variáveis de calendário, temperatura, preço e memória temporal permitiu capturar parte dos padrões de consumo observados na série.

Figura 8 – Previsão da Regressão Linear Dinâmica para a cerveja no conjunto de teste



Fonte: O autor (2026).

Conforme apresentado na Figura 8, o modelo conseguiu acompanhar parte importante das oscilações da série real, especialmente os ciclos recorrentes de maior e menor demanda. Entretanto, ainda apresenta limitações na previsão de picos extremos, comportamento esperado em séries diárias de produtos com alta sensibilidade a fatores externos e eventos pontuais.

A análise dos coeficientes estimados permite compreender quais variáveis exerceram maior influência no modelo. A Tabela 12 apresenta os principais coeficientes em termos de importância absoluta.


Tabela 12 – Principais coeficientes da Regressão Linear Dinâmica para a cerveja

Variável	Coefficiente	Importância Absoluta
Loja_fechada	-6006,06	6006,06
Dia_Semana_7	1617,33	1617,33
Dia_Semana_6	1353,07	1353,07
Dia_Semana_5	807,25	807,25
Vespera_Feriado	614,05	614,05
Dia_Semana_4	586,65	586,65
Dia_Semana_3	530,45	530,45
Mês_12	503,76	503,76
Mês_10	292,35	292,35
Mês_9	285,52	285,52

Fonte: O autor (2026).

Os coeficientes indicam forte influência das variáveis associadas ao dia da semana. Os maiores impactos positivos foram observados nos dias 7, 6 e 5, indicando aumento relevante da demanda nos períodos finais da semana. Esse comportamento é coerente com a natureza da cerveja como produto de oportunidade, frequentemente associado ao consumo em momentos de lazer, confraternizações e finais de semana.

Figura 9 – Distribuição Percentual das Vendas de Cerveja ao Longo da Semana



Fonte: O autor (2026).

Nota: Na codificação utilizada, os valores de 1 a 7 representam, respectivamente, domingo, segunda-feira, terça-feira, quarta-feira, quinta-feira, sexta-feira e sábado .

A Figura 9 reforça esse comportamento ao evidenciar maior concentração percentual das vendas nos dias finais da semana. Esse padrão ajuda a explicar a elevada importância das variáveis *Dia_Semana* no modelo de Regressão Linear Dinâmica.

Além do padrão semanal, a variável *Vespera_Feriado* apresentou coeficiente positivo relevante, sugerindo aumento da demanda em dias anteriores a feriados. Esse resultado é compatível com o comportamento esperado para a cerveja, uma vez que feriados tendem a estar associados a encontros sociais, viagens, eventos e consumo antecipado.

A variável *Loja_fechada* apresentou coeficiente negativo elevado, como esperado, visto que dias sem funcionamento reduzem diretamente o volume vendido. A variável *Preço* apresentou coeficiente negativo, comportamento coerente com a teoria econômica da demanda, segundo a qual aumentos de preço tendem a reduzir a quantidade demandada, mantendo-se as demais condições constantes. Já a variável *Temperatura_Media* apresentou coeficiente positivo, indicando que temperaturas mais elevadas tendem a favorecer o consumo do produto.

Por outro lado, a variável *Efeito_Pagamento* apresentou influência relativamente menor quando comparada aos dias da semana e à véspera de feriado. Esse achado é coerente com a análise descritiva apresentada anteriormente, na qual a cerveja apresentou distribuição mais homogênea ao longo do mês, sem concentração expressiva nos primeiros dias. Dessa forma, para este produto, fatores ligados ao calendário semanal, feriados e condições climáticas parecem exercer maior influência do que o ciclo de recebimento salarial.

Apesar do melhor desempenho relativo, o MAPE de 37,70% ainda indica que parte da variabilidade da demanda permanece não explicada pelo modelo. Esse comportamento pode estar associado a fatores não observados na base, como promoções específicas, rupturas de estoque, ações da concorrência, eventos informais ou mudanças pontuais no comportamento dos consumidores.

Dessa forma, para a série de cerveja, a Regressão Linear Dinâmica apresentou o melhor desempenho entre os modelos avaliados, superando a Média Móvel e o Holt-Winters. O resultado reforça a importância da incorporação de variáveis exógenas e temporais na previsão de produtos de alta volatilidade e consumo associado a ocasiões específicas.

4.5 Síntese Comparativa dos Resultados

Após a aplicação dos modelos de Média Móvel, Holt-Winters e Regressão Linear Dinâmica, realizou-se uma comparação consolidada do desempenho preditivo obtido para os dois produtos analisados. A Tabela 13 apresenta a síntese das métricas de erro dos modelos avaliados.

Tabela 13 – Comparação final dos modelos de previsão avaliados

Produto	Modelo	MAE	RMSE	MAPE
Arroz	Média Móvel	36,33	51,07	67,69%
	Holt-Winters	30,53	42,90	56,61%
	Regressão Linear Dinâmica	24,44	32,54	47,99%
Cerveja	Média Móvel	818,04	1066,41	60,74%
	Holt-Winters	445,34	632,67	41,11%
	Regressão Linear Dinâmica	430,90	557,98	37,70%

Fonte: O autor (2026).

Nota: As métricas MAE e RMSE estão expressas na escala transformada dos dados, em razão do escalonamento linear aplicado para preservar a confidencialidade das informações. Por se tratarem de medidas estatísticas, os valores podem assumir casas decimais.

A análise comparativa evidencia que a Média Móvel apresentou o pior desempenho entre os modelos avaliados para ambos os produtos. Esse resultado era esperado, uma vez que o método considera apenas a média de observações passadas recentes, sem incorporar componentes de sazonalidade, tendência ou variáveis externas. Dessa forma, sua aplicação mostrou-se limitada diante da elevada volatilidade observada nas séries de arroz e cerveja.

O modelo Holt-Winters apresentou melhora expressiva em relação ao baseline. Para a cerveja, o MAPE foi reduzido de 60,74%, obtido pela melhor configuração de Média Móvel, para 41,11%. No caso do arroz, o erro percentual médio foi reduzido de 67,69% para 56,61%. Esses resultados indicam que a incorporação dos componentes de nível, tendência e sazonalidade contribuiu para uma melhor representação do comportamento temporal das séries. No entanto, os erros ainda permaneceram elevados, especialmente no arroz, sugerindo que apenas a sazonalidade semanal não foi suficiente para capturar integralmente os padrões de consumo observados.

A Regressão Linear Dinâmica apresentou o melhor desempenho geral entre os modelos avaliados. Para o arroz, o modelo obteve os menores valores de MAE, RMSE e MAPE, indicando que a inclusão de variáveis como dia da semana, efeito pagamento e memória temporal contribuiu para melhorar a previsão da demanda. Para a cerveja, o modelo também apresentou o menor erro percentual médio, reforçando a importância de variáveis associadas ao calendário semanal, vésperas de feriado, preço e temperatura no comportamento de consumo do produto.

Apesar do melhor desempenho da Regressão Linear Dinâmica, observa-se que os valores de MAPE ainda permanecem relativamente elevados. Esse resultado reforça a complexidade da previsão de demanda diária no varejo, especialmente em séries caracterizadas por alta volatilidade, picos de consumo, eventos não observados e fatores operacionais não registrados na base de dados. Portanto, os resultados não indicam a eliminação da incerteza, mas demonstram que a incorporação de variáveis exógenas e temporais pode reduzir os erros de previsão em relação aos modelos puramente baseados na memória histórica da série.

De forma geral, os resultados obtidos indicam que a adoção de modelos mais estruturados contribui para uma previsão mais precisa da demanda. A Média Móvel cumpriu adequadamente o papel de modelo de referência, o Holt-Winters apresentou ganhos relevantes ao incorporar componentes temporais, e a Regressão Linear Dinâmica mostrou-se a alternativa mais adequada no contexto analisado, ao combinar desempenho preditivo superior com interpretabilidade dos fatores que influenciam a demanda.

Esses resultados corroboram a literatura que aponta que a incorporação de variáveis exógenas e componentes autorregressivos tende a produzir previsões mais precisas do que métodos baseados exclusivamente no histórico da série, especialmente em ambientes varejistas sujeitos à elevada variabilidade da demanda.

5 Considerações Finais

O presente trabalho teve como objetivo avaliar diferentes métodos de previsão de demanda aplicados ao contexto varejista, utilizando dados reais de vendas de arroz e cerveja em um supermercado. Para isso, foram comparadas três abordagens em ordem crescente de complexidade: a Média Móvel, utilizada como modelo de referência; o Holt-Winters, empregado para capturar componentes de nível, tendência e sazonalidade; e a Regressão Linear Dinâmica, utilizada como modelo de *machine learning* interpretável, incorporando variáveis temporais e exógenas.

A análise descritiva inicial demonstrou que ambas as séries apresentaram elevada volatilidade, com coeficientes de variação próximos. Esse resultado foi particularmente relevante para o arroz, uma vez que, apesar de ser frequentemente tratado como produto de consumo recorrente e demanda relativamente estável, a série analisada apresentou comportamento bastante oscilatório. Observou-se ainda concentração expressiva das vendas de arroz nos primeiros dias do mês, sugerindo influência do ciclo de recebimento salarial e de compras de abastecimento doméstico.

No caso da cerveja, a análise evidenciou comportamento compatível com um produto de oportunidade, caracterizado por elevada amplitude de variação, picos de consumo e maior influência de fatores comportamentais e contextuais. A distribuição das vendas ao longo do mês mostrou-se mais homogênea do que a do arroz, indicando menor influência do efeito pagamento. Por outro lado, a análise semanal revelou maior concentração das vendas nos dias finais da semana, comportamento coerente com o consumo associado a lazer, encontros sociais e finais de semana.

A Regressão Linear Dinâmica apresentou o melhor desempenho geral, obtendo os menores valores de MAE, RMSE e MAPE para o arroz e para a cerveja. Esse resultado sugere que a inclusão de variáveis explicativas, como dia da semana, efeito pagamento, feriados, temperatura, preço e variáveis autorregressivas, contribuiu para melhorar a capacidade preditiva dos modelos. Ainda assim, os valores de MAPE permanecem elevados, evidenciando a complexidade da previsão de demanda diária em ambiente varejista, especialmente em séries com alta volatilidade e ocorrência de picos de consumo.

Em relação aos modelos avaliados, a Média Móvel apresentou o pior desempenho em ambos os produtos, confirmando sua limitação diante de séries altamente voláteis. Embora seja útil como modelo de referência, sua estrutura baseada apenas na média de observações passadas mostrou-se insuficiente para representar adequadamente as oscilações das séries. Para a cerveja, o melhor resultado entre as médias móveis foi obtido pela janela de 7 dias, com MAPE de 60,74%. Para o arroz, a janela de 3 dias apresentou o melhor desempenho, com MAPE de 67,69%.

O modelo Holt-Winters apresentou melhora significativa em relação à Média Móvel, demonstrando que a incorporação de componentes de nível, tendência e sazonalidade contribuiu para melhor representação temporal das séries. Para a cerveja, o MAPE foi reduzido para 41,11%, enquanto, para o arroz, o erro percentual médio caiu para 56,61%. Apesar da melhora, os resultados ainda indicaram limitações do modelo em capturar integralmente os padrões de demanda, especialmente diante de picos abruptos e efeitos intramensais, como a concentração das vendas de arroz no início do mês.

A Regressão Linear Dinâmica apresentou o melhor desempenho geral entre os modelos avaliados. Para o arroz, o modelo obteve MAE de 24,44, RMSE de 32,54, MAPE de 47,99% e R^2 de 0,6112. Para a cerveja, os resultados foram MAE de 430,90, RMSE de 557,98, MAPE de 37,70% e R^2 de 0,5334.

A análise dos coeficientes da Regressão Linear Dinâmica também forneceu importantes subsídios gerenciais. No arroz, as variáveis associadas ao dia da semana e ao efeito pagamento apresentaram influência relevante, reforçando a existência de padrões de compra relacionados ao calendário semanal e ao ciclo financeiro dos consumidores. Na cerveja, destacaram-se as variáveis associadas aos dias finais da semana, à véspera de feriado, à temperatura média e ao preço, comportamento coerente com a natureza do produto e com sua maior sensibilidade a fatores contextuais.

Um achado relevante do processo de feature engineering foi que o sistema de Tiers, apesar de conceitualmente coerente, não contribuiu para a melhoria do desempenho preditivo, tendo sido excluído da especificação final após testes empíricos. Esse resultado reforça a importância de validar estatisticamente hipóteses de negócio antes de assumi-las como boas features, e sugere que a granularidade da base disponível pode ser insuficiente para capturar esse efeito de forma robusta.

Além da comparação entre os modelos, os resultados obtidos evidenciam a relevância da previsão de demanda para o processo decisório das organizações varejistas. Conforme discutem [Fildes, Ma e Kolassa \(2022\)](#), as previsões subsidiam decisões nos níveis estratégico, tático e operacional, reforçando que ganhos de acurácia podem refletir em melhorias no planejamento e na gestão das operações.

Dessa forma, os resultados obtidos respondem à questão de pesquisa ao indicar que a aplicação de modelos quantitativos e de *machine learning*, especialmente quando enriquecidos com variáveis externas, pode aprimorar a precisão da previsão de demanda no varejo. Entretanto, os ganhos observados devem ser interpretados com cautela. Embora a Regressão Linear Dinâmica tenha apresentado o melhor desempenho, os valores de MAPE ainda permaneceram elevados, evidenciando a complexidade de prever séries diárias de vendas em ambiente varejista, marcadas por volatilidade, eventos não observados, comportamento heterogêneo dos consumidores e possíveis fatores operacionais não registrados.

Do ponto de vista prático, o estudo contribui ao demonstrar que modelos simples, embora úteis como referência inicial, podem ser insuficientes para apoiar decisões de compra e reposição em produtos com alta variabilidade. Esse comportamento está em consonância com as observações de [Fildes, Ma e Kolassa \(2022\)](#), que destacam que a demanda de produtos varejistas pode ser influenciada por diversos fatores externos, como condições climáticas, promoções e características do calendário. Dessa forma, a consideração dessas variáveis contribui para representar de maneira mais adequada a dinâmica da demanda.

Como limitações, destaca-se que o estudo foi realizado com dados de apenas uma empresa e com duas categorias de produtos, o que restringe a generalização dos resultados para outros contextos varejistas. Além disso, algumas variáveis potencialmente relevantes, como promoções específicas, ações da concorrência, rupturas de estoque, campanhas internas e fluxo diário de clientes, não estavam disponíveis na base de dados. Tais fatores podem explicar parte da variabilidade não capturada pelos modelos.

Para trabalhos futuros, recomenda-se ampliar a base de produtos analisados, incorporar novas variáveis operacionais e comerciais, avaliar diferentes horizontes de previsão e testar modelos adicionais de aprendizado de máquina, como Random Forest, XGBoost e redes neurais, desde que haja volume de dados suficiente para treinamento e validação. Também seria relevante comparar previsões diárias e agregadas semanalmente ou mensalmente, a fim de verificar se a agregação temporal reduz a volatilidade e melhora a utilidade gerencial dos modelos.

Conclui-se, portanto, que a previsão de demanda baseada em dados constitui uma ferramenta relevante para a gestão de estoques no varejo. No caso analisado, a Regressão Linear Dinâmica apresentou o melhor equilíbrio entre desempenho preditivo e interpretabilidade, mostrando-se uma alternativa viável para apoiar decisões de compra, reposição e planejamento operacional em supermercados.

Referências

- BALLOU, R. H. **Gerenciamento da Cadeia de Suprimentos / Logística Empresarial**. 5. ed. Porto Alegre: Bookman, 2006. ISBN 978-8536305912.
- FILDES, R.; MA, S.; KOLASSA, S. Retail forecasting: Research and practice. **International Journal of Forecasting**, Elsevier, v. 38, p. 1283–1318, 2022.
- FISHER, M.; RAMAN, A. Using data and big data in retailing. **Production and Operations Management**, Wiley Online Library, v. 27, n. 9, p. 1665–1669, 2018.
- GÉRON, A. **Mãos à Obra com Scikit-Learn, Keras & TensorFlow**. 2. ed. Rio de Janeiro: Alta Books, 2019.
- GIL, A. C. **Como elaborar projetos de pesquisa**. 4. ed. São Paulo: Atlas, 2002.
- GUJARATI, D. N.; PORTER, D. C. **Econometria Básica**. 5. ed. Porto Alegre: AMGH, 2011.
- HYNDMAN, R. J.; ATHANASOPOULOS, G. **Forecasting: Principles and Practice**. 3. ed. Melbourne: OTexts, 2021. Disponível em: <<https://otexts.com/fpp3/>>. Acesso em: 16 out. 2025.
- JAMES, G.; WITTEN, D.; HASTIE, T.; TIBSHIRANI, R. **An Introduction to Statistical Learning: with Applications in R**. New York: Springer, 2013. v. 103. (Springer Texts in Statistics, v. 103).
- NELLESSEN, L. M.; SANTOS, H. V. d. C.; SOUZA, R. M. d.; MACHADO, R. R. G.; PEREIRA, R. B. D. Teste e aplicação de diferentes modelos preditivos na previsão de demanda de uma loja varejista. In: **Anais do XLV Encontro Nacional de Engenharia de Produção**. Natal, RN: ABEPRO, 2025.
- PINDYCK, R. S.; RUBINFELD, D. L. **Microeconomia**. 6. ed. São Paulo: Prentice Hall, 2006.
- SILVA, G. M. d.; VIEIRA, M. J.; PELEGRINA, G. D. Uma abordagem integrada para analisar a eficiência na previsão de demanda e na gestão de estoque com ferramentas de ciência de dados. In: ENEGEP. **Anais do XLV Encontro Nacional de Engenharia de Produção**. Natal, RN, 2025. p. 1–15.
- SLACK, N.; BRANDON-JONES, A.; JOHNSTON, R. **Administração da Produção**. 8. ed. São Paulo: Atlas, 2018.
- STEVENSON, W. J. **Operations Management**. 12. ed. New York: McGraw-Hill Education, 2015.
- TUBINO, D. F. **Planejamento e Controle da Produção: Teoria e Prática**. 3. ed. São Paulo: Atlas, 2007.

Glossário

Aprendizado Supervisionado Ramo do *machine learning* em que o algoritmo é treinado em um conjunto de dados que já contém as respostas corretas (variável-alvo), aprendendo a mapear as relações entre as variáveis explicativas e a saída para prever eventos futuros.

Baseline (Modelo de Referência) Modelo preditivo simples (como a Média Móvel) utilizado como ponto de partida e padrão mínimo de comparação. O desempenho de modelos mais complexos deve, obrigatoriamente, ser superior ao *baseline* para justificar sua implementação.

Efeito Lag (Atraso/Inércia) Fenômeno observado em modelos preditivos mais simples, onde o algoritmo responde de forma lenta a mudanças recentes ou tendências nos dados, gerando previsões sistematicamente atrasadas em relação à realidade observada.

Feature Engineering (Engenharia de Variáveis) Processo de utilização de conhecimento de domínio para extrair, criar e transformar variáveis (como criar categorias para eventos esportivos ou sinalizar a proximidade de feriados) a fim de melhorar o desempenho dos algoritmos preditivos.

Machine Learning (Aprendizado de Máquina) Campo da inteligência artificial focado no desenvolvimento de algoritmos capazes de aprender padrões de forma autônoma a partir de grandes volumes de dados, sem serem explicitamente programados com regras fixas para aquela tarefa.

MAPE (Mean Absolute Percentage Error) Métrica que expressa o erro percentual médio das previsões. Em aplicações práticas de varejo, a lógica de cálculo dessa métrica exige a exclusão formal de datas em que a loja estava fechada para evitar erros matemáticos de divisão por zero que distorceriam a avaliação do modelo.

Out-of-Time (OOT) Estratégia de validação de modelos preditivos que preserva a ordem cronológica dos dados. O conjunto de dados é dividido no tempo, utilizando o passado para treinar o algoritmo e um período futuro inédito para testá-lo, evitando o vazamento de informações (*data leakage*).

Overfitting (Sobreajuste) Ocorre quando um modelo estatístico ou de *machine learning* se ajusta excessivamente aos dados de treinamento, aprendendo inclusive os ruídos e aleatoriedades da amostra. Consequentemente, o modelo perde a sua capacidade de generalização, falhando ao realizar previsões em dados novos.

Séries Temporais Conjunto de observações de uma variável coletadas sequencialmente em intervalos regulares de tempo (ex: demanda diária).

Tiers (Níveis/Camadas) Sistema de classificação hierárquica criado para quantificar dados qualitativos. No estudo, foi utilizado para categorizar a magnitude do impacto socioeconômico de eventos regionais e partidas de futebol.

Variáveis Exógenas Variável explicativa que tem origem externa, ou seja, cujo valor é determinado fora do sistema ou ambiente modelado. São fatores independentes do processo produtivo em si, como precipitação, temperatura e calendário de feriados.

White Box (Caixa-Branca) Modelos e algoritmos cujos processos matemáticos internos e lógicas de decisão são transparentes, interpretáveis e rastreáveis. Permitem aos gestores compreender exatamente como cada variável de entrada afeta a previsão final.