

UNIVERSIDADE ESTADUAL PAULISTA - UNESP
Instituto de Ciência e Engenharia - Campus de Itapeva

LÍVIA ALMEIDA ITOHARA

PREVISÃO DE DEMANDA NA PRODUÇÃO DE PÃO FRANCÊS:

Um estudo de caso em uma padaria de supermercado

Itapeva – SP

2026

LÍVIA ALMEIDA ITOHARA

**PREVISÃO DE DEMANDA NA PRODUÇÃO DE PÃO FRANCÊS:
Um estudo de caso em uma padaria de supermercado**

Trabalho de Conclusão de Curso
apresentado à Universidade Estadual
Paulista (UNESP), Instituto de Ciências e
Engenharia, Campus de Itapeva, para
obtenção do título de Bacharel(a) em
Engenharia de Produção.

Orientador(a): Prof. Dr. Marcel Yuzo
Kondo

Itapeva - SP

2026

189p

Itohara, Livia Almeida

Previsão de demanda na produção de pão francês: : um estudo de caso em uma padaria de supermercado / Livia Almeida Itohara. -- Itapeva, 2026

62 p. : il., tabs.

Trabalho de conclusão de curso (Bacharelado - Engenharia de Produção) - Universidade Estadual Paulista (UNESP), Instituto de Ciências e Engenharia, Itapeva

Orientador: Marcel Yuzo Kondo

1. Planejamento da produção. 2. Produtos perecíveis. 3. Previsão. 4. Demanda. 5. Engenharia de produção. I. Título.

LIVIA ALMEIDA ITOHARA

PREVISÃO DE DEMANDA NA PRODUÇÃO DE PÃO FRANCÊS:
um estudo de caso em uma padaria de supermercado

Trabalho de Conclusão de Curso para obtenção do título de Bacharel em Engenharia de Produção, da Universidade Estadual Paulista - UNESP - Campus de Itapeva.

BANCA EXAMINADORA

Documento assinado digitalmente
 **MARCEL YUZO KONDO**
Data: 30/06/2026 14:37:03-0300
Verifique em <https://validar.iti.gov.br>

Orientador: Prof. Dr. Marcel Yuzo Kondo
Universidade Estadual Paulista - UNESP - Campus de Itapeva.

Documento assinado digitalmente
 **RICARDO GHANTOUS CERVI**
Data: 30/06/2026 15:34:07-0300
Verifique em <https://validar.iti.gov.br>

2º Examinador: Prof. Dr. Ricardo Ghantous Cervi
Universidade Estadual Paulista - UNESP - Campus de Itapeva.

Documento assinado digitalmente
 **BRUNO SANTOS FERREIRA**
Data: 01/07/2026 14:56:55-0300
Verifique em <https://validar.iti.gov.br>

3º Examinador: Prof. Dr. Bruno Santos Ferreira
Universidade Estadual Paulista - UNESP - Campus de Itapeva.

Itapeva, 20/06/2026.

Dedico este trabalho aos meus pais e
minha irmã, que não mediram esforços
para me ver chegar aqui.

AGRADECIMENTOS

Assim como tudo na minha vida, a decisão de mudar de rota e seguir na engenharia de produção foi acolhida e apoiada pelas pessoas que mais amo: minha família. Agradeço à todos aqueles que vibraram com a minha aprovação, comemoraram minhas conquistas e sempre me incentivaram a crescer, evoluir e voar. Graças ao apoio de vocês, eu pude realizar meu sonho de me graduar pela Universidade Estadual Paulista "Júlio de Mesquita Filho".

À minha mãe, Camila, por me ensinar diariamente a ser uma mulher forte, sem perder a empatia e a sensibilidade. Com você eu aprendi a sempre me dedicar com amor às coisas importantes para mim. Obrigada por sempre estar cuidando de mim, seja de perto ou de longe.

Ao meu pai, Ricardo, por me ensinar, desde pequena, a importância do conhecimento, da curiosidade e da busca constante por aprendizado. E por ter me ensinado a sempre escolher o que eu quero e não aceitar qualquer coisa.

À minha irmã, Thamires, que desde sempre foi minha maior inspiração. Obrigada pela parceria ao longo da vida, pela presença constante nos momentos mais importantes da minha vida. Seu apoio e confiança fizeram e fazem toda diferença para mim.

Ao meu namorado, Leonardo, por compartilhar a sua vida comigo e tornar a minha mais leve. Obrigada pelo apoio, paciência e compreensão durante o desenvolvimento desse trabalho e da graduação. Obrigada por enxergar em mim um potencial que, muitas vezes, eu mesma não consigo reconhecer.

Aos meus amigos que fiz ao longo dessa caminhada, Emanuelle, Manuela, Julianne, Julia, Tiago, Cauã, Gustavo e Giuliano que fizeram de Itapeva um lar e foram minha família durante esses anos. E também aos outros que fizeram parte da minha trajetória e deixaram essa jornada mais especial.

Aos professores do ICE, por todo o conhecimento compartilhado e por contribuírem não apenas para minha formação acadêmica, mas também para o meu desenvolvimento e formação como profissional. Em especial ao meu orientador, Marcel Yuzo Kondo, pela mentoria, trocas e contribuições dentro das salas de aula e durante o desenvolvimento do meu trabalho de conclusão de curso.

Obrigada.

“Aprendizagem não é obrigatória; é voluntária. Mas, para sobreviver, devemos aprender.”

W. Edwards Deming

RESUMO

Este trabalho tem como objetivo aplicar e comparar métodos quantitativos de previsão de demanda na produção de pão francês em uma padaria de supermercado, com o intuito de identificar a abordagem mais adequada para apoiar o planejamento da produção e reduzir desperdícios e rupturas de estoque. A pesquisa caracteriza-se como um estudo de caso de natureza aplicada, com abordagem quantitativa, utilizando dados históricos de vendas coletados entre abril e agosto de 2026, complementados por informações sobre variáveis como dia da semana, período de venda e temperatura ambiente. Foram aplicados diferentes métodos de previsão, incluindo Média Móvel Simples, Suavização Exponencial Simples, método de Holt, modelo de Holt-Winters e Regressão Linear Múltipla. O desempenho dos modelos foi avaliado com base nas métricas de erro MAE, RMSE e MAPE. Os resultados indicaram que a demanda apresenta comportamento influenciado principalmente por fatores temporais, como dia da semana e período do dia, evidenciando a presença de sazonalidade semanal. Entre os modelos analisados, o método de Holt apresentou o melhor desempenho geral, demonstrando maior capacidade de representar a dinâmica da demanda. Conclui-se que a aplicação de métodos quantitativos contribui significativamente para a melhoria do processo de tomada de decisão, permitindo um planejamento mais eficiente da produção em ambientes com elevada variabilidade, como no caso de produtos perecíveis.

Palavras-chave: previsão de demanda; produtos perecíveis; planejamento de produção; varejo alimentar.

ABSTRACT

This study aims to apply and compare quantitative demand forecasting methods in the production of French bread in a supermarket bakery, in order to identify the most appropriate approach to support production planning and reduce waste and stockouts. The research is characterized as a case study of an applied nature, with a quantitative approach, using historical sales data collected between April and August 2026, complemented by variables such as day of the week, sales period, and ambient temperature. Different forecasting methods were applied, including Simple Moving Average, Simple Exponential Smoothing, the Holt method, the Holt-Winters model, and Multiple Linear Regression. The performance of the models was evaluated based on the error metrics MAE, RMSE, and MAPE. The results indicated that demand behavior is mainly influenced by temporal factors, such as day of the week and time of day, evidencing the presence of weekly seasonality. Among the evaluated models, the Holt method presented the best overall performance, demonstrating greater capacity to represent the dynamics of demand. It is concluded that the application of quantitative methods significantly contributes to improving the decision-making process, enabling more efficient production planning in environments with high variability, such as perishable product operations.

Keywords: demand forecasting; perishable products; production planning; food retail.

SUMÁRIO

1. INTRODUÇÃO	15
1.1. Objetivos	16
2. REVISÃO BIBLIOGRÁFICA	16
2.1. Gestão da Demanda	17
2.2. Gestão e Produção de Produtos Perecíveis	17
2.3. Padarias em Supermercados	18
2.4. Previsão de demanda	19
2.4.1. Média Móvel Simples (MMS)	20
2.4.2. Suavização Exponencial Simples (SES)	21
2.4.3. Suavização Exponencial Dupla (Modelo de Holt)	21
2.4.4. Suavização Exponencial Tripla (Holt-Winters)	22
2.5. Regressão Linear	23
2.6. Erros de previsão	25
3. METODOLOGIA	28
3.1. Caracterização da pesquisa	28
3.2. Caracterização da empresa e do produto	28
3.3. Coleta de dados	29
3.4. Tratamento dos dados	29
3.5. Análise exploratória dos dados	30
3.6. Definição dos modelos de previsão	31
3.7. Aplicação dos Modelos	31
3.8. Avaliação dos Modelos	31
3.9. Limitação da Pesquisa	32
4. RESULTADOS E DISCUSSÕES	33
4.1. Cenário atual	33
4.2. Análise Exploratória dos dados	33
4.2.1. Estatística Descritiva	33
4.2.2. Distribuição dos Dados	38
4.2.3. Análise por Boxplots	40
4.2.4. Testes Estatísticos	45
4.3. Modelos de previsão e Erros	49
4.3.1. Média Móvel Simples (MMS):	49
4.3.2. Suavização Exponencial Simples (SES):	51
4.3.3. Holt	53
4.3.4. Holt-Winters	54
4.3.5. Regressão linear	56
4.4. Comparação dos resultados	58
5. CONCLUSÃO	59
5.1. Comparação final e método recomendado	60

5.2. Implicações gerenciais para o planejamento da produção	60
5.3. Sugestões para trabalhos futuros	61
5.4. Fechamento final	61
6. REFERÊNCIAS	62

1. INTRODUÇÃO

O contexto atual de elevada competitividade entre organizações e a busca por maior eficiência operacional tem impulsionado empresas a adotarem processos de tomada de decisão cada vez mais orientados por dados. Nesse cenário, a previsão de demanda assume papel estratégico ao apoiar o planejamento da produção, gestão de estoques e otimização de recursos. Esses métodos, a partir de análises do histórico, permitem estimar o volume de vendas futuro, contribuindo para decisões mais assertivas quanto à quantidade a ser produzida, reduzindo incertezas e minimizando impactos decorrentes do erro no planejamento.

A relevância da previsão de demanda torna-se ainda mais evidente em operações que trabalham com produtos perecíveis, em que a necessidade de equilíbrio entre oferta e demanda representa um desafio operacional constante. A limitada vida útil desses produtos exige maior precisão nas decisões relacionadas à quantidade produzida e disponibilizada para consumo, uma vez que erros de previsão podem ocasionar desperdícios, perdas financeiras e rupturas de estoque (Slack; Chambers; Johnston, 2009). Portanto, a previsão de demanda assume papel fundamental no planejamento da produção e das vendas, em especial dos pequenos empreendimentos que precisam ser cada vez mais competitivos.

O varejo alimentar apresenta elevada complexidade devido à grande variabilidade do comportamento de consumo, influenciado por fatores como sazonalidade, períodos do dia, hábitos dos consumidores e condições climáticas. Entre os processos mais sensíveis a essas oscilações destacam-se as padarias inseridas em supermercados, que demandam decisões frequentes e de curto prazo sobre a quantidade ideal de produtos a ser preparada ao longo do dia. Em muitos casos, os produtos são adquiridos pré-processados e apenas finalizados no local sendo assados no forno, o que torna o planejamento da produção diretamente dependente do comportamento da demanda. Nesse contexto, fatores como períodos, dias da semana, sazonalidade e temperatura ambiente podem influenciar o volume de consumo.

Diante disso, os métodos quantitativos de previsão apresentam-se como alternativas relevantes para apoiar o planejamento operacional e auxiliar na redução de desperdícios. Modelos matemáticos de séries temporais são amplamente utilizados para identificar padrões históricos de consumo e gerar previsões que

auxiliam no planejamento da produção e no controle operacional. Além disso, a incorporação de variáveis externas, como temperatura ambiente, pode ampliar a capacidade analítica dos modelos e melhorar a precisão das previsões.

Apesar de o presente estudo estar concentrado na produção de pão francês em uma padaria de supermercado, a metodologia proposta apresenta potencial de aplicação em diferentes contextos organizacionais que enfrentam desafios semelhantes relacionados à gestão de produtos e à variabilidade da demanda. Dessa forma, o trabalho busca contribuir não apenas para a realidade operacional da empresa analisada, mas também para discussões sobre a aplicação de modelos quantitativos de previsão como ferramentas de apoio à tomada de decisão.

Diante desse contexto, o presente trabalho busca responder ao seguinte problema de pesquisa: como modelos quantitativos de previsão de demanda podem ser aplicados à produção de pão francês em uma padaria de supermercado, considerando a influência de fatores como dia da semana, período de venda, mês e temperatura de modo a reduzir desperdícios e minimizar rupturas de estoque?

1.1. Objetivos

O objetivo deste trabalho é aplicar métodos de previsão de demanda à produção de pão francês em uma padaria de supermercado, utilizando dados históricos de vendas, análise de padrões de consumo e variáveis externas, a fim de identificar o método mais adequado e contribuir para o planejamento da produção e do processo de tomada de decisão.

Os objetivos específicos são:

- Realizar o tratamento e organização dos dados históricos de vendas;
- Realizar análise exploratória para identificação de padrões e influências no comportamento da demanda;
- Avaliar a influência das variáveis explicativas nas quantidades de venda;
- Aplicar e comparar diferentes métodos quantitativos de previsão de demanda;
- Avaliar o desempenho dos modelos com base em métricas de erro;
- Propor o método mais adequado no planejamento da produção.

2. REVISÃO BIBLIOGRÁFICA

2.1. Gestão da Demanda

A gestão da demanda pode ser compreendida como um conjunto de processos organizacionais voltados à compreensão, planejamento e atendimento das necessidades dos consumidores, buscando alinhar a capacidade operacional com o comportamento do mercado. Segundo Corrêa e Corrêa (2012), a gestão da demanda desempenha papel estratégico no planejamento das operações, auxiliando na tomada de decisões relacionadas à produção, compras, estoques e distribuição.

A demanda apresenta variabilidade decorrente de fatores internos e externos às organizações, como sazonalidade, condições econômicas, ações promocionais, hábitos de consumo e variáveis ambientais. De acordo com Slack, Chambers e Johnston (2009), a compreensão dessas influências é fundamental para reduzir incertezas e melhorar a eficiência do planejamento operacional.

Nesse contexto, a previsão de demanda destaca-se como uma das principais ferramentas de apoio à gestão da demanda. Conforme Makridakis, Wheelwright e Hyndman (1998), a previsão corresponde ao processo de estimar valores futuros com base na análise de dados históricos e na identificação de padrões de comportamento. Embora não elimine completamente as incertezas inerentes ao mercado, sua utilização permite reduzir riscos e melhorar a qualidade das decisões gerenciais.

Dessa forma, a gestão da demanda pode ser entendida como um processo integrado que envolve o monitoramento do comportamento dos consumidores, a análise de dados históricos e a utilização de técnicas de previsão para apoiar o planejamento das operações. Sua aplicação adequada contribui para a melhoria do desempenho organizacional, redução de custos e aumento da capacidade de resposta às necessidades do mercado.

2.2. Gestão e Produção de Produtos Perecíveis

A relevância da gestão da demanda torna-se ainda mais evidente em operações que trabalham com produtos perecíveis. Esses produtos, caracterizados

pela curta vida útil e elevada sensibilidade às condições de armazenamento e comercialização, exigem maior precisão no planejamento da produção e dos estoques. Segundo Slack, Chambers e Johnston (2009), falhas no gerenciamento de produtos perecíveis podem resultar em desperdícios, perdas financeiras, rupturas de estoque e redução da satisfação dos consumidores.

De acordo com Ballou (2006), a eficiência na gestão de estoques de produtos perecíveis depende diretamente da capacidade de antecipar a demanda e sincronizar os fluxos de abastecimento e produção. Assim, a utilização de métodos de previsão torna-se uma ferramenta importante para reduzir incertezas e apoiar a tomada de decisão em ambientes caracterizados por elevada variabilidade de consumo.

Assim, organizações que comercializam produtos perecíveis precisam desenvolver mecanismos capazes de alinhar produção e demanda de forma contínua, buscando assegurar a disponibilidade dos produtos ao consumidor e minimizar desperdícios decorrentes de erros de planejamento.

2.3. Padarias em Supermercados

As padarias inseridas em supermercados representam uma operação que une gestão da demanda com as particularidades da comercialização de produtos perecíveis. Segundo Parente (2014), a ampliação do mix de produtos e serviços oferecidos pelos supermercados transformou as padarias internas em importantes diferenciais competitivos, contribuindo para a atração e fidelização dos consumidores.

Diferentemente das padarias tradicionais, muitos desses estabelecimentos adotam modelos parcialmente industrializados, nos quais os produtos são adquiridos pré-processados ou congelados e são finalizados no próprio estabelecimento nos fornos. Esse formato permite maior padronização e redução da complexidade produtiva, mantendo características valorizadas pelos consumidores, como frescor e crocância.

Apesar dessas vantagens operacionais, as padarias em supermercados enfrentam desafios significativos relacionados ao planejamento da produção. Além

das limitações impostas pela perecibilidade, a demanda desses produtos costuma apresentar elevada variabilidade em função de fatores como sazonalidade, hábitos de consumo, dias da semana, horários de maior movimento e condições climáticas. Portanto, torna-se necessário definir continuamente a quantidade ideal a ser preparada ao longo do dia, evitando tanto desperdícios quanto rupturas de estoque.

Essa variabilidade exige maior precisão no planejamento operacional e reforça a importância da utilização de ferramentas capazes de antecipar o comportamento da demanda. Dessa forma, a aplicação de métodos de previsão de demanda apresenta potencial para apoiar o processo de tomada de decisões em padarias inseridas em supermercados, contribuindo para o aumento da eficiência operacional.

2.4. Previsão de demanda

A previsão de demanda consiste no processo de estimar o consumo futuro de produtos ou serviços com base na análise de dados históricos, padrões de comportamento e variáveis relacionadas ao mercado. De acordo com Mentzer (2004), a previsão de demanda não se limita apenas a extrapolar dados passados; ela envolve a análise criteriosa de tendências, fatores sazonais, flutuações econômicas e eventos específicos do setor que possam afetar as necessidades dos clientes.

Além disso, autores como Chopra e Meindl (2011), ressaltam que a previsão de demanda é um elemento essencial para o planejamento estratégico das empresas, uma vez que influencia diretamente o nível de serviço ao cliente, a gestão de estoques, a alocação de recursos e, por conseguinte, o desempenho financeiro da organização. Portanto, a habilidade de prever com precisão a demanda é um fator crítico de sucesso na gestão de operações e na busca pela satisfação dos clientes.

As previsões de demanda são variadas em termos de técnicas, cada uma com seu grau de precisão e custos associados. De modo geral, os métodos quantitativos utilizam modelos estatísticos e matemáticos aplicados a dados históricos para estimar valores futuros, sendo amplamente utilizados em contextos caracterizados por elevada variabilidade de consumo. Esses modelos permitem

identificar padrões, tendências e oscilações presentes nas séries temporais, fornecendo suporte às decisões operacionais.

As séries temporais representam conjuntos de dados observados ao longo do tempo e constituem a principal base para os modelos quantitativos de previsão. Segundo Morettin e Toloi (2006), a análise de séries temporais busca compreender o comportamento histórico dos dados por meio da identificação de componentes como tendência, sazonalidade, ciclos e variações aleatórias. A tendência está relacionada ao comportamento de crescimento ou redução da demanda ao longo do tempo, enquanto a sazonalidade refere-se às oscilações recorrentes observadas em períodos específicos.

Dessa forma, a compreensão desses componentes é fundamental para a seleção e aplicação adequada dos métodos de previsão. A seguir, são apresentados alguns dos principais métodos quantitativos utilizados na literatura para previsão de demanda.

2.4.1. Média Móvel Simples (MMS)

Esse modelo é o mais simples de todos os métodos quantitativos e é mais indicado para demandas estáveis, com baixa presença de sazonalidade ou quando aplicado a série previamente segmentada. A média móvel simples faz a previsão da demanda a partir de “n” dados de períodos anteriores. Segundo Tubino (2007), os modelos baseados em médias são úteis para reduzir as variações aleatórias nos dados históricos, e suavizam os valores extremos ao proporcionar uma previsão com menor variabilidade. A Equação (1) é utilizada para o cálculo das médias móveis simples.

$$MMS = \frac{\sum_{i=1}^n D_i}{n} \quad (1)$$

Onde,

MMS = Média Móvel Simples de n períodos;

D_i = demanda no período i;

n = número de períodos;

i = índice do período ($i= 1,2,3,\dots$).

Apesar de sua facilidade de implementação, o método apresenta limitações em cenários com mudanças bruscas na demanda, pois atribui o mesmo peso para todos os períodos analisados.

2.4.2. Suavização Exponencial Simples (SES)

O Modelo de Suavização Exponencial Simples é uma técnica de previsão amplamente empregada na análise de séries temporais. Conforme apontado por Ballou (2006), essa abordagem oferece uma constante “ α ” para suavizar variações em dados temporais, com foco na identificação de tendências e padrões subjacentes. O modelo se baseia no princípio de que as observações mais recentes recebem maior peso na previsão, refletindo o pressuposto de que eventos mais recentes são mais representativos do comportamento futuro.

A principal vantagem desse método está em sua capacidade de responder rapidamente às alterações na demanda sem desconsiderar completamente os dados passados. A Equação (2) que representa esse método é apresentada a seguir:

$$F_{t+1} = F_t + \alpha(Y_t - F_t) \quad (2)$$

Onde:

F_{t+1} = Previsão para o período $t + 1$;

F_t = Previsão para o período t ;

α = Constante de suavização, que recebe um valor entre 0 e 1;

Y_t = Valor observado para o período t .

O valor da constante de suavização influencia diretamente a sensibilidade do modelo às variações recentes da demanda, quanto mais próximo de 1, maior é o peso atribuído aos períodos mais recentes da série, o que possibilita o modelo responder mais rápido às mudanças.

2.4.3. Suavização Exponencial Dupla (Modelo de Holt)

O modelo de Holt é utilizado em previsões onde os dados apresentam tendência linear e não apresentam sazonalidade. De acordo com Holt (1957), esse método utiliza duas constantes de suavização, α e β , com valores variando entre 0 e 1. As Equações (3, 4 e 5) são utilizadas nesse método.

$$B_t = \alpha D_t + (1 - \alpha)(B_{t-1} + T_{t-1}) \quad (3)$$

$$T_t = \beta(B_t - B_{t-1}) + (1 - \beta)T_{t-1} \quad (4)$$

$$F_t(t + k) = B_t + kT_t \quad k = 1, 2, \dots \quad (5)$$

Onde,

D_t = demanda no período t ;

B_t = base ao final do instante t;

T_t = tendência ao final do instante t;

α = constante de suavização para Base;

β = constante de suavização para Tendência;

$F_t(u)$ = previsão ao final do período t para o período u ($u > t$).

A primeira equação é a equação de nível, utilizada para calcular uma média ponderada entre a demanda real e a nova. A segunda é a equação de tendência, tem como base a variação nos dois últimos períodos e a estimativa anterior. A última equação é a de previsão que fornece a previsão de demanda para “k” períodos adiante.

2.4.4. Suavização Exponencial Tripla (Holt-Winters)

Nesse modelo, Winters (1960) introduziu o componente de sazonalidade aos dados da série temporal, expandindo o modelo original proposto por Holt (1957). Holt-Winters é utilizado em séries que apresentam simultaneamente tendência e sazonalidade, especialmente quando esses padrões se mostram estáveis ao longo do tempo. Por isso, é amplamente aplicado em problemas de previsão no varejo devido à sua capacidade de representar padrões recorrentes de consumo, como variações em determinados períodos da semana, meses ou estações do ano. (Djakaria; Saleh, 2021).

A representação do modelo é apresentada através das Equações (6, 7, 8 e 9)

$$B_t = \alpha \frac{D_t}{I_{t-L}} + (1 - \alpha)(B_{t-1} + T_{t-1}) \quad (6)$$

$$T_t = \beta(B_t - B_{t-1}) + (1 - \beta)T_{t-1} \quad (7)$$

$$I_t = \gamma \frac{D_t}{B_t} + (1 - \gamma)I_{t-1} \quad (8)$$

$$F_t(t + k) = (B_t + kT_t)I_{t-L+k} \quad k = 1, 2, \dots \quad (9)$$

Onde,

D_t = demanda no período t ;

B_t = base ao final do instante t;

T_t = tendência ao final do instante t;

I_t = índice de sazonalidade do instante t;

α = constante de suavização para Base;

β = constante de suavização para Tendência;

γ = constante de suavização para sazonalidade;

$F_t(u)$ = previsão ao final do período t para o período u ($u > t$).

A primeira equação mostra o cálculo da base ao final do período t. A segunda equação mostra o cálculo da tendência. Na terceira equação tem-se a atualização do índice de sazonalidade e nesta equação a constante L representa a extensão do ciclo sazonal. Devido à introdução da variável índice de sazonalidade é introduzida também uma terceira constante de suavização (γ). Por fim, a previsão de demanda é calculada através da última equação, multiplicando a projeção da demanda pelo índice de sazonalidade correspondente. (Lustosa *et al.*, 2008)

2.5. Regressão Linear

Diferentes dos outros modelos matemáticos, a regressão linear é um método estatístico, que é amplamente utilizado para modelar a relação entre uma variável dependente e uma ou mais variáveis independentes. Na previsão de demanda, essa técnica permite estimar o comportamento futuro das vendas a partir da influência exercida por fatores que podem afetar o consumo, como temperatura, período do dia, dia da semana e outras variáveis relacionadas ao processo produtivo. Segundo Fávero e Belfiore (2017), a regressão linear busca identificar e quantificar relações entre variáveis, possibilitando compreender o impacto de determinados fatores sobre a variável de interesse.

Diferentemente dos métodos de suavização exponencial, que utilizam apenas o histórico da própria demanda para gerar previsões, a regressão linear permite

incorporar variáveis explicativas ao modelo, tornando-se uma alternativa relevante quando existem fatores externos capazes de influenciar o comportamento da demanda. A forma geral do modelo de regressão linear simples é apresentada pela Equação (10):

$$Y = B_0 + B_1X + \varepsilon \quad (10)$$

Onde,

Y= Variável dependente (demanda prevista);

X= Variável independente;

B_0 = intercepto ou coeficiente linear;

B_1 = coeficiente angular da regressão ou inclinação

ε = erro aleatório do modelo

Quando há mais de uma variável explicativa, utiliza-se a regressão linear múltipla, representada pela Equação (11):

$$Y = B_0 + B_1X_1 + B_2X_2 + \dots + B_nX_n + \varepsilon \quad (11)$$

Onde,

Y= Variável dependente (demanda prevista);

$X_1, X_2, \dots, X_n$ = Variáveis independentes;

B_0 = intercepto ou coeficiente linear;

$B_1, B_2, \dots, B_n$ = coeficientes angulares associados às variáveis explicativas

ε = erro aleatório do modelo

A principal vantagem da regressão linear está na capacidade de identificar e quantificar o efeito das variáveis explicativas sobre a demanda. Além de gerar previsões, o método possibilita compreender quais fatores exercem maior influência sobre o comportamento das vendas, fornecendo informações relevantes para a tomada de decisão e para o planejamento da produção.

A escolha do modelo de previsão mais adequado depende das características da série temporal analisada, bem como da presença de tendências, sazonalidades e oscilações no comportamento da demanda.

2.6. Erros de previsão

A previsão de demanda representa uma ferramenta fundamental de apoio ao planejamento e à tomada de decisão nas organizações. Entretanto, devido às incertezas presentes no comportamento do mercado e às variações naturais da demanda, nenhum método de previsão é capaz de reproduzir com exatidão os valores futuros da demanda. Dessa forma, torna-se necessário avaliar os erros de previsão, permitindo analisar o desempenho dos modelos utilizados e identificar aquele que apresenta maior precisão para determinada série temporal.

Segundo Corrêa e Corrêa (2012), o erro de previsão pode ser definido como a diferença entre o valor previsto e o valor efetivamente observado em determinado período. A análise desses erros possibilita verificar a confiabilidade dos modelos de previsão e auxiliar na seleção da técnica mais adequada para cada contexto operacional.

No contexto do varejo alimentar, erros de previsão podem gerar impactos operacionais significativos nas operações. Quando a demanda é superestimada, ocorre excesso de produção e aumento dos desperdícios, especialmente em produtos perecíveis. Por outro lado, a subestimação da demanda pode resultar em rupturas de estoque, perda de vendas e redução da satisfação dos consumidores. Assim, a avaliação contínua dos erros torna-se essencial para aprimorar o processo de tomada de decisão.

Entre as métricas mais utilizadas para mensurar a qualidade das previsões destacam-se o Erro Médio Absoluto (MAE), a Raiz do Erro Quadrático Médio (RMSE) e o Erro Percentual Absoluto Médio (MAPE).

O MAE (*Mean Absolute Error*) mede a média absoluta das diferenças entre os valores previstos e os valores reais observados, sendo amplamente utilizado devido à facilidade de interpretação. A equação é representada pela Equação (12).

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (12)$$

Onde,

n = número total de observações;

y_i = valor real

$\hat{y}_i$ = valor previsto

Já o RMSE (*Root Mean Squared Error*) corresponde à raiz quadrada do MSE, sendo utilizado para representar o erro médio na mesma unidade dos dados analisados. Essa métrica penaliza com maior intensidade erros de maior magnitude. Sua formulação é apresentada pela Equação (13).

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (13)$$

Onde,

N = número total de observações;

y_i = valor real;

$\hat{y}_i$ = valor previsto.

Por sua vez, o MAPE expressa os erros em termos percentuais, permitindo comparações entre diferentes conjuntos de dados e facilitando a interpretação dos resultados. A Equação é representada pela Equação (14).

$$MAPE = \frac{100}{n} \sum_{i=1}^n \left| \frac{A_t - F_t}{A_t} \right| \quad (14)$$

Onde,

n = número total de observações;

A_t = valor real;

F_t = valor previsto.

Dessa forma, a análise dos erros de previsão desempenha papel fundamental na avaliação da qualidade dos modelos preditivos, permitindo identificar suas limitações, comparar diferentes abordagens e fornecer maior confiabilidade ao processo de tomada de decisão.

Além das métricas de erro, estudos que utilizam modelos de regressão são avaliados por meio do Coeficiente de Determinação (R^2), utilizado para medir a capacidade do modelo em explicar a variabilidade dos dados observados. Segundo Montgomery, Peck e Vining (2021), o R^2 representa a proporção da variação da variável dependente que pode ser explicada pelas variáveis independentes presentes no modelo, representada pela Equação (15):

$$R^2 = 1 - \frac{SQR}{SQT} \quad (15)$$

Onde,

SQR= Soma dos Quadrados dos Resíduos;

SQT= Soma dos Quadrados Totais.

O valor de R^2 varia entre 0 e 1. Quanto mais próximo de 1, maior é a capacidade do modelo em explicar o comportamento da variável analisada. Entretanto, um modelo pode apresentar elevado coeficiente de determinação e ainda assim produzir previsões com baixa precisão. Por esse motivo, recomenda-se que o R^2 seja utilizado em conjunto com outras métricas de avaliação, como MAE, RMSE e MAPE, proporcionando uma análise mais completa do desempenho do modelo.

3. METODOLOGIA

3.1. Caracterização da pesquisa

O presente trabalho caracteriza-se como um estudo de caso de natureza aplicada, com abordagem quantitativa, com o objetivo de solucionar um problema prático relacionado à previsão de demanda de uma empresa utilizando técnicas estatísticas e modelos matemáticos.

Quanto aos objetivos, a pesquisa possui caráter descritivo e exploratório, buscando compreender o comportamento da demanda de um produto perecível, o pão francês, entender a influência de diferentes fatores sobre as vendas e avaliar o desempenho dos modelos quantitativos de previsão de demanda.

3.2. Caracterização da empresa e do produto

A pesquisa foi desenvolvida em uma padaria inserida dentro de um mercado de bairro localizado no município de Guapiara-SP. De acordo com o Censo do IBGE 2022, a população de Guapiara é estimada em 17.071 habitantes, com renda domiciliar per capita de R\$1.032,99. O funcionamento do estabelecimento ocorre ao longo dos sete dias da semana das 8h às 19h. Para o desenvolvimento do estudo, o horário de funcionamento foi dividido em dois períodos operacionais: matutino, das 08h às 12h, e vespertino, das 12h às 19h. Aos domingos, as atividades ocorrem exclusivamente no período da manhã. A justificativa para a segmentação dos períodos foi devido aos registros já estarem segregados em manhã e tarde.

O produto analisado corresponde ao pão francês, item de consumo diário, cuja demanda apresenta variações. A escolha do produto ocorreu em função de ser um produto introduzido recentemente no estabelecimento, com os registros de vendas controlados. Além disso, o produto gerava dúvidas sobre a quantidade a produzir diariamente associadas à margem de lucro reduzida.

O modelo operacional adotado pela empresa baseia-se na aquisição do produto já pré-processado, não sendo realizada a fabricação da massa no local. Dessa forma, as atividades da padaria concentram-se no assamento e disponibilização do produto para comercialização. Esse modelo de operação exige decisões frequentes relacionadas à quantidade de pão francês a ser assada em

cada período do dia, tornando o planejamento da produção diretamente dependente do comportamento da demanda e das oscilações do consumo.

3.3. Coleta de dados

Os dados utilizados neste estudo foram fornecidos pelo proprietário do estabelecimento, que registrava manualmente o histórico de vendas em cadernos. Os dados coletados compreendem os meses de abril de 2026 à setembro de 2026.

A base de dados continha informações diárias relacionados à quantidade de pão francês vendidos, preço do produto em reais por quilograma (R\$/kg), dia da semana, dia do mês e o período de comercialização. Essas informações foram utilizadas como base para análise do comportamento da demanda e aplicação dos métodos de previsão.

Além dos dados de vendas, foram coletadas informações relacionadas à temperatura do município de Guapiara-SP, obtidas por meio do banco de dados do Instituto Nacional de Meteorologia (INMET). Os dados climáticos correspondem ao mesmo período analisado nas vendas do estabelecimento, permitindo avaliar possíveis influências da temperatura sobre o comportamento da demanda.

3.4. Tratamento dos dados

Os dados coletados foram inicialmente transcritos em planilhas eletrônicas, visando padronização, organização e preparação para análise. A estruturação da base de dados foi realizada por meio da separação das variáveis em colunas específicas, incluindo quantidade vendida, preço, dia do mês, dia da semana e período de comercialização.

Durante o processo de tratamento dos dados, foram identificadas informações incompletas nos registros manuais. Para os registros que não apresentavam identificação do período de venda, adotou-se a classificação correspondente ao período matutino, considerando o padrão operacional do estabelecimento. Já nos casos em que não havia registro do preço do produto, foi utilizado média dos valores disponíveis, com o objetivo de manter a consistência dos dados e minimizar perdas de informação.

Os registros referentes ao mês de setembro de 2026 foram desconsiderados na análise final, uma vez que continham informações correspondente a apenas sete dias de funcionamento, o que poderia comprometer a representatividade estatística e comparativa da série temporal analisada.

Em relação aos dados climáticos, as informações de temperatura foram organizadas em planilhas eletrônicas contendo variáveis relacionadas à data, horário de Brasília, temperatura observado no momento do registro, temperatura média diária, período correspondente e classificação da temperatura. A divisão dos períodos seguiu a mesma estrutura adotada para os dados de vendas, permitindo integração entre as variáveis utilizadas na análise.

Após a etapa de limpeza e adequação, a base foi importada para o ambiente Python para a realização das análises estatísticas e construção dos modelos de previsão.

3.5. Análise exploratória dos dados

A análise exploratória dos dados teve como objetivo compreender o comportamento da demanda do pão francês, identificar padrões presentes na série temporal e verificar possíveis relações entre as variáveis disponíveis. Essa etapa é fundamental, pois permite a identificação de tendências, sazonalidades, dispersões e comportamentos atípicos que podem influenciar diretamente no modelo quantitativo de previsão a ser aplicado.

Inicialmente foram elaborados gráficos descritivos, incluindo histogramas, gráficos de barras, séries temporais e *boxplots*. Os gráficos foram utilizados para avaliar a distribuição das vendas em função do período do dia, temperatura e dia da semana, permitindo a identificação de dispersão, valores extremos, diferenças entre grupos, possíveis tendências e padrões recorrentes presentes na série.

Posteriormente, foi realizada a Análise de Variância (ANOVA), com o objetivo de verificar se existiam diferenças estatisticamente significativas entre as variáveis analisadas. Para os fatores que apresentaram significância estatística, foi aplicado o teste de Tukey como análise *post-hoc*, permitindo identificar quais grupos apresentaram diferenças significativas entre si.

A análise exploratória contribuiu para a seleção dos modelos de previsão mais adequados, considerando características como presença de tendência e

sazonalidade. Dessa forma, essa etapa serviu como base para o desenvolvimento e aplicação dos modelos quantitativos utilizados no estudo.

3.6. Definição dos modelos de previsão

A seleção dos modelos de previsão foi realizada considerando diferentes abordagens da literatura. Foram selecionados cinco métodos: Média Móvel Simples, Suavização Exponencial Simples, Holt, Holt-Winters e Regressão Linear Múltipla.

3.7. Aplicação dos Modelos

Os modelos foram aplicados separadamente para os períodos da manhã e da tarde, justificado pela identificação de comportamentos distintos da demanda entre esses grupos na análise exploratória.

A aplicação do método de Média Móvel Simples utilizou três janelas temporais (3, 7 e 14 períodos). Para a Suavização Exponencial Simples foi atribuído três parâmetros principais ($\alpha=0.2$, $\alpha=0.5$, $\alpha=0.8$). Já no modelo de Holt, os parâmetros de suavização do nível e de tendência (alpha e beta) foram estimados automaticamente pelo algoritmo de cada grupo de dia da semana e período, utilizando ajuste otimizado. O modelo Holt-Winters utilizou sazonalidade semanal, utilizando o período sazonal igual a sete dias e assim como no modelo de Holt, os parâmetros foram estimados automaticamente pelo algoritmo ao ajustar a série da manhã e da tarde. E para a Regressão Linear, a foi utilizado como variável dependente a quantidade de vendas e como variáveis explicativas um índice temporal (t), três defasagens da série (lag 1- período anterior; lag 7- uma semana anterior; lag 14=duas semanas anteriores) e o dia da semana.

3.8. Avaliação dos Modelos

A avaliação dos modelos aplicados foi feita a partir das métricas de erros de previsão de demanda, amplamente utilizadas na literatura, sendo elas: Erro Médio Absoluto (MAE), Raiz do Erro Quadrático Médio (RMSE) e o Erro Percentual Absoluto Médio (MAPE). A utilização conjunta dessas métricas permite uma

avaliação mais completa dos modelos, uma vez que o MAE representa o erro médio absoluto em unidades, o RMSE penaliza com maior intensidade erros de grande magnitude, e o MAPE possibilita a interpretação percentual dos desvios de previsão.

O MAE foi utilizado para medir os erros médios absolutos das previsões. Já o RMSE foi utilizado para avaliar a magnitude do erro, atribuindo maior peso aos erros mais elevados. Enquanto o MAPE foi utilizado para medir o erro percentual médio, permitindo comparação do desempenho entre os diferentes métodos.

Os resultados das métricas foram utilizados para comparar o potencial de previsão dos modelos avaliados.

3.9. Limitação da Pesquisa

Entre as limitações do estudo destaca-se a disponibilidade de variáveis analisadas, uma vez que existem fatores externos com potencial de influência no comportamento da demanda, como eventos locais, promoções e condições econômicas, não foram disponibilizados e analisados.

4. RESULTADOS E DISCUSSÕES

4.1. Cenário atual

Atualmente, o planejamento da produção de pão francês é realizado de forma empírica, baseado na experiência e no conhecimento acumulado pelo proprietário do estabelecimento. As informações de vendas são registradas manualmente em cadernos, não havendo a utilização de sistemas informatizados ou modelos formais de previsão de demanda para apoiar a tomada de decisões. Essas práticas podem aumentar a exposição a erros no planejamento e controle da produção.

4.2. Análise Exploratória dos dados

4.2.1. Estatística Descritiva

Inicialmente, foi realizada uma análise descritiva dos dados coletados sobre as vendas de pão francês com o objetivo de compreender o comportamento da demanda ao longo dos dias da semana, períodos e meses analisados.

A Tabela 1 apresenta a média de vendas por dia da semana. Observa-se que a maior média de vendas ocorre aos domingos (118,59 unidades), evidenciando um pico significativo em relação ao resto da semana, o que pode indicar a presença de sazonalidade. O sábado aparece em segundo lugar (77,85 unidades), enquanto os dias úteis mantêm uma média estável de 70 a 75 unidades. Esse comportamento sugere uma maior procura pelos produtos durante os finais de semana, possivelmente associada aos hábitos de consumo característicos desses dias.


O gráfico de barras da Figura 1 reforça essa tendência, evidenciando um crescimento ao fim da semana, resultando nos maiores volumes médios de vendas aos finais de semana. Embora a diferença entre os dias não sejam extremamente elevadas, observa-se um padrão que indica a influência do dia da semana sobre o comportamento da demanda.

Tabela 1 - Média de Quantidade de vendas por Dia da Semana

Dia da Semana	Média de Quantidade (unidade)
Domingo	118,591
Sábado	77,850
Quarta	73,500
Quinta	70,359
Segunda	71,868
Sexta	75,000
Terça	70,325

Fonte: Autoria Própria (2026).

Figura 1 : Média de Quantidade de vendas por Dia da Semana



Fonte: Autoria Própria (2026).

Já em relação aos períodos do dia, os resultados apresentados na Tabela 2 indicam que as vendas pela manhã (82,3 unidades) apresentaram média superior a


do período da tarde (70 unidades). Como comentado no tópico da metodologia, o estabelecimento funciona somente no período da manhã aos domingo, isso pode indicar que apesar de ter menos horas de funcionamento, o volume de vendas é significativo. O gráfico, Figura 2, indica visualmente a diferença da média de vendas nos períodos.

Tabela 2 - Média de Quantidade por Período

Período	Média de Quantidade (unidade)
Manhã	82,340
Tarde	70,561

Fonte: Autoria Própria (2026).

Figura 2 : Média de Quantidade de vendas por Período



Fonte: Autoria Própria (2026).

A Tabela 3 tem-se a análise do volume total de vendas por mês demonstra uma variação ao longo do período analisado. O menor volume foi registrado em


abril, com 3110 unidades vendidas, o que pode ser justificado pelos registrados terem sidos iniciados no dia 10, enquanto julho apresentou o maior resultado, totalizando 4354 unidades. Observa-se que os meses de maio, junho e agosto apresentam valores próximos, todos superiores a 4000 unidades. A Figura 3 demonstra visualmente esses pontos. Esse comportamento pode indicar influência de fatores sazonais ou climáticos sobre o consumo, hipótese que foi analisada nas próximas etapas.

Tabela 3 - Quantidade Total por Mês

Mês	Quantidade (unidades)
Abril	3110
Maio	4065
Junho	4077
Julho	4354
Agosto	4050

Fonte: Aatoria Própria (2026).

Figura 3 : Quantidade Total por Mês



Fonte: Aatoria Própria (2026).


Já na Tabela 4, é possível notar que as vendas são bastante estáveis e altas em dias categorizados como “Frio”, “Ameno” e “Quente”, mantendo uma média entre 77 e 78 unidades. No entanto, quando a temperatura fica “Muito Quente”, ocorre uma queda brusca nas vendas para uma média de 54,85 unidades. A Figura 4 demonstra essa relação.

Tabela 4 - Média da Quantidade por Categoria de Temperatura

Mês	Quantidade (unidades)
Frio (<15°C)	77,4310
Ameno (15-20°C)	78,2623
Quente (20-25°C)	76,9265
Muito Quente (>25°C)	54,8571

Fonte: Autoria Própria (2026).

Figura 4 : Média da Quantidade por Categoria de Temperatura



Fonte: Autoria Própria (2026)


4.2.2. Distribuição dos Dados

Foram gerados histogramas para demonstrar como os dados estavam distribuídos.

A Figura 5 apresenta a distribuição das quantidades vendidas de pão francês durante o período analisado. Observa-se uma concentração predominante das vendas entre aproximadamente 55 e 90 unidades. O pico da distribuição parece ocorrer próximo de 65 à 75 unidades, indicando que esse é o volume de venda mais frequente. Além disso, nota-se a presença de uma assimetria positiva, cauda à direita, com alguns valores superiores a 120 unidades, chegando próximo de 170 unidades. Esse comportamento sugere que, apesar da maior parte das observações

estarem concentrada em níveis intermediários, há a existência de dias com um aumento expressivo da demanda, possivelmente associados a finais de semana, feriados, ou condições climáticas.


Figura 5 : Histograma das Vendas



Fonte: Autoria Própria (2026).

Já a Figura 6 apresenta a distribuição das temperaturas registradas durante o período da coleta de dados. Observa-se uma distribuição aproximadamente simétrica, com maior concentração das observações entre 15°C e 22°C. As temperaturas extremas ocorrem com menor frequência, indicando que durante o período analisado, houve a predominância de condições climáticas moderadas. Essa análise será importante para as próximas análises, visto que poderá ser avaliado a influência da temperatura sobre o comportamento da demanda.

Figura 6 : Histograma da Temperatura




Fonte: Autoria Própria (2026).

4.2.3. Análise por *Boxplots*

Para visualizar possíveis variações, concentrações de dados e os “outliers” que podem ter sido camuflados com as médias, foram gerados *boxplots*.


Analisando a Figura 7, é possível notar que o Domingo possui maior mediana que os outros dias da semana, mas também maior dispersão visto que sua caixa é mais alongada, o que reforça a necessidade de maior atenção no planejamento da produção neste dia. O que indica que, além de vender mais, as vendas de domingo são mais instáveis, ou seja, variam bastante de um domingo para outro. Outra observação notada é que apesar da mediana dos dias úteis da semana serem próximos, há segundas, terças, quarta e quintas-feiras específicas que as vendas aumentam, chegando a níveis de final de semana.

Figura 7 – *Boxplot* da Quantidade Vendida por Dia da Semana



Fonte: Autoria própria (2026).


Na distribuição das vendas por período, Figura 8, nota-se que as medianas da manhã e da tarde estão praticamente na mesma altura. Ou seja, o comportamento padrão de vendas é parecido nos dois períodos. A diferença está nos pontos atípicos. Onde o período da manhã tem outliers que chegam acima de 160 unidades, enquanto os da tarde param perto de 120 unidades. Podendo assumir que a maior quantidade de venda costuma ocorrer no período matutino.

Figura 8 – *Boxplot* da Quantidade Vendida por Período

Fonte: Autoria Própria (2026)


A partir da Figura 9 é possível notar que o mês de abril, apesar de ter apresentado menor quantidade total de vendas, possui a maior mediana, próximo de 90 unidades. Isso pode ser justificado pelos registros analisados terem menos dias em Abril do que comparado aos outros, ou seja, nos dias de registros a padaria vendeu bem, mas a ausência de dados de todos os dias afetou o volume total do mês. Além disso, notou-se que nos meses seguintes, a mediana diária se estabilizou em torno de 70 unidades. E possivelmente os pontos isolados, “outliers” podem ser referentes aos domingos.

Figura 9 – *Boxplot* da Quantidade Vendida por Mês



Fonte: Autoria Própria (2026)


Analisando a Figura 10, pode se confirmar que os dias que tiveram categoria “Muito Quente” apresentaram não só a mediana mais baixa, perto das 55 unidades, como o seu limite máximo de vendas fica abaixo das medianas das outras categorias de temperatura.

Figura 10 – *Boxplot* da Quantidade Vendida por Temperatura

Fonte: Autoria Própria (2026)

A Figura 11 representa a relação entre período e dia da semana na quantidade vendida de pão francês no estabelecimento. Como já falado anteriormente, o domingo só abre no período matutino, por isso não há a presença da caixa azul no *boxplot*. É possível notar que, mesmo funcionando apenas um período, o domingo consegue ser o dia de maior volume de vendas geral (como indicado na Figura 1), o que indica um fluxo de clientes ou vendas intenso.

Figura 11 – *Boxplot* da Quantidade Vendida por Período em cada Dia da Semana



Fonte: Autoria Própria (2026)

De modo geral, os resultados da estatística descritiva indicam, principalmente, que a demanda de pão francês não é aleatória, podendo ser associada às variações dos dias da semana, visto que os finais de semana parecem concentrar uma maior procura. Além da influência nas vendas quando os dias são “Muito Quentes”. As outras variáveis não apresentaram diferenças tão significativas. Porém, para verificar se as diferenças observadas são estatisticamente significativas é necessário a realização de análises estatísticas complementares. Com isso, também será possível identificar quais os fatores que mais influenciam a demanda.

4.2.4. Testes Estatísticos

4.2.4.1. ANÁLISE DE VARIÂNCIA (ANOVA)

Com a aplicação do ANOVA nas variáveis disponíveis nos dados, pode-se verificar quais são aquelas que apresentam diferenças estatisticamente significativas. Os resultados apresentados na Tabela 5 indicam que as variáveis “Dia

da Semana” e “Período” exercem influência estatisticamente significativa sobre a demanda, representadas por um p-value inferior a 0,05 ($p=1.146874e-17$ e $p\text{-value}=0.000026$, respectivamente). Demonstrando que há uma influência das variáveis sobre a demanda, não aleatórias, em que os dias da semana apresentam comportamentos de demanda diferentes entre si, bem como os períodos da manhã e da tarde. Já as variáveis de Temperatura e Mês apresentaram p-value superior a 0,05, o que indica ausência de diferença estatisticamente significativa entre as vendas realizadas nos meses e temperaturas analisadas. Apesar disso, como o valor de p-value é próximo do nível de significância adotado, pode-se dizer que há uma tendência estatística de influência.

Tabela 5 - ANOVA das variáveis		
Variável	F	p-value
Temperatura	2.226875	0.085561
Dia da Semana	18.399905	1.146874e-17
Período	18.325418	0.000026
Mês	2.140546	0.076345

Fonte: Autoria Própria (2026).

Após a descoberta de quais as variáveis que afetam a demanda, é realizado o teste de Tukey para descobrir onde estão as diferenças.


4.2.4.2. Teste de Tukey

A aplicação do Teste de Tukey foi feita somente nas variáveis que apresentaram tendência estatística. Na Tabela 6, é possível observar a relação entre os períodos manhã e tarde, o valor de meandiff indica que a média de vendas da manhã é aproximadamente 11,8 maior que a da tarde. A comparação visual entre os períodos pode ser observada na Figura 12

Tabela 6 - Teste de Tukey - Período				
Grupo 1	Grupo 2	meandiff	p-adj	Reject
Manhã	Tarde	-11,779	0,0001	True

Fonte: Autoria Própria (2026).

Figura 12 – Comparação Múltipla entre as Variáveis
Comparação Múltipla entre as Variáveis



Fonte: Autoria Própria (2026)

Para as variáveis do Dia da Semana, o teste evidenciou que o Domingo apresentou diferenças estatisticamente significativas em relação a todos os outros dias da semana ($p < 0,05$), indicando um comportamento de demanda distinto e evidenciando uma forte sazonalidade semanal. Já entre os outros dias da semana, apesar das médias serem diferentes (meandiff), não há diferença estatisticamente entre elas. A representação gráfica dessa observação pode ser representada na Figura 13.

Tabela 7 - Teste de Tukey - Dia da Semana


				(continua)
Grupo 1	Grupo 2	meandiff	p-adj	Reject
Domingo	Quarta	-45,0909	0	TRUE
Domingo	Quinta	-48,2319	0	TRUE
Domingo	Segunda	-46,7225	0	TRUE
Domingo	Sexta	-43,5909	0	TRUE
Domingo	Sábado	-40,7409	0	TRUE
Domingo	Terça	-48,2659	0	TRUE
Quarta	Quinta	-3,141	0,9927	FALSE
Quarta	Segunda	-1,6316	0,9998	FALSE

Tabela 7 - Teste de Tukey - Dia da Semana

				(conclusão)
Grupo 1	Grupo 2	meandiff	p-adj	Reject
Quarta	Sexta	1,5	0,9999	FALSE
Quarta	Sábado	4,35	0,9598	FALSE
Quarta	Terça	-3,175	0,992	FALSE
Quinta	Segunda	1,5094	0,9999	FALSE
Quinta	Sexta	4,641	0,9468	FALSE
Quinta	Sábado	7,491	0,6282	FALSE
Quinta	Terça	-0,034	1	FALSE
Segunda	Sexta	3,1316	0,9931	FALSE
Segunda	Sábado	5,9816	0,8349	FALSE
Segunda	Terça	-1,5434	0,9999	FALSE
Sexta	Sábado	2,85	0,9956	FALSE
Sexta	Terça	-4,675	0,9434	FALSE
Sábado	Terça	-7,525	0,6159	FALSE


Fonte: Autoria Própria (2026).

Figura 13 – Comparação Múltipla entre as Variáveis



Fonte: Autoria Própria (2026)

Por fim, foi construído um *heatmap* (mapa de calor) da média de vendas por dia da semana e período. Dessa forma é possível visualizar de forma facilitada a sazonalidade semanal, onde domingo apresenta maior quantidade de vendas e a diferença da demanda em cada período.




Fonte: Autoria Própria (2026)

4.3. Modelos de previsão e Erros

4.3.1. Média Móvel Simples (MMS):


Os resultados da Média Móvel Simples demonstraram que a variação da janela de suavização teve impacto direto na qualidade das previsões, tanto no período matutino quanto no vespertino, representados na Figura 15 e Figura 16.

Figura 15 – Comparação dos erros por janela



Fonte: Autoria Própria (2026)

Figura 16 – Comparação dos erros por janela




Fonte: Autoria Própria (2026)

Os erros gerados a partir da análise estão representados na Tabela 8. E na Figura 17 podemos observar visualmente a comparação entre os erros em cada janela e período. Nota-se que os resultados indicam um o melhor equilíbrio entre suavização e capacidade de resposta às oscilações da série na janela 7, especialmente no período da Tarde. O pior resultado observado na janela 14 indica que o excesso de suavização compromete a resposta do modelo quanto às variações de demanda, principalmente em uma série com padrão semanal e diferenças marcantes entre os dias. De forma geral, para séries com sazonalidade

semanal e influência de períodos, a MMS pode ser utilizada, mas sua eficácia depende fortemente da escolha da janela e da adequada segmentação da série.

Tabela 8 - MMS: Comparativo dos erros nas diferentes janelas e períodos				
Período	Janela	MAE	RMSE	MAPE (%)
Manhã	3	16,7389	22,3898	22,5908
Tarde	3	12,6879	16,8611	21,585
Manhã	7	16,3401	21,3216	22,6167
Tarde	7	11,798	16,1002	20,3609
Manhã	14	17,5897	23,4272	25,7191
Tarde	14	14,7551	19,9483	26,7568

Fonte: Autoria Própria (2026).




Fonte: Autoria Própria (2026).

4.3.2. Suavização Exponencial Simples (SES):


Na aplicação da Suavização Exponencial Simples, notou-se que o modelo é mais sensível à escolha do parâmetro alpha, visto que pequenas mudanças no valor alteram o desempenho do método. Com isso, é possível observar nas Figuras 18 e 19 que valores intermediários ou mais baixos de alpha geram previsões mais estáveis.

Figura 18 – Comparação dos erros por janela



Fonte: Autoria Própria (2026)

Figura 19 – Comparação dos erros por janela



Fonte: Autoria Própria (2026)

Observa-se na Tabela 9 que o método apresentou melhor desempenho com $\alpha = 0,2$ na Manhã, considerando MAE e RMS. Já na Tarde, o $\alpha = 0,5$ teve o melhor desempenho nos três erros comparado com os demais alphas testados. Em contrapartida, o desempenho com $\alpha = 0,8$ foi inferior em ambos os períodos, o que indica que um peso excessivo nas observações recentes tornou o modelo mais reativo, possivelmente capturando oscilações momentâneas. A Figura 20 faz uma representação gráfica dessa comparação dos erros.


Tabela 9 - SES: Comparativo dos erros nos diferentes alpha's e períodos

Período	Alpha	MAE	RMSE	MAPE (%)
Manhã	0,2	15,9313	20,8971	22,0544
Tarde	0,2	14,6559	20,1207	25,578
Manhã	0,5	16,0574	21,8606	21,7188
Tarde	0,5	13,7395	18,9405	23,3972
Manhã	0,8	17,1025	24,0367	22,9598
Tarde	0,8	14,2357	19,7103	23,962

Fonte: Autoria Própria (2026)

Figura 20 – Comparação dos erros por janela

Comparação dos erros período - período da semana + período




Fonte: Autoria Própria (2026)

Assim, a SES mostrou-se mais flexível que a MMS, porém ainda limitada pela ausência de tratamento explícito da sazonalidade semanal.

4.3.3. Holt


Os resultados obtidos na aplicação do modelo de Holt são apresentados na Figura 21 e 22, que mostram a comparação entre os valores reais e previstos. Nota-se que o modelo apresenta boa capacidade de acompanhar o comportamento geral da demanda em ambos os períodos. Embora no período da manhã o modelo apresentou maior dificuldade em capturar picos mais elevados da demanda, tendendo a suavizar variações abruptas.

Figura 21 – Comparação dos erros por janela



Fonte: Autoria Própria (2026)

Figura 22 – Comparação dos erros por janela



Fonte: Autoria Própria (2026)


As métricas de erro, apresentadas na Tabela 10 e representadas na Figura 23, reforçam essa observação. Destaca-se que o período da Tarde apresentou menor MAE e menor RMSE do que a Manhã, o que sugere maior previsibilidade em termos absolutos, enquanto a Manhã apresentou menor MAPE, indicando erro percentual ligeiramente inferior. Apesar dessa diferença, o desempenho é semelhante entre os dois períodos, indicando que o modelo é consistente em ambos os cenários.

Tabela 10 - Holt: Comparativo dos erros nos diferentes períodos

Período	MAE	RMSE	MAPE (%)
Manhã	13,5569	18,1656	17,9361
Tarde	11,3515	14,5844	18,9832

Fonte: Autoria Própria (2026)

Figura 23 – Comparação dos erros por janela



Fonte: Autoria Própria (2026)

O bom desempenho do método de Holt pode ser interpretado como consequência da sua capacidade de capturar simultaneamente o nível e a tendência da série, especialmente quando a modelagem é feita respeitando a heterogeneidade dos grupos analisados. Embora o método não incorpore sazonalidade explicitamente, ele apresentou melhor desempenho do que métodos mais simples, sugerindo que a combinação entre tendência local e uma estrutura de dados adequadamente segmentada foi suficiente para representar bem a dinâmica observada. De forma geral, o método de Holt mostrou-se o mais robusto entre os modelos analisados, resultado consistente com a literatura, que indica melhor desempenho de modelos que capturam tendência em séries com esse comportamento.

4.3.4. Holt-Winters

No método de Holt-Winters aditivo, os resultados obtidos foram MAE = 17,1265, RMSE = 20,9325 e MAPE = 22,2913% para a Manhã, e MAE = 12,6389, RMSE = 17,3182 e MAPE = 21,2495% para a Tarde. As figuras associadas a esse método mostram desempenho intermediário, com melhor resultado na Tarde do que na Manhã, porém sem superar o método de Holt.

Apesar de o Holt-Winters ser, em teoria, um modelo especialmente apropriado para séries com sazonalidade, os resultados sugerem que a inclusão explícita da componente sazonal aditiva não trouxe ganho de desempenho suficiente nesta aplicação. Isso pode indicar que a sazonalidade semanal presente na base não se


manifestou de forma suficientemente estável para melhorar o ajuste, ou que a estrutura escolhida para modelagem já capturava parte desse padrão por meio da organização dos dados por período e do próprio comportamento da série. Em termos práticos, observou-se que o método ficou atrás do Holt e, em alguns casos, também atrás da MMS e da SES, sobretudo na Manhã, o que mostra que maior sofisticação estrutural nem sempre se traduz em melhor resultado preditivo quando a série apresenta variações irregulares e diferenças operacionais relevantes entre períodos.

Tabela 11 - Holt-Winters: Comparativo dos erros nos diferentes períodos

Período	MAE	RMSE	MAPE (%)
Manhã	17,1265	20,9325	22,2913
Tarde	12,6389	17,3182	21,2495


Fonte: Autoria Própria (2026).

Figura 24 – Comparação dos erros por janela




Fonte: Autoria Própria (2026)

Figura 25 – Comparação dos erros por janela



Fonte: Autoria Própria (2026)

Figura 26 – Comparação dos erros por janela



Fonte: Autoria Própria (2026)

4.3.5. Regressão linear

A Regressão Linear apresentou os maiores erros entre os métodos analisados no relatório. Para o período da Manhã, foram registrados MAE = 22,0544, RMSE = 37,5562 e MAPE = 28,9960%. Para a Tarde, os resultados foram MAE = 16,2259, RMSE = 23,6600 e MAPE = 25,8049%. As figuras associadas ao método também indicam visualmente maior dispersão dos erros, sinalizando menor aderência às variações observadas no histórico.


Esses resultados indicam que, na forma especificada, a regressão linear não foi capaz de representar adequadamente a dinâmica da demanda analisada. O elevado RMSE, especialmente na Manhã, sugere a ocorrência de erros grandes em determinados pontos da série, o que compromete sua aplicação prática para apoio ao planejamento operacional. Essa limitação pode estar associada à relação não estritamente linear entre a demanda e os fatores temporais observados, à presença de flutuações abruptas entre dias e períodos, ou ainda à insuficiência de variáveis explicativas para capturar toda a estrutura do fenômeno. Dessa forma, embora a regressão linear seja um método interpretável e útil em muitos contextos, os resultados indicam que, para esta base específica, os modelos clássicos de séries temporais apresentaram melhor aderência.

Tabela 12 - Regressão Linear: Comparativo dos erros nos diferentes períodos

Período	MAE	RMSE	MAPE (%)
Manhã	22,0544	37,5562	28,996
Tarde	16,2259	23,66	25,8049


Fonte: Autoria Própria (2026).

Figura 27 – Comparação dos erros por janela




Fonte: Autoria Própria (2026)

Figura 28 – Comparação dos erros por janela



Fonte: Autoria Própria (2026)

Figura 29 – Comparação dos erros por janela




Fonte: Autoria Própria (2026)

4.4. Comparação dos resultados

A análise conjunta dos métodos evidencia que a escolha do modelo de previsão foi fortemente influenciada pela estrutura da série, especialmente pela presença de sazonalidade semanal e diferenças entre períodos da manhã e da tarde. Em termos gerais, o método de Holt apresentou os melhores resultados entre os modelos avaliados, sendo o mais consistente tanto em erro absoluto quanto em erro quadrático e erro percentual. A MMS, especialmente com janela 7, apresentou desempenho competitivo, principalmente no período da Tarde, enquanto a SES mostrou comportamento intermediário, com sensibilidade ao valor de α utilizado. O Holt-Winters aditivo, embora teoricamente apropriado para séries sazonais, não apresentou superioridade prática nesta aplicação, e a Regressão Linear foi o método de menor desempenho.

Esses resultados reforçam que, em problemas de previsão de demanda, a seleção do método não depende exclusivamente do grau de sofisticação algorítmica, mas sobretudo da adequação entre o comportamento da série e a forma como o modelo é estruturado e parametrizado. No caso estudado, a presença de sazonalidade semanal e o efeito do período de venda mostraram que métodos simples podem ter bom desempenho quando a série é organizada corretamente, enquanto modelos mais complexos podem não trazer ganho adicional quando a estrutura da demanda não se ajusta plenamente às hipóteses do modelo. Dessa forma, os resultados obtidos sustentam a escolha do Holt como principal alternativa para previsão da demanda na base analisada, com a MMS aparecendo como alternativa viável em contextos nos quais se deseje simplicidade operacional.

Figura 30 – Comparação dos erros por janela



Fonte: Autoria Própria (2026)

Os resultados encontrados demonstram que a adoção de métodos quantitativos de previsão pode contribuir de forma concreta para o planejamento da produção de produtos perecíveis, como o pão francês, reduzindo a dependência exclusiva da experiência empírica e ampliando a qualidade da tomada de decisão. No caso da empresa analisada, a utilização de previsões por período e com atenção à sazonalidade semanal pode auxiliar diretamente na definição da quantidade a ser assada em cada turno, reduzindo desperdícios decorrentes de superprodução e diminuindo a probabilidade de faltas em horários e dias de maior demanda.

A análise estatística e os modelos testados mostram que o estabelecimento não apresenta uma demanda homogênea ao longo da semana, evidenciando a necessidade de segmentação no planejamento da produção. Em especial, os domingos se destacam como os dias de maior volume médio de vendas, e a manhã apresenta níveis médios superiores aos da tarde. Esses padrões sugerem que o planejamento da produção deve ser orientado por previsões segmentadas e constantemente atualizadas, e não apenas por uma média geral de vendas. Assim, o estudo reforça a utilidade da previsão de demanda como instrumento de apoio à eficiência operacional no varejo alimentar.

5. CONCLUSÃO

O presente trabalho teve como objetivo analisar e comparar métodos quantitativos de previsão de demanda na produção de pão francês em uma padaria de supermercado, buscando identificar a abordagem mais adequada para apoiar o planejamento da produção e contribuir para a redução de desperdícios e rupturas de estoque.

Para isso, foram utilizados dados históricos de vendas, complementados por variáveis relacionadas ao comportamento da demanda, como dia da semana, período de venda e temperatura, possibilitando a análise de padrões e a construção de modelos de previsão

Foram analisados diferentes métodos de previsão que poderiam contribuir para tornar o processo decisório mais estruturado, confiável e aderente ao comportamento real da demanda. Sendo eles os métodos de Média Móvel Simples (MMS), Suavização Exponencial Simples (SES), Holt, Holt-Winters aditivo e Regressão Linear Múltipla, todos avaliados com base nas métricas MAE, RMSE e MAPE.

A comparação conjunta entre os modelos evidenciou que a escolha do método de previsão foi fortemente influenciada pela estrutura da série, caracterizada por sazonalidade semanal e por diferenças entre os períodos da manhã e da tarde. Quando a comparação foi refeita em um mesmo subconjunto de observações válidas, o método de Holt manteve o melhor desempenho geral, sendo o melhor na manhã em MAE (14,2380), RMSE (19,1327) e MAPE (19,1030%). Na tarde, a MMS apresentou o menor MAE (11,7980), enquanto o Holt apresentou os melhores RMSE (15,0225) e MAPE (19,3050%), o que reforça seu bom desempenho geral.

Dessa forma, recomenda-se o uso do método de Holt como principal alternativa para previsão da demanda na padaria estudada, especialmente no período da manhã, em que apresentou superioridade clara sobre os demais métodos. Para o período da tarde, a MMS com janela 7 também se mostra uma alternativa operacionalmente viável quando o principal critério de decisão for o menor erro absoluto médio. Ainda assim, quando se considera o equilíbrio entre erro absoluto, erro quadrático e erro percentual, o Holt permanece como a opção mais robusta.

Dessa forma, pode-se concluir que o objetivo do trabalho foi alcançado, uma vez que foi possível aplicar, comparar e avaliar diferentes métodos de previsão de demanda no contexto analisado, identificando a abordagem mais aderente à realidade operacional da empresa estudada. Os resultados mostram que a demanda é influenciada por fatores temporais claros, especialmente dia da semana e período, e que a estrutura da série histórica deve ser considerada de forma criteriosa na escolha do método de previsão. Nesse cenário, o método de Holt destacou-se como a alternativa mais consistente para apoiar o planejamento da produção, oferecendo uma base quantitativa mais confiável para decisões que, até então, eram tomadas predominantemente de forma empírica.

Como continuidade desta pesquisa, recomenda-se a ampliação da base histórica de dados e a incorporação de variáveis adicionais, como temperatura em maior detalhe, promoções, datas comemorativas, eventos locais e outras informações capazes de influenciar o comportamento da demanda.

Além disso, futuras pesquisas podem avaliar a aplicação dos modelos não apenas na previsão da demanda, mas também a integração dos modelos de previsão com sistemas de apoio à decisão, possibilitando a automação do planejamento da produção, integrando estoque disponível, margem de segurança e perdas operacionais. Tal ampliação pode aproximar ainda mais o modelo teórico da realidade da tomada de decisão na empresa, contribuindo para uma gestão mais eficiente da produção de pão francês

REFERÊNCIAS

BALLOU, Ronald H. **Gerenciamento da cadeia de suprimentos/logística empresarial**. 5. ed. Porto Alegre: Bookman, 2006.

CHAGAS, Beatriz Adrien de Albuquerque. **Gestão de estoques**: uma análise da gestão da Baker Lima Padaria. 2020. Trabalho de Conclusão de Curso (Graduação em Administração) – Universidade Federal de Santa Catarina, Florianópolis, 2020.

CHOPRA, Sunil; MEINDL, Peter. **Gerenciamento da cadeia de suprimentos**: estratégia, planejamento e operação. 4. ed. São Paulo: Pearson Prentice Hall, 2011.

CORRÊA, Henrique Luiz; CORRÊA, Carlos Alberto. **Administração de produção e operações**. São Paulo: Atlas, 2012.

COSTA, Igor Santos *et al.* **Aplicação dos métodos de previsão de demanda em uma hamburgueria**. In: ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO, 37., 2017, Joinville. Anais [...]. Rio de Janeiro: ABEPRO, 2017.

FÁVERO, Luiz Paulo Lopes; BELFIORE, Patrícia. **Análise de dados**: técnicas multivariadas exploratórias com SPSS e Stata. São Paulo: Elsevier, 2017.

GUERRA, Ivan Gomes; OLIVEIRA-MELO, Felipe Guilherme de. **Aplicação dos métodos de previsão de demanda em uma indústria de alimentos**. In: ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO, 41., 2021, Foz do Iguaçu. Anais [...]. Rio de Janeiro: ABEPRO, 2021.

HEIZER, Jay; RENDER, Barry; MUNSON, Chuck. **Administração de operações e cadeia de suprimentos**. 14. ed. São Paulo: Pearson, 2017.

LUSTOSA, Leonardo *et al.* **Planejamento e controle da produção**. Rio de Janeiro: Elsevier, 2008.

MAKRIDAKIS, Spyros; WHEELWRIGHT, Steven C.; HYNDMAN, Rob J. **Forecasting: methods and applications**. 3. ed. New York: Wiley, 1998.

MARQUES, Camilla Emanuelle; SANTOS, Maísa Rodrigues. **Previsão de demanda**: estudo de caso na padaria de uma empresa do ramo supermercadista.

2018. Trabalho de Conclusão de Curso (Bacharelado em Engenharia de Produção)
– Universidade Federal de Uberlândia, Ituiutaba, 2018.

MENTZER, John T. **Fundamentals of supply chain management**. Thousand Oaks:
Sage Publications, 2004.

MONTGOMERY, Douglas C.; PECK, Elizabeth A.; VINING, G. Geoffrey.
Introduction to linear regression analysis. 6. ed. New York: Wiley, 2021.

MORETTIN, Pedro Alberto; TOLOI, Clélia Maria de Castro. **Análise de séries
temporais**. São Paulo: Edgard Blücher, 2006.

PARENTE, Juracy. **Varejo no Brasil: gestão e estratégia**. 2. ed. São Paulo: Atlas,
2014.

SLACK, Nigel; CHAMBERS, Stuart; JOHNSTON, Robert. **Administração da
produção**. 3. ed. São Paulo: Atlas, 2009.

TUBINO, Dalvio Ferrari. **Planejamento e controle da produção: teoria e prática**.
São Paulo: Atlas, 2007.