

**APLICAÇÃO DE MÉTODOS DE PREVISÃO DE DEMANDA EM SETORES PRODUTIVA DE SERVIÇOS COM FOCO EM ATENDIMENTO****APPLICATION OF DEMAND FORECASTING METHODS IN SERVICE PRODUCTION SECTORS WITH A FOCUS ON CUSTOMER SERVICE****APLICACIÓN DE MÉTODOS DE PRONÓSTICO DE LA DEMANDA EN SECTORES PRODUCTIVOS DE SERVICIOS CON ENFOQUE EN LA ATENCIÓN AL CLIENTE**<https://doi.org/10.56238/ERR01v10n6-068>**Camilly Lima dos Santos**

Graduanda em Engenharia de Produção  
Instituição: Universidade São Judas Tadeu  
E-mail: 821140647@ulife.com.br

**Lucas de Souza Nunes**

Graduando em Engenharia de Produção  
Instituição: Universidade São Judas Tadeu  
E-mail: 8222240896@ulife.com.br

**Matheus Santos Ferreira das Neves**

Graduando Engenharia de Produção  
Instituição: Universidade São Judas Tadeu  
E-mail: 8222240895@ulife.com.br

**Bernardo Goisman**

Mestre em Engenharia  
Instituição: Universidade São Judas Tadeu  
E-mail: prof.bernardo.goisman@gmail.com

**RESUMO**

O Planejamento e Controle da Produção (PCP), no setor de serviços, enfrenta o desafio da necessidade do maior número atendimentos ao cliente com um menor número de pessoas na equipe. Previsões de demanda de serviços devem, então, ser assertivas para um bom planejamento na alocação de recursos. Este trabalho teve como objetivo analisar e comparar diferentes métodos quantitativos de previsão de demanda aplicados a dados de uma empresa do ramo bancário. O estudo utilizou uma abordagem quantitativa, analisando dados históricos mensais de volume de atendimento em um período de 2 anos e meio (janeiro de 2023 a junho de 2025). Os dados foram separados em períodos de treinamento (janeiro de 2023 a março de 2025) e os restantes, referentes a abril a junho de 2025, serão utilizados como teste. Foram aplicados modelos de séries temporais com parâmetros otimizados via Solver do Excel. A acurácia dos modelos foi avaliada utilizando o Erro Percentual Absoluto Médio (MAPE). Os resultados indicaram que Holt Winters e média móvel ponderada se mostraram mais eficientes, apresentando um menor MAPE no período de teste. Conclui-se que o método utilizado é uma boa ferramenta para o dimensionamento de equipes em previsões de curto prazo. No entanto, destaca-se

que fatores humanos podem influenciar a demanda e a previsão, fazendo-se necessárias mais análises em um ambiente de tempo maior.

**Palavras-chave:** Previsão de Demanda. Planejamento e Controle de Custo. MAPE. Séries Temporais.

### ABSTRACT

Production Planning and Control (PCP) in the service sector faces the challenge of needing to serve more customers with fewer staff. Service demand forecasts must therefore be accurate to enable effective resource allocation planning. The objective of this study was to analyze and compare different quantitative demand forecasting methods applied to data from a banking company. The study used a quantitative approach, analyzing historical monthly service volume data over a period of two and a half years (January 2023 to June 2025). The data were separated into training periods (January 2023 to March 2025) and the remaining data, referring to April to June 2025, will be used as a test. Time series models with parameters optimized via Excel Solver were applied. The accuracy of the models was evaluated using the Mean Absolute Percentage Error (MAPE). The results indicated that Holt Winters and weighted moving average proved to be more efficient, presenting a lower MAPE in the test period. It is concluded that the method used is a good tool for sizing teams in short-term forecasts. However, it should be noted that human factors can influence demand and forecasting, requiring further analysis over a longer period of time.

**Keywords:** Demand Forecasting. Cost Planning and Control. MAPE. Time Series.

### RESUMEN

La Planificación y el Control de la Producción (PCP) en el sector servicios se enfrenta al reto de atender a un mayor número de clientes con menos personal. Por lo tanto, las previsiones de la demanda de servicios deben ser precisas para poder planificar adecuadamente la asignación de recursos. El objetivo de este trabajo era analizar y comparar diferentes métodos cuantitativos de previsión de la demanda aplicados a los datos de una empresa del sector bancario. El estudio utilizó un enfoque cuantitativo, analizando datos históricos mensuales del volumen de atención en un período de dos años y medio (enero de 2023 a junio de 2025). Los datos se separaron en períodos de entrenamiento (enero de 2023 a marzo de 2025) y los restantes, correspondientes a abril a junio de 2025, se utilizarán como prueba. Se aplicaron modelos de series temporales con parámetros optimizados mediante Solver de Excel. La precisión de los modelos se evaluó utilizando el error porcentual absoluto medio (MAPE). Los resultados indicaron que Holt Winters y la media móvil ponderada resultaron más eficientes, presentando un MAPE menor en el período de prueba. Se concluye que el método utilizado es una buena herramienta para dimensionar equipos en previsiones a corto plazo. Sin embargo, cabe destacar que los factores humanos pueden influir en la demanda y la previsión, por lo que es necesario realizar más análisis en un entorno de mayor duración.

**Palabras clave:** Previsión de la Demanda. Planificación y Control de Costos. MAPE. Series Temporales.

## 1 INTRODUÇÃO

A Engenharia de Produção é um campo interdisciplinar voltado à otimização de processos em áreas como engenharia do produto, Planejamento e Controle da Produção (PCP), qualidade, supply chain, finanças e sustentabilidade. Procura-se, nesse contexto, a integração entre diferentes áreas com o objetivo de alcançar eficiência organizacional. Dentro dessa perspectiva, o PCP exerce papel estratégico ao definir o que, quanto e quando produzir ou prestar, coordenando recursos, estoques e prazos (ESPACIOS, 2017).

Essa função está diretamente relacionada à supply chain e às finanças, pois envolve o alinhamento de suprimentos, custos e prazos para garantir agilidade operacional e viabilidade econômica (SILVA et al., 2025). Na perspectiva da sustentabilidade, o PCP também contribui para a redução de desperdícios por meio de práticas como o planejamento eficaz, o controle de estoque, a manutenção preventiva e a aplicação de conceitos de produção enxuta (ESPACIOS, 2017).

Quando aplicado a operações de serviços, como *contact centers*, *helpdesks*, balcões de atendimento, clínicas e suporte técnico, o PCP adapta seus princípios para administrar fluxos de atendimento e recursos humanos. Essa adaptação permite planejar, programar e controlar a prestação de serviços de forma eficiente, assegurando qualidade e satisfação do usuário (SILVA et al., 2025). Apesar da relevância do tema, observa-se que a aplicação de métodos quantitativos de previsão ainda é mais difundida na indústria manufatureira do que no setor de serviços. No entanto, o crescimento da participação dos serviços na economia e a complexidade de operações de atendimento evidenciam a necessidade de aprofundar estudos nesse campo.

### 1.1 PREVISÃO DE DEMANDA EM SERVIÇOS

A previsão de demanda em serviços pode ser entendida como a estimativa, com base em dados históricos e variáveis externas, do volume futuro de atendimentos que uma operação deverá absorver em determinado horizonte temporal. A complexidade nesse setor é superior à da manufatura, uma vez que a impossibilidade de estocar serviços impõe a necessidade de equilíbrio dinâmico entre oferta e demanda, exigindo dimensionamento preciso da capacidade instalada (ALBRECHT et al., 2019).

Em operações de atendimento, como *call centers*, balcões bancários e serviços de saúde, a demanda apresenta comportamento altamente variável e sujeito a sazonalidades intradiárias, semanais e mensais. Esse comportamento gera séries temporais marcadas por flutuações de curto prazo e rupturas decorrentes de fatores externos, como alterações regulatórias, campanhas institucionais ou mudanças no perfil de consumo. Nesse sentido, os modelos de previsão em serviços devem ser calibrados para capturar padrões de alta frequência e reagir a mudanças abruptas no ambiente (ACKERMANN; SELITTO, 2022).

O desempenho da previsão, nesses casos, impacta não apenas métricas operacionais, mas também indicadores financeiros e de qualidade. Uma superestimativa gera custos adicionais de capacidade ociosa, enquanto a subestimativa resulta em filas, aumento do tempo de espera e perda de satisfação do cliente. Assim, a previsão de demanda torna-se um mecanismo essencial de suporte à decisão, auxiliando na programação de turnos, na alocação de equipes, na definição de níveis de serviço e no planejamento orçamentário (SAADI et al., 2017).

## **2 REVISÃO BIBLIOGRÁFICA: MÉTODOS DE PREVISÃO DE DEMANDA**

Existem duas grandes abordagens para previsão de demanda: as qualitativas e as quantitativas, que variam a depender do contexto e das informações disponíveis. Os métodos qualitativos partem de informações mais subjetivas, como a experiência de especialistas, pesquisas de mercado, entre outros, e são mais utilizados em situações de incerteza ou quando não há histórico de dados disponíveis ou em cenários com pouca quantidade de informações. Apesar de não terem a mesma estrutura estatística dos modelos quantitativos, possuem a vantagem de considerar fatores externos, tendências e expectativas futuras na abordagem (ROSSETTO, 2025).

Os métodos quantitativos se apoiam principalmente em análises estatísticas e uso de dados, buscando uma decisão mais objetiva e gerando previsões assertivas. No entanto, também possui limitações, especialmente quando se analisa cenários no longo prazo, devido à dificuldade em captar mudanças repentinas ou variações inesperadas do mercado. Assim, a escolha entre os métodos quantitativos e qualitativos deve considerar alguns fatores, como a disponibilidade de dados, horizonte de tempo, contexto e os objetivos da previsão (ROSSETTO, 2025).

A previsão de demanda consiste, portanto, em uma estimativa de valores futuros de consumo de bens ou serviços, com base em dados históricos e eventuais fatores causais, servindo como fundamento para o planejamento, que envolve definição de recursos, programação e alocação de atividades (ACKERMANN; SELLITTO, 2022).

O planejamento interpreta os resultados da previsão para estruturar ações estratégicas, táticas e operacionais. O horizonte de tempo das previsões pode ser categorizado, por exemplo, em curto prazo (até 1 ano), médio prazo (1 a 2 anos) e longo prazo (mais de 3 anos), sendo adequados para decisões distintas, como abastecimento, orçamento ou investimentos de longo prazo (ACKERMANN; SELLITTO, 2022).

Em ambientes de serviços, é comum observar sazonalidade intradiária (variações dentro do dia) e semanal (dias da semana mais movimentados), além de flutuações causadas por campanhas promocionais, fatores climáticos, alterações na folha de pagamento ou eventos do calendário

institucional, os quais devem ser incorporados ao modelo de previsão para melhorar a acurácia (ACKERMANN; SELBITTO, 2022).

## 2.1 MÉTODOS QUALITATIVOS

Os métodos qualitativos de previsão de demanda se baseiam principalmente em informações subjetivas, como a experiência de especialistas, percepções, conhecimentos práticos e observações do mercado. Essas técnicas não utilizam modelos estatísticos ou matemáticos, contudo, podem ser conduzidas de forma estruturada e com previsões confiáveis. Além disso, este método tem uma grande característica positiva que é a rapidez na aplicação, já que não depende de análises tão detalhadas. (ROSSETTO, 2025)

Esses métodos transformam opiniões e intuições em previsões mais acertadas, com os próprios especialistas atuando como os analistas, interpretando as informações disponíveis. Entre os métodos qualitativos mais comuns estão: Delphi, analogia histórica, pesquisas de mercado, opinião de executivos, entre outros. É importante destacar que usar uma única técnica pode não ser o suficiente para uma previsão acertada. Afinal, um método só dificilmente vai capturar todas as complexidades de um mercado. Por isso, a melhor estratégia é combinar diferentes métodos qualitativos para aumentar a precisão e diminuir a margem de erro nas previsões. Há diversos métodos qualitativos, entre os quais a pesquisa de mercado, analogia histórica e método DELPHI se destacam entre os métodos mais utilizados. (ROSSETTO, 2025).

### 2.1.1 Métodos qualitativos - analogia histórica

Este método utiliza como referências comportamentos e situações históricas com o objetivo de prever possíveis cenários futuros. A ideia central é que ao identificar eventos ou padrões semelhantes, é possível identificar uma tendência de mercado através de analogias estruturadas que comparam cenários passados com o contexto atual, ajudando a prever o comportamento do mercado. (ACKERMANN, 2022)

Neste método, um organizador prepara uma descrição detalhada de uma situação e seleciona especialistas com experiência direta no tema. Esses especialistas descrevem situações similares e compartilham exemplos de situações vivenciadas. Após esse processo, o organizador irá criar analogias com base na opinião de cada especialista, e consolidá-las em apenas uma visão geral que poderia explicar o comportamento do mercado. (ACKERMANN, 2022)

### 2.1.2 Métodos qualitativos - opinião de executivos

Como o próprio nome indica, o método é realizado com base nos conhecimentos e perspectivas dos executivos da empresa. Por atuarem diretamente em diversas áreas e possuírem uma visão integrada da organização, o método permite uma observação mais ampla e sistêmica do mercado e suas tendências. Essa técnica consiste em um grupo de executivos de diferentes setores que se reúnem para construir de forma colaborativa uma previsão, geralmente no longo prazo e alinhada com os planos estratégicos da organização. (ROSSETTO, 2025)

Uma das principais qualidades desse método é o aproveitamento da perspectiva de diferentes pessoas com experiências em temas diversos, mas com uma visão do todo, contribuindo para resultados mais qualificados e consistentes. Contudo, caso haja membros com forte influência nas decisões pode gerar opiniões enviesadas. Além disso, o elevado custo, tempo exigido dos executivos e o risco de que as previsões sejam alteradas sem o consenso de todos, podem comprometer a confiabilidade da previsão. Diferentemente do método de Delphi que busca a uniformidade através de especialistas externos, a opinião de executivos considera os líderes da própria empresa, ou seja, uma análise mais interna que também está alinhada com os objetivos estratégicos (ROSSETTO, 2025)

### 2.1.3 Métodos qualitativos – delphi

O método Delphi é uma das técnicas para previsão de demanda mais conhecidas, ela reúne a opinião de diversos especialistas para tomada de decisões, sem precisar necessariamente de encontros presenciais. Esse método é realizado através de diversas rodadas de questionário respondidas individualmente, sendo que a cada nova etapa, os especialistas recebem um resumo das respostas anteriores, permitindo que os analistas conheçam a visão dos outros e ajustem suas visões. (MARQUES, 2018)

Entre cada rodada, os pesquisadores analisam as tendências e divergências observadas e devolvem suas respostas revisadas do tema com o objetivo de construir uma resposta coletiva mais bem fundamentada e assertiva. Ao invés de fazer uma simples média das respostas, esse método busca criar um debate construtivo e compartilhado, não apenas gerando respostas e conclusões, mas que os especialistas explicam como chegaram a cada conclusão. (MARQUES, 2018)

Opiniões contrárias são o principal insumo para a reflexão de forma ampla, pois geram uma discussão maior e diferentes pontos de vista, assim, como o passar do tempo, as respostas tendem a se alinhar e chegar a um consenso confiável, sendo mais útil em situações de incerteza e complexidade, mas o conhecimento coletivo pode orientar decisões mais estratégicas e assertivas. (MARQUES, 2018)

## 2.2 MÉTODOS QUANTITATIVOS

Os métodos quantitativos de previsão da demanda visam estudar dados históricos a fim de projetar, numericamente, o comportamento do mercado (BASSI et al., 2022) Esses métodos são utilizados quando é possível obter dados confiáveis e bem ajustados à realidade, contudo, caso os dados sejam instáveis, os métodos qualitativos tornam-se uma alternativa melhor.

Os métodos quantitativos podem ser classificados em métodos causais e séries temporais.

### 2.2.1 Séries temporais

Os métodos de previsão utilizando séries temporais visam estudar um conjunto de dados no tempo e estimar valores em um ponto futuro. (MEISENBACHER, S., 2021) Normalmente, a aplicação desse método consiste na preparação dos dados, ajuste do modelo e previsão. Nas duas primeiras fases, faz-se importante explorar o comportamento da série para identificar a presença de nível, tendência e sazonalidade, pois são componentes que direcionam qual modelo utilizar para previsão, uma vez que existem modelos aplicáveis a séries sem tendência e sazonalidade, modelos aplicáveis a séries que há presença de tendência e outro destinado a dados com as três componentes.

#### 2.2.1.1 Métodos sem tendência e sem sazonalidade

O método da média móvel simples consiste em definir uma quantidade de períodos passados e calcular a média aritmética, gerando um valor de previsto para o próximo período. Após a conclusão do período projetado, deve-se substituir o valor mais antigo utilizado no cálculo pelo real, gerando a mobilidade da média. (BASSI et al., 2022). A eq. 1 mostra o cálculo da média móvel simples, no qual a projeção do período seguinte,  $P_{t+1}$  é dado pela média aritmética dos períodos anteriores  $D_t, D_{t-1}, \dots e D_{t-n+1}$  de  $n$  períodos.

$$P_{t+1} = M_t = \frac{(R_t + R_{t-1} + \dots + R_{t-n+1})}{n} \quad (\text{eq. 1})$$

Este método torna-se eficaz em séries temporais sem tendência e sazonalidade. Geralmente, os períodos utilizados para previsão são os valores mais recentes observados da demanda, de forma que todos os valores utilizados possuem pesos iguais.

O método de média móvel ponderada assemelha-se ao método simples acima, contudo atribui pesos diferentes aos valores de demanda utilizados na previsão, em que o último valor observado recebe, normalmente, o maior peso, seguido do penúltimo valor recebendo um peso menor e assim por diante, até o valor mais distante do período atual (BASSI et al., 2022). Desta forma, o método estabelece um critério na previsão, conforme a equação a seguir:

De forma semelhante, este método é eficaz em séries temporais com poucas oscilações. Além disso, também obtém bons resultados com pouca amplitude de dados, quando não é possível analisar e determinar o comportamento do produto com as informações disponíveis. A eq. 2 mostra a aplicação da média móvel ponderada, na qual a previsão para o próximo período  $P_{t+1}$  é dada pela soma dos produtos dos períodos anteriores pelos pesos atribuídos.

$$P_{t+1} = (D_t \times PE_1) + (D_{t-1} \times PE_2) + \dots + (D_{t-n+1} \times PE_n) \quad (\text{eq. 2})$$

Os métodos de suavização exponencial foram estudados, originalmente, em 1960 na segunda guerra mundial. Esses métodos introduzem os conceitos de nível, tendência e sazonalidade estudados na série temporal para gerar um valor projetado de demanda futura. (GARDNER JR., 2006)

A suavização exponencial simples é um método que possui duas formas de abordagem, no qual uma apresenta estrutura semelhante a média móvel ponderada utilizando os valores de períodos anteriores e crescendo ou decrescendo os pesos de acordo com o alfa ( $\alpha$ ) utilizado. A constante  $\alpha$  é chamada constante de suavização, que precisa ser um número positivo menor ou igual a 1. (HYNDMAN; ATHANASOPOULOS, 2021).

A eq. 3 mostra a equação de suavização, em que a projeção para o período seguinte  $P_{t+1}$  é dada pela média ponderada entre o valor real observado do período  $D_t$  e a previsão do período  $P_t$ , utilizando a constante de suavização  $\alpha$  como ponderador.

$$P_{t+1} = \alpha \times D_t + (1 - \alpha) \times P_t \quad (\text{eq. 3})$$

Este método é utilizado para previsão do componente de nível da série temporal e pode ser utilizado como projeção para períodos futuros em dados sem tendência e sazonalidade, contudo é amplamente utilizado em conjunto com os demais componentes descritos a seguir. (HYNDMAN; ATHANASOPOULOS, 2021)

### 2.2.1.2 Métodos com tendência e sem sazonalidade

O método de suavização exponencial dupla, também conhecido como método de Holt, é uma aprimoração da suavização simples, em que o componente de tendência foi adicionado com a variável beta ( $\beta$ ) como fator de suavização, em que  $0 \leq \beta \leq 1$ . (HYNDMAN; ATHANASOPOULOS, 2021)

Este método é eficaz para séries temporais com tendência bem definida, desta forma, a equação de previsão deixa de apresentar somente nível e passa a conter tendência, de forma que N períodos



futuros são definidos pelo nível observado adicionado da tendência multiplicada por N. (HYNDMAN; ATHANASOPOULOS, 2021)

A eq. 5 descreve a previsão por meio do modelo de holt, em que o valor de previsão no enésimo período  $P_{t+n}$  é dada pela soma das componentes nível  $L_t$  e  $n \times T_t$

$$P_{t+n} = L_t + n \times T_t \quad (\text{eq. 5})$$

A eq. 6 detalha o componente de nível  $L_t$  como sendo a constante de suavização de nível  $\alpha$  multiplicado pela demanda observada  $D_t$  somado da multiplicação entre  $1 - \alpha$  e a soma da componente de nível no período anterior  $L_{t-1}$  e o componente de tendência no período anterior  $T_{t-1}$ .

$$L_t = \alpha \times D_t + (1 - \alpha) * (L_{t-1} + T_{t-1}) \quad (\text{eq. 6})$$

Já a eq. 7 detalha o componente de tendência  $T_t$  como a constante de suavização de tendência  $\beta$  multiplicado pela diferença entre o componente de nível no instante período t e no período anterior  $L_t - L_{t-1}$  somado da multiplicação entre a tendência no instante anterior  $T_{t-1}$  e  $1 - \beta$ .

$$T_t = \beta * (L_t - L_{t-1}) + T_{t-1} * (1 - \beta) \quad (\text{eq. 7})$$

### 2.2.1.3 Métodos com tendência e sazonalidade

O método de Holt-Winter é a expansão da suavização exponencial tripla para adicionar o componente de sazonalidade com o fator de suavização  $\gamma$ , em que  $0 \leq \gamma \leq 1$ . Dessa forma o método possui uma equação de previsão e outras três de suavização para nível, tendência e sazonalidade. (HYNDMAN; ATHANASOPOULOS, 2021)

Além disso, o aperfeiçoamento também gerou duas abordagens, em que a primeira, a aditiva, é caracterizada por tendência constantes ao longo da série de dados, de forma independente dos demais componentes. (HYNDMAN; ATHANASOPOULOS, 2021)

A segunda abordagem do método, a multiplicativa, é caracterizada pela variação da sazonalidade que depende do nível e tendência, em que períodos futuros geram valores sazonais maiores. (HYNDMAN; ATHANASOPOULOS, 2021) A eq. 8 detalha relação entre os componentes de nível, tendência e sazonalidade para gerar a previsão, enquanto a eq. 9 aborda o cálculo do nível, a eq. 10 a tendência e a eq. 11 a sazonalidade.

$$P_{t+n} = (L_t + n \times T_t) \times S_{t+n-s} \quad (\text{eq. 8})$$

$$L_{t+1} = \alpha \times \frac{D_{t+1}}{S_{t+1-s}} + (1 - \alpha) \times (L_t + T_t) \quad (\text{eq. 9})$$

$$T_{t+1} = \beta \times (L_{t+1} - L_t) + (1 - \beta) \times T_t \quad (\text{eq. 10})$$

$$S_t = \gamma \times \frac{D_t}{L_t} + (1 - \gamma) \times S_{t-s} \quad (\text{eq. 11})$$

## 2.3 MÉTRICAS DE AVALIAÇÃO

A avaliação da acurácia de um modelo de previsão é fundamental para determinar sua eficácia e compará-lo com outros modelos. A escolha da métrica de avaliação deve ser cuidadosa, considerando as características da série temporal e os objetivos da previsão.

### 2.3.1 Erro absoluto médio (mae - mean absolute error)

O erro absoluto médio é uma das principais métricas para previsão de demanda, ela é representada pela média absoluta entre as observações previstas e as reais. Contudo, essa métrica não pondera fortemente os erros muito grandes, ou seja, esse erro pode acarretar um problema na medição, sendo assim, o MAE pode ser considerada uma métrica mais limitada para casos específicos em previsão de demanda, a eq. 12 apresenta a fórmula utilizada para o cálculo do Erro Absoluto Médio (MAE), conforme descrito acima (KUSTER, 2022).

A eq. 12 detalha os componentes do MAE, como sendo a soma das diferenças absolutas entre os valores observados ( $y_i$ ) e os valores previstos ( $p_i$ ) para cada observação ( $i$ ), dividida pelo número total de observações ( $n$ )

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - p_i| \quad (\text{eq.12})$$

### 2.3.2 Erro percentual absoluto médio (mape - mean absolute percentage error)

O MAPE expressa o erro como uma porcentagem do valor real, diferentemente do MAE. Essa métrica permite avaliar os erros de forma relativa, considerando o valor previsto e o real, mas apresentado de forma percentual. Essa métrica é utilizada por ser intuitiva e de fácil interpretação em questões de erros relativos, principalmente em contextos que se mede o desempenho em porcentagens. No entanto, esse método possui limitações quando os valores reais se aproximam de zero, gerando possíveis distorções ou valores infinitos, a eq. 13 apresenta a fórmula utilizada para o cálculo do Erro Percentual Absoluto Médio (MAPE), conforme descrito acima. (BEZERRA, 2024).

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left[ \frac{y_i - p_i}{y_i} \right] \quad (\text{eq. 13})$$

### 2.3.3 Raiz do erro quadrático médio (rmse - root mean squared error)

O RMSE é calculado por meio do cálculo da raiz quadrada da média dos erros ao quadrado, e fornece a dimensão média do desvio entre os valores previstos e os observados. Uma característica fundamental do RMSE é a sua sensibilidade a erros maiores, visto que penaliza severamente as discrepâncias maiores pelos valores estarem ao quadrado, a grande vantagem dessa métrica é a sua interpretação, já que seu resultado é expresso na mesma unidade da variável original, permitindo uma compreensão imediata da acurácia do modelo, a eq. 14 apresenta a fórmula utilizada para o cálculo do Raiz do Erro Quadrático Médio (RMSE), conforme descrito acima. (BEZERRA, 2024).

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - p_i)^2} \quad (\text{eq. 14})$$

## 3 METODOLOGIA

Este trabalho busca resolver um problema de previsão de demanda em um contexto real em uma empresa com contato com clientes. A abordagem escolhida é quantitativa, visto que é utilizado uma análise estatística com dados históricos.

### 3.1 CARACTERIZAÇÃO DO CENÁRIO E COLETA DE DADOS

Para desenvolver este estudo, foi permitido acesso aos dados de uma empresa no ramo bancário. Essas informações ficam armazenadas no banco de dados interno da empresa e registram a atividade dos diferentes setores de produção ao longo de dois anos e meio, sendo de janeiro de 2023 a junho de 2025, permitindo trabalhar com um intervalo de tempo de 2 anos e meio para análise.

Os dados fornecidos contêm 3 tipos de informações diferentes para cada registro, sendo eles: data do processamento, número da setores de trabalho e volume mensal processado. Foram escolhidas entre um total de 26 setores, os 4 setores são da fase intermediária do ciclo de vida do produto, tornando viável realizar um estudo de previsão baseado em séries temporais.

### 3.2 PREPARAÇÃO E ORGANIZAÇÃO DOS DADOS

Os dados foram extraídos diretamente do sistema da empresa e organizados em planilhas do Excel, sendo que cada setor ficou em uma aba separada, para facilitar a análise individual.

Na etapa seguinte, os dados foram divididos em dois grupos diferentes com propósitos diferentes. O primeiro, considerando um intervalo de tempo de janeiro de 2023 a março de 2025, servindo como modelo para ajustar a previsão e sendo utilizado para testar e desenvolver esse modelo.

Enquanto o segundo grupo, com dados de abril de 2025 a junho de 2025, foram utilizados exclusivamente para os testes finais, verificando a previsão do modelo e a sua acurácia versus os dados reais obtidos, para verificação se o resultado é confiável ou não para o resultado obtido em cada setor.

### 3.3 MODELOS DE PREVISÃO E PROCEDIMENTO DE AJUSTE

Para cada um dos setores, serão testados três métodos diferentes de previsão: a média móvel simples, a média móvel ponderada e o método de Holt-Winters. O objetivo é comparar como cada uma dessas técnicas se comporta diante dos dados analisados e em cada setor. Para cada setor, os modelos foram obtidos fazendo uso da ferramenta Solver do Excel. Esse processo permite encontrar os parâmetros para cada modelo, ajustando-os de forma a reduzir ao máximo os erros de previsão durante a fase de testes.

### 3.4 AVALIAÇÃO DA ACURÁCIA DOS MODELOS

Para avaliar a qualidade das previsões, será utilizado o Erro Percentual Absoluto Médio (MAPE). Essa métrica mostra em porcentagem, o quanto as previsões se desviam dos valores reais. O MAPE foi calculado em duas etapas distintas: primeiro durante o período de treinamento (2023-2024), para verificar se os modelos estavam capturando adequadamente os padrões históricos e depois no período de teste (abril - junho 2025), para avaliar como eles se saíram ao prever dados nunca vistos antes.

### 3.5 ANÁLISE COMPARATIVA E VALIDAÇÃO

A validação final consiste em comparar as previsões geradas para 2025 com os dados reais, buscando identificar para cada setor, o método mais adequado.

## 4 RESULTADOS E DISCUSSÕES

O trabalho trata da aplicação de conceitos e análise de resultados da previsão da demanda para 5 setores distintos de uma empresa de prestação de serviços.

São usados modelos de previsão com médias móveis, médias ponderadas e modelos de Holt-Winters para cada um dos 5 conjuntos de dados dos 5 setores em estudo.

#### 4.1 DEFINIÇÃO DOS SETORES

O estudo selecionou 5 setores distintos de uma empresa de prestação de serviços. Tais serviços, dentro da empresa, são definidos como atendimento “pós compra”, durante a vigência do serviço vendido ao consumidor.

A previsão de demanda, para cada um dos setores, trata do número de acessos a cada setor, em função das necessidades do cliente, para um serviço dentro da data de contratação deste. Os acessos são medidos mensalmente.

Os setores serão identificados, para o estudo, como A, B, C, D e E.

Os setores A e B tratam de “pós-venda” que envolve atualização contratual do serviço contratado enquanto os setores C, D e E tratam de tipos específicos de reclamação de “pós-venda” do produto contratado.

Dado isso, as informações foram organizadas em Excel para prévia análise e posterior aplicação dos modelos, apresentadas na tabela 1.

Tabela 1 - Horizonte de observações da volumetria mensal dos setores da empresa

<b>Tempo</b>	<b>A</b>	<b>B</b>	<b>C</b>	<b>D</b>	<b>E</b>
jan/23	379	2159	46	13	
fev/23	328	1963	75	8	
mar/23	393	2338	80	19	
abr/23	350	2059	75	12	
mai/23	387	2791	59	3	
jun/23	362	2510	52	6	
jul/23	429	2533	67	10	
ago/23	498	2342	72	9	
set/23	404	1870	86	12	
out/23	342	1936	75	14	
nov/23	348	1709	73	17	
dez/23	296	1837	56	20	4
jan/24	292	2168	66	26	5
fev/24	218	2134	45	8	135
mar/24	220	2033	53	8	312
abr/24	512	2228	64	10	284
mai/24	475	1868	55	8	546
jun/24	367	1772	59	1	406
jul/24	452	1812	53	11	409
ago/24	484	1779	51	4	490
set/24	486	1798	56	1	430
out/24	550	1995	58	5	522
nov/24	340	1713	66	2	375
dez/24	275	1659	58	2	374
jan/25	348	1795	64	3	353
fev/25	323	1791	59	1	320
mar/25	357	2180	58	2	266
abr/25	324	1774	57	2	437
mai/25	305	1738	57	2	622
jun/25	342	1662	65	3	321

Fonte: autoria própria (2025).

A partir da tabela 1, percebe-se que a quantidade de dados é inferior para o setor E, além disso há alta variabilidade nos seus valores. Sendo o período de análise inferior aos outros e variabilidade dos dados alta, exclui-se tal setor do uso de series temporais.

## 4.2 APLICAÇÃO DA METODOLOGIA

Utilizando o setor A como exemplo da aplicação da metodologia, os dados foram separados em 2 grupos, treino e teste. O grupo de treino consiste nas observações de 2023, 2024 e primeiro trimestre de 2025, que foram utilizadas para ajuste dos modelos aplicados. Após isso, foram aplicados os modelos obtidos pelo treinamento e calculada a métrica de erro MAPE para cada um destes modelos para os últimos 3 meses da base de dados, o grupo de teste. Considera-se o melhor modelo aquele com menor MAPE.

### 4.2.1 Média móvel simples

No método de média móvel simples, foram usados 3 modelos com períodos diferentes, 2 meses anteriores, 3 meses anteriores e 4 meses anteriores, denominados como MMS (2), MMS (3) e MMS (4), respectivamente. A tabela 2 mostra o desempenho de treinamento dos três modelos, isto é, são mostrados os resultados para os 3 modelos aplicados ao setor A.

Tabela 2 - Dados reais do setor A e testes de média móvel simples de 2, 3 e 4 períodos.

<b>Tempo</b>	<b>Dt</b>	<b>MMS (2)</b>	<b>MMS (3)</b>	<b>MMS (4)</b>
jan/23	379			
fev/23	328			
mar/23	393	354		
abr/23	350	361	367	
mai/23	387	372	357	363
jun/23	362	369	377	365
jul/23	429	375	366	373
ago/23	498	396	393	382
set/23	404	464	430	419
out/23	342	451	444	423
nov/23	348	373	415	418
dez/23	296	345	365	398
jan/24	292	322	329	348
fev/24	218	294	312	320
mar/24	220	255	269	289
abr/24	512	219	243	257
mai/24	475	366	317	311
jun/24	367	494	402	356
jul/24	452	421	451	394
ago/24	484	410	431	452
set/24	486	468	434	445
out/24	550	485	474	447
nov/24	340	518	507	493

dez/24	275	445	459	465
jan/25	348	308	388	413
fev/25	323	312	321	378
mar/25	357	336	315	322

Fonte: autoria própria (2025).

Com os dados da tabela 2, foi calculado a métrica de erro MAPE para posterior seleção de modelo com melhor ajuste, conforme tabela 3.

Tabela 3 - Métrica de erro MAPE calculada para os três testes de aplicação da média móvel simples.

Tempo	MMS (2)	MMS (3)	MMS (4)
jan/23	-	-	-
fev/23	-	-	-
mar/23	10%	-	-
abr/23	3%	5%	-
mai/23	4%	8%	6%
jun/23	2%	4%	1%
jul/23	13%	15%	13%
ago/23	21%	21%	23%
set/23	15%	6%	4%
out/23	32%	30%	24%
nov/23	7%	19%	20%
dez/23	17%	23%	34%
jan/24	10%	13%	19%
fev/24	35%	43%	47%
mar/24	16%	22%	31%
abr/24	57%	52%	50%
mai/24	23%	33%	35%
jun/24	34%	10%	3%
jul/24	7%	0%	13%
ago/24	15%	11%	7%
set/24	4%	11%	9%
out/24	12%	14%	19%
nov/24	52%	49%	45%
dez/24	62%	67%	69%
jan/25	12%	12%	19%
fev/25	4%	1%	17%
mar/25	6%	12%	10%
<b>MAPE ajuste</b>	<b>19%</b>	<b>20%</b>	<b>22%</b>

Fonte: autoria própria (2025).

Por fim, as previsões para 2025 foram realizadas com os modelos ajustados e, posteriormente, os erros MAPE foram calculados para avaliação de performance do modelo escolhido conforme tabelas 4 e 5, respectivamente.



Tabela 4 - Dados reais do setor A e previsões calculados com os modelos de média móvel simples para 2, 3 e 4 períodos.

<b>Tempo</b>	<b>Dt</b>	<b>MMS (2)</b>	<b>MMS (3)</b>	<b>MMS (4)</b>
abr/25	324	308	388	413
mai/25	305	308	388	413
jun/25	342	308	388	413

Fonte: autoria própria (2025).

Tabela 5 - Métrica de erro MAPE calculada para as três previsões de média móvel simples.

<b>Tempo</b>	<b>MMS (2)</b>	<b>MMS (3)</b>	<b>MMS (4)</b>
abr/25	5%	6%	1%
mai/25	11%	12%	7%
jun/25	1%	0%	5%
MAPE previsão	6%	6%	4%

Fonte: autoria própria (2025).

Os dados de MAPE de ajuste foram utilizados para selecionar, dentre as três médias móveis simples realizadas, o modelo que melhor se ajusta aos valores históricos. Estes não apresentaram grande diferença. Foi escolhido o modelo MMS (2) com 19% de erro. Após isso, analisando os dados da tabela 5 que mede o MAPE da previsão realizada com as médias móveis, é possível observar que o modelo selecionado, MMS (2), apresentou erro de 6% para o período previsto.

Além disso, na tabela 5, também é possível verificar que o modelo MMS (4) apresentou erro de previsão menor que o selecionado, MMS (2).

#### 4.2.2 Média móvel ponderada

No método de média móvel ponderada, foram criados 3 modelos semelhantes a aplicação da média móvel simples. Contudo, vale ressaltar que, conceitualmente, a MMP expande a MMS ao possibilitar a utilização de pesos diferentes para cada período, para isso foi utilizado o método GRG não linear no Solver do Excel para encontrar a solução ótima dos pesos considerando a minimização do MAPE de ajuste.

Sendo assim, a aplicação do método iniciou-se na criação de uma tabela para os pesos que serão utilizados no ajuste e otimizados pelo Solver, conforme tabela 6.



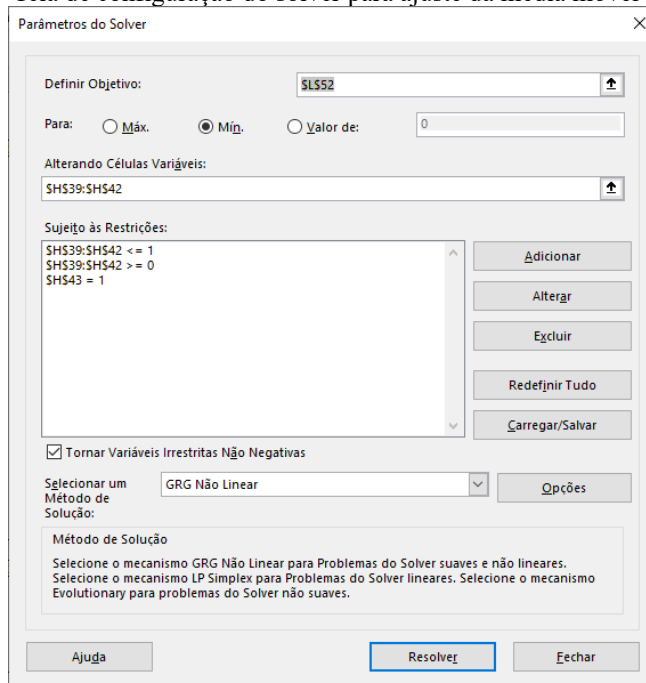
Tabela 6 - Pesos iniciais para ajuste e posterior utilização no método de média móvel ponderada.

<b>Pesos</b>	<b>MMP (2)</b>	<b>MMP (3)</b>	<b>MMP (4)</b>
PE4			0,00
PE3		0,00	0,00
PE2	0,00	0,00	0,00
PE1	0,00	0,00	0,00
<b>SOMA</b>	<b>0,00</b>	<b>0,00</b>	<b>0,00</b>

Fonte: autoria própria (2025).

Em sequência, para encontrar os pesos ótimos para minimizar o MAPE de ajuste, foi utilizado o solver de forma que  $0 \leq \text{Pesos} \leq 1$  e  $\sum \text{Pesos} = 1$ . Conforme figura 2.

Figura 1 - Tela de configuração do solver para ajuste da média móvel ponderada.



Fonte: autoria própria (2025).

Após isso, os pesos apresentados a seguir na tabela 7 foram gerados e utilizados para cálculo da previsão do período de 2025.

Tabela 7 - Pesos ajustados para utilização da previsão no método de média móvel ponderada.

<b>Pesos</b>	<b>MMP (2)</b>	<b>MMP (3)</b>	<b>MMP (4)</b>
PE4			0,00
PE3		0,13	0,13
PE2	0,13	0,00	0,00
PE1	0,87	0,87	0,87
<b>SOMA</b>	<b>1,00</b>	<b>1,00</b>	<b>1,00</b>

Fonte: autoria própria (2025).

Com isso, a tabela 8 foi construída utilizando três cenários de média móvel ponderada: 2, 3 e 4 meses anteriores. De forma semelhante, o cálculo da métrica de erro MAPE foi realizado na tabela 9 para utilizar como parâmetro de ajuste do modelo e posterior seleção do mais performático.

Tabela 8 - Dados reais do setor A e testes de média móvel ponderada de 2, 3 e 4 períodos.

<b>Tempo</b>	<b>Dt</b>	<b>MMP (2)</b>	<b>MMP (3)</b>	<b>MMP (4)</b>
jan/23	379			
fev/23	328			
mar/23	393	334		
abr/23	350	385	391	
mai/23	387	355	347	347
jun/23	362	382	388	388
jul/23	429	365	360	360
ago/23	498	421	424	424
set/23	404	489	481	481
out/23	342	416	407	407
nov/23	348	350	362	362
dez/23	296	347	355	355
jan/24	292	303	302	302
fev/24	218	293	299	299
mar/24	220	227	228	228
abr/24	512	220	229	229
mai/24	475	475	475	475
jun/24	367	480	443	443
jul/24	452	381	385	385
ago/24	484	441	455	455
set/24	486	480	469	469
out/24	550	486	482	482
nov/24	340	542	542	542
dez/24	275	367	358	358
jan/25	348	283	310	310
fev/25	323	339	347	347
mar/25	357	326	317	317

Fonte: autoria própria (2025).

Tabela 9 - Métrica de erro MAPE calculada para os três testes de aplicação da média móvel ponderada.

<b>Tempo</b>	<b>MMP (2)</b>	<b>MMP (3)</b>	<b>MMP (4)</b>
jan/23	-	-	-
fev/23	-	-	-
mar/23	15%		
abr/23	10%	12%	
mai/23	8%	10%	10%
jun/23	6%	7%	7%
jul/23	15%	16%	16%
ago/23	16%	15%	15%
set/23	21%	19%	19%
out/23	22%	19%	19%
nov/23	1%	4%	4%
dez/23	17%	20%	20%
jan/24	4%	3%	3%
fev/24	34%	37%	37%
mar/24	3%	4%	4%
abr/24	57%	55%	55%
mai/24	0%	0%	0%
jun/24	31%	21%	21%
jul/24	16%	15%	15%
ago/24	9%	6%	6%
set/24	1%	3%	3%
out/24	12%	12%	12%
nov/24	59%	59%	59%
dez/24	33%	30%	30%
jan/25	19%	11%	11%
fev/25	5%	7%	7%
mar/25	9%	11%	11%
<b>MAPE ajuste</b>	<b>17,6%</b>	<b>17,5%</b>	<b>17,8%</b>

Fonte: autoria própria (2025).

Considerando esses pesos para os modelos de previsão, foram geradas as tabelas 10 e 11, que representam a previsão para o período de 2025 e métrica de erro MAPE para avaliação da acuracidade.

Tabela 7 - Dados reais do setor A e previsões calculadas com os modelos de média móvel ponderada para 2, 3 e 4 períodos.

<b>Tempo</b>	<b>Dt</b>	<b>MMP (2)</b>	<b>MMP (3)</b>	<b>MMP (4)</b>
abr/25	324	353	356	356
mai/25	305	353	356	356
jun/25	342	353	356	356

Fonte: autoria própria (2025).

Tabela 8 - Métrica de erro MAPE calculada para as três previsões de média móvel ponderada.

<b>Tempo</b>	<b>MMP (2)</b>	<b>MMP (3)</b>	<b>MMP (4)</b>
abr/25	9%	10%	10%
mai/25	16%	17%	17%
jun/25	3%	4%	4%
<b>MAPE previsão</b>	<b>9%</b>	<b>10%</b>	<b>10%</b>

Fonte: autoria própria (2025).



Os dados da tabela 9 foram utilizados para selecionar o melhor modelo de média móvel ponderada dentre os três cenários gerados, selecionando o MMP com menor valor de MAPE de ajuste. Dessa forma, apesar da baixa variação nos resultados, o MMP (3) foi selecionado.

### 4.2.3 Holt-winters

De forma semelhante à média móvel ponderada, o método de Holt Winters também possui etapa de ajuste dos fatores. Neste caso, foram 3 componentes, alfa, beta e gama, que são responsáveis pela suavização dos componentes level, tendência e sazonalidade, respectivamente. A tabela 12 mostra os valores iniciais dos parâmetros, condições iniciais antes do ajuste.

Tabela 9 - Fatores de suavização iniciais para ajuste com o Solver.

<b>Pesos</b>	<b>Holt Winter</b>
Alfa	0,0
Beta	0,0
gama	0,0
<b>SOMA</b>	<b>0,0</b>

Fonte: autoria própria (2025).

O modelo de Holt Winters utilizado parte da premissa de sazonalidade anual. Foi preciso realizar o cálculo das componentes de “level”, tendência e sazonalidade, para elaboração do método de Holt Winters com o objetivo de ajustar o modelo através do método de erro MAPE, conforme tabelas 13 e 14, respectivamente.

Tabela 10 - Dados reais do setor A, componentes de level, tendência, sazonalidade e modelo de ajuste para Holt Winters.

<b>Tempo</b>	<b>Dt</b>	<b>Level</b>	<b>Tendência</b>	<b>Sazonalidade</b>	<b>Holt Winter</b>
jan/23	379	-	-	0,88	-
fev/23	328	-	-	0,71	-
mar/23	393	-	-	0,80	-
abr/23	350	-	-	1,13	-
mai/23	387	-	-	1,13	-
jun/23	362	-	-	0,95	-
jul/23	429	-	-	1,15	-
ago/23	498	-	-	1,28	-
set/23	404	-	-	1,16	-
out/23	342	-	-	1,17	-
nov/23	348	-	-	0,90	-
dez/23	296	376	1,08	0,75	-
jan/24	292	342	1,08	0,88	331
fev/24	218	313	1,08	0,71	245
mar/24	220	283	1,08	0,80	252
abr/24	512	421	1,08	1,13	319
mai/24	475	422	1,08	1,13	475
jun/24	367	393	1,08	0,95	403
jul/24	452	393	1,08	1,15	453
ago/24	484	381	1,08	1,28	505
set/24	486	411	1,08	1,16	444

out/24	550	460	1,08	1,17	480
nov/24	340	395	1,08	0,90	414
dez/24	275	374	1,08	0,75	295
jan/25	348	393	1,08	0,88	329
fev/25	323	441	1,08	0,71	281
mar/25	357	445	1,08	0,80	354

Fonte: autoria própria (2025).

Tabela 11 - Métrica de erro MAPE calculada para o método de ajuste do Holt Winters.

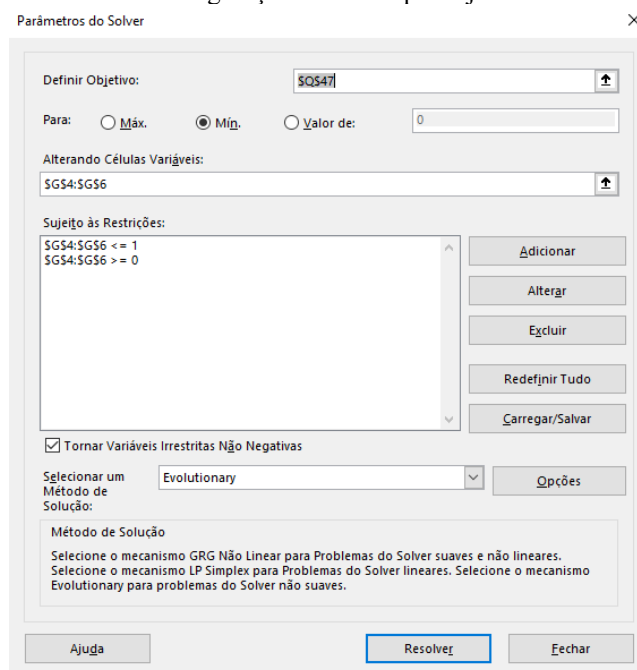
<b>Tempo</b>	<b>Holt Winter</b>
jan/23	-
fev/23	-
mar/23	-
abr/23	-
mai/23	-
jun/23	-
jul/23	-
ago/23	-
set/23	-
out/23	-
nov/23	-
dez/23	-
jan/24	13%
fev/24	12%
mar/24	14%
abr/24	38%
mai/24	0%
jun/24	10%
jul/24	0%
ago/24	4%
set/24	9%
out/24	13%
nov/24	22%
dez/24	7%
jan/25	6%
fev/25	13%
mar/25	1%
<b>MAPE ajuste</b>	<b>11%</b>

Fonte: autoria própria (2025).

Após construção das tabelas referentes ao ajuste do modelo, foi utilizado o Solver com o objetivo de atingir o valor ótimo dos componentes de suavização que minimizam o MAPE de ajuste, conforme figura 3. Com isso, foi obtida a tabela 15 com os parâmetros ajustados, que para este caso ficou igual aos parâmetros iniciais.



Figura 2 - Tela de configuração do solver para ajuste do Holt Winters.



Fonte: autoria própria (2025).

Tabela 12 - Fatores de suavização iniciais para ajuste com o Solver.

<b>Pesos</b>	<b>Holt Winter</b>
alfa	0,80
beta	0,00
gama	0,00
<b>SOMA</b>	<b>0,8</b>

Fonte: autoria própria (2025).

A partir do modelo ajustados com os componentes obtidos pelo ajuste, foi aplicado o método de previsão do Holt Winters e calculado o erro MAPE para avaliação da acuracidade da previsão, conforme tabela 16 e 17 a seguir, respectivamente.

Tabela 13 - Dados reais do setor A, componentes de level, tendência, sazonalidade e modelo de previsão para Holt Winters.

<b>Tempo</b>	<b>Dt</b>	<b>Holt Winter</b>
abr/25	324	502
mai/25	305	361
jun/25	342	268

Fonte: autoria própria (2025).

Tabela 14 - Métrica de erro MAPE calculada para o método de previsão do Holt Winters.

<b>Tempo</b>	<b>Holt Winter</b>
abr/25	58%
mai/25	88%
jun/25	52%
<b>MAPE previsão</b>	<b>66%</b>

Fonte: autoria própria (2025).

### 4.3 DESEMPENHO DOS MODELOS E PREVISÃO

Utilizando os dados obtidos dos modelos – parâmetros de ajuste, MAPE de ajuste e MAPE de previsão – foi possível avaliar a aplicabilidade e levantar hipóteses sobre as características do processo que impactam na utilização de séries temporais para previsão, já que dois setores se apresentaram suscetíveis ao modelo de Holt Winters, enquanto os demais apresentaram resultados satisfatórios apenas com os modelos de médias móveis.

Para chegar à conclusão supracitada, foi analisada a tabela 18, que contém os dados consolidados dos dois modelos com menor erro MAPE de ajuste para cada setor.

Tabela 18 – Parâmetros de ajuste, erro MAPE de ajuste e erro MAPE de resultado dos dois melhores modelos de cada setor

Setores	Método	N	Var1	Var2	Var3	Var4	MAPE calibração	MAPE resultado
A	MMP	3	0,87	0,00	0,13		17%	10%
A	MMP	4	0,87	0,00	0,13	0,00	17%	10%
B	Holt Winters	0	0,60	0,00	0,34		8%	10%
B	MMP	4	0,86	0,10	0,00	0,04	9%	23%
C	Holt Winters	0	0,26	0,00	0,00		13%	5%
C	MMP	3	0,52	0,39	0,09		13%	5%
D	MMP	3	0,60	0,00	0,40		94%	20%
D	MMP	4	0,60	0,00	0,40	0,00	96%	20%

Fonte: autoria própria (2025)

Analisando a tabela 18, foi possível agrupar o resultado do trabalho em dois blocos, os setores aderentes ao método de Holt-Winters e os setores aderentes ao método das médias móveis. Sendo assim, nos tópicos a seguir, será mostrado as justificativas levantadas para explicar a aderência aos respectivos métodos e a semelhança gráfica na série temporal.


#### 4.3.1 Setores aplicáveis ao modelo de holt-winters

Com a aplicação da metodologia explorada nos itens supracitados, os setores B e C apresentaram maior desempenho com a aplicação do modelo de Holt-Winters, explicadas pelas características observadas na análise gráfica da dos dados.

Com a análise gráfica do setor B, foi possível perceber tendência decrescente definida, com variabilidade acentuada no passado distante e redução no passado recente, fatores que contribuiram para um bom ajuste do modelo de suavização e previsão adequada para o futuro curto, conforme gráfico 1.




Gráfico 1 - Série temporal completa do setor B.



Fonte: autoria própria (2025).

De forma semelhante, a análise do setor C apresentou dados com tendência decrescente definida, contudo maior variabilidade dos dados, sobretudo nas observações iniciais da série temporal. Neste caso, é possível assumir que a redução na variabilidade teve grande importância nos resultados da previsão, sendo possível observar no gráfico 2.

Gráfico 2 - Série temporal completa do setor C.



Fonte: autoria própria (2025).

Em ambos os casos, a hipótese assumida é de processos perenes e com baixa interferência de otimização de recursos e automações, pois as variações nos dados foram baixas, possibilitando um bom ajuste do modelo, conforme apresentado na tabela 19.






Tabela 19 - Parâmetros de ajuste, MAPE de ajuste e MAPE de previsão do método de Holt-Winters para os setores B e C.

Setores	Método	Alfa	Beta	Gama	MAPE ajuste	MAPE resultado
B	Holt Winters	0,60	0,00	0,34	8%	10%
C	Holt Winters	0,26	0,00	0,00	13%	5%

Fonte: autoria própria (2025).

Com foco no setor B, o modelo capturou nível, conforme alfa apresentado, e leve sazonalidade, através do componente gama. O ajuste do modelo, apresentado pela linha vermelha, teve um MAPE de 8% que é considerado dentro dos critérios de aceite na empresa estudada, enquanto o MAPE de resultado foi de 10% e condiz com a linha verde, conforme observado no gráfico 3 abaixo.


Gráfico 3 - Série temporal, ajuste do modelo de Holt-Winters e resultado da previsão para o setor B.



Fonte: autoria própria (2025).

No caso do setor C, o modelo capturou a nível através do componente alfa, contudo não houve sensibilização aos componentes de tendência e sazonalidade, com isso obteve 8% no MAPE de ajuste e desempenho de 5% no resultado. O gráfico 4 apresenta o comparativo entre a demanda real, linha azul, valores obtidos pelo modelo na fase de ajuste que podem ser observados na linha vermelha e, por fim, os valores de previsão representados pela linha verde.

Gráfico 4 - Série temporal, ajuste do modelo de Holt-Winters e resultado da previsão para o setor C.



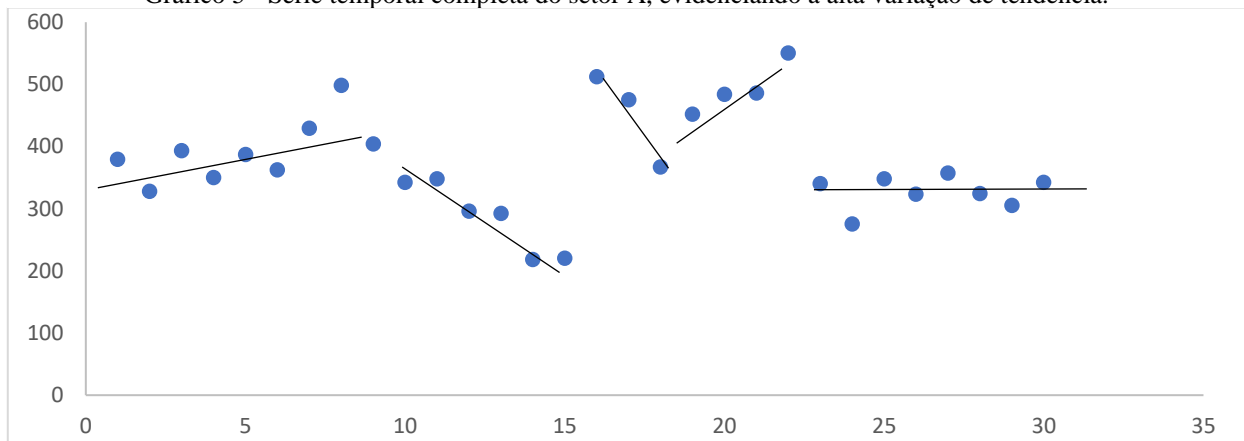
Fonte: autoria própria (2025).

Os resultados dos setores B e C foram satisfatórios, atendendo os critérios de aceite da empresa e possibilitando realizar previsões de curto prazo com boa assertividade. Além disso, vale ressaltar que, apesar do valor do componente de tendência ser igual a 0 nos dois casos, o ajuste do modelo já apresenta a tendência calculada que foi diferente de 0.

#### 4.3.2 Setores aplicáveis ao modelo médias móveis

Após análise do desempenho dos modelos nos setores A e D, ficou evidente que o modelo de Holt-Winters não obteve bom desempenho, sobretudo ao analisar a série temporal graficamente, no qual os setores apresentaram alta variância nos dados e mudanças constantes de tendência. O gráfico 5 apresenta a série temporal do setor A, sendo possível perceber a mudança constante de tendência com o passar dos meses, caracterizando um cenário em que o futuro não é explicado pelo passado de longo prazo.

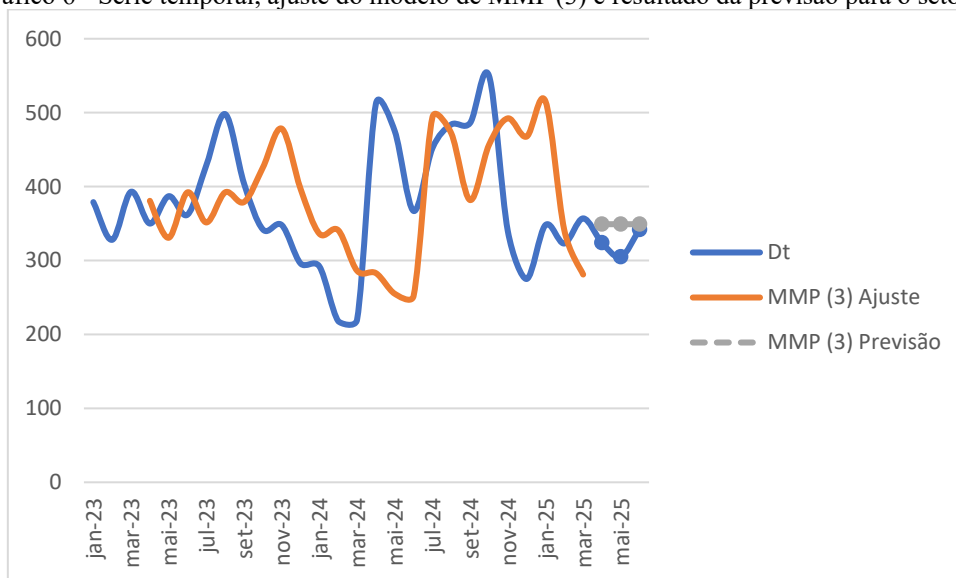
Gráfico 5 - Série temporal completa do setor A, evidenciando a alta variação de tendência.



Fonte: autoria própria (2025).

Neste cenário, o modelo de Holt-Winters obteve um bom ajuste nos dados para o setor A com o MAPE de ajuste de 8%, contudo o MAPE de previsão foi de 66%, gerando a necessidade de assumir o segundo melhor modelo no critério de MAPE de ajuste, a Média Móvel Ponderada de 3 períodos, que obteve ajuste de 17% e resultado de 10%, conforme apresentado no gráfico 6.


Gráfico 6 - Série temporal, ajuste do modelo de MMP (3) e resultado da previsão para o setor A.



Fonte: autoria própria (2025).

De forma semelhante, a análise gráfica do setor D apresentou características semelhantes ao setor A, com mudanças repentinas na tendência e alta variância nos dados. Além disso, vale destacar que o nível da série é menor em valores absolutos, acarretando erros maiores, conforme apresentado no gráfico 7.


Gráfico 7 - Série temporal completa do setor D, evidenciando a alta variação de tendência.



Fonte: autoria própria (2025).

Com isso, o modelo de MMP (3) obteve ajuste de 94% e previsão de 20%. Apesar do ajuste alto, é possível verificar na análise gráfica que a reta de ajuste se manteve próxima ao Dt, sendo assim, o método pode apresentar bons resultados na previsão de curto prazo, conforme apresentado no gráfico 8.

Gráfico 8 - Série temporal, ajuste do modelo de MMP (3) e resultado da previsão para o setor D.



Fonte: autoria própria (2025).

## 5 CONCLUSÃO


O presente trabalho teve como objetivo aplicar e comparar diferentes métodos quantitativos de previsão de demanda em setores produtivos de serviços, com foco no atendimento ao cliente. A partir da análise de dados históricos de uma empresa do setor bancário, foi possível compreender o comportamento da demanda em operações de pós-compra, caracterizadas por volumes variáveis e influenciados por fatores sazonais e comportamentais.

A aplicação dos modelos de média móvel simples, média móvel ponderada e Holt-Winters demonstrou que o desempenho das previsões depende diretamente das características da série analisada. Os métodos de média móvel apresentaram bons resultados em cenários de menor oscilação, oferecendo simplicidade de aplicação e fácil interpretação. Já o método de Holt-Winters destacou-se por incorporar os componentes de nível, tendência e sazonalidade, apresentando maior acurácia em séries com comportamento mais complexo e sazonal.

Os resultados obtidos confirmam que a previsão de demanda, quando estruturada de forma quantitativa e apoiada em técnicas estatísticas, é uma ferramenta essencial para o Planejamento e Controle da Produção (PCP) no setor de serviços. Ao permitir o dimensionamento mais preciso das equipes, a gestão dos recursos torna-se mais eficiente, reduzindo custos operacionais, tempos de espera e melhorando a experiência do cliente. Além disso, o estudo reforça a importância de adotar uma cultura analítica nas organizações, substituindo práticas empíricas por processos baseados em dados e indicadores de desempenho.

Do ponto de vista teórico, este trabalho contribui ao demonstrar a aplicabilidade de métodos clássicos de previsão de demanda em ambientes de serviço, um campo ainda pouco explorado quando comparado ao setor industrial. Sob a ótica prática, oferece uma metodologia replicável para empresas que enfrentam desafios semelhantes de variabilidade e dimensionamento operacional, especialmente em operações que envolvem atendimento direto ao consumidor.

Como proposta para estudos futuros, recomenda-se a ampliação da análise para outros setores produtivos e a incorporação de modelos preditivos mais sofisticados, como ARIMA, SARIMA ou técnicas de aprendizado de máquina, que podem capturar melhor padrões não lineares e melhorar a acurácia das previsões. Dessa forma, este trabalho representa um passo importante para o fortalecimento da tomada de decisão baseada em dados e para a evolução do planejamento operacional em serviços, consolidando a previsão de demanda como um elemento estratégico para a eficiência e competitividade organizacional.



**REFERÊNCIAS**

- ACKERMANN, A. E. F., & Sellitto, M. A. (2022) **Métodos de previsão de demanda: uma revisão da literatura**. *Innovar*, 32(85), 83-99. Disponível em: <<http://www.scielo.org.co/pdf/inno/v32n85/0121-5051-inno-32-85-83.pdf>>. Acesso em: 30 ago. 2025.
- ACKERMANN, A. E. F.; SELLITTO, M. A. Métodos de previsão de demanda: uma revisão da literatura. *Innovar*, v. 32, n. 85, p. 83-100, 2022. Disponível em: [https://www.researchgate.net/publication/358623651\\_Metodos\\_de\\_previsao\\_de\\_demanda\\_uma\\_revisao\\_da\\_literatura](https://www.researchgate.net/publication/358623651_Metodos_de_previsao_de_demanda_uma_revisao_da_literatura). Acesso em: 23 set. 2025.
- ALBRECHT, D. L. et al. **Modelo de previsão por séries temporais: aplicação para serviços comerciais em uma concessionária de energia elétrica**. *Iberoamerican Journal of Industrial Engineering*, Florianópolis, v. 11, n. 21, p. 14-29, 2019. Disponível em: <https://periodicos.ufsc.br/index.php/IJIE/article/view/v11n2102>. Acesso em: 23 set. 2025.
- BASSI, Renata Elaine; SILVA, Alex; CRUZ, Alexandro Araujo; TOGNOLLI, Marcos Cezar Souza. **A utilização da previsão de demanda em uma distribuidora de temperos alimentícios**. In: XIII FATECLOG – Os impactos das novas demandas pós-pandemia nos sistemas logísticos das organizações, 13., 2022, Mauá, SP. *Anais....* Mauá: Fatec Mauá, 2022. Disponível em: <https://fateclog.com.br/anais/2022/57-99-1-RV.pdf>. Acesso em: 31 ago. 2025.
- BENEVANTI, B. R. F. **Previsão de demanda: aspectos de horizonte temporal e componentes de séries temporais**. Universidade de Araraquara (Uniará), 2017. Disponível em: <https://m.uniara.com.br/arquivos/producao/prod-cadc4583c983c78f9cb03ec0a7ddaf1f.pdf>. Acesso em: 31 ago. 2025. Uniará
- BEZERRA, Francisco Diego Vidal. **Avaliação de métodos de ensemble dinâmico em aprendizado de máquina para previsões de irradiância solar e velocidade do vento – 2024**. 61. Dissertação (mestrado) – Universidade Federal do Ceará, Centro de Tecnologia, Programa de PósGraduação em Engenharia Mecânica, Fortaleza, 2024. Orientação: Prof. Dr. Paulo Alexandre Costa Rocha. Disponível em <[https://repositorio.ufc.br/bitstream/riufc/79234/3/2024\\_dis\\_fdvbezerra.pdf](https://repositorio.ufc.br/bitstream/riufc/79234/3/2024_dis_fdvbezerra.pdf)>. Acesso em: 30 ago. 2025
- ESPACIOS. **Planejamento e Controle da Produção (PCP)**. *Revista ESPACIOS*, v. 37, n. 27, 2016. Disponível em: <https://www.revistaespacios.com/a16v37n27/16372708.html>. Acesso em: 31 ago. 2025.
- ESPACIOS. **PPCP: sua abrangência e relação com as áreas produtivas**. *Revista ESPACIOS*, v. 38, n. 17, 2017. Disponível em: <https://www.l.revistaespacios.com/a17v38n17/17381736.html>. Acesso em: 31 ago. 2025.
- GARDNER JR., Everette S. **Exponential smoothing: The state of the art—Part II**. *International Journal of Forecasting*, v. 22, n. 4, p. 637–666, 2006. DOI: 10.1016/j.ijforecast.2006.03.005. Disponível em: <https://www.bauer.uh.edu/egardner/3301H%20Operations%20Management/ESG%20Publications/2006%20Exp.%20Sm.%20State%20of%20the%20art%20-%20Part%20II.pdf>
- HYNDMAN, Rob J.; ATHANASOPOULOS, George. 8.1 Suavização exponencial simples. In: HYNDMAN, Rob J.; ATHANASOPOULOS, George. **Previsão: princípios e prática**. 3. ed.

Melbourne: OTexts, 2021. cap. 8.1. Disponível em: <https://otexts.com/fpppg/ses.html>. Acesso em: 31 ago. 2025.

KUSTER, Janaina Silva Hastenreiter, 1992- **Estudos de correlações e comparações entre limites de liquidez de solos obtidos pelos métodos de Casagrande e cone** / Janaina Silva Hastenreiter Küster. - 2022. Küs269 f. : il. Disponível em <<https://dspace5.ufes.br/server/api/core/bitstreams/2384ad7a-b4fa-481a-8a38-527175604146/content>>. Acesso em: 30 ago. 2025

LIMA JÚNIOR, Pedro Pereira. **Previsão de demanda de veículos automotores através do modelo de regressão linear múltipla**. 2015. 64 f. Trabalho de Graduação (Engenharia Mecânica) — Faculdade de Engenharia do Campus de Guaratinguetá, Universidade Estadual Paulista, Guaratinguetá, 2015. Disponível em: <<https://repositorio.unesp.br/server/api/core/bitstreams/d82b02f1-5b99-46a8-831c-f7721a1ad4b1/content>>

MARQUES, Joana Brás Varanda; FREITAS, Denise de. **Método DELPHI: caracterização e potencialidades na pesquisa em Educação**. Pro-Posições, v. 29, n. 2, p. 389–415, 2018. Disponível em: <<https://www.scielo.br/j/pp/a/MGG8gKTQGhrH7czngNFQ5ZL/?format=html&lang=pt>> Acesso em: 28 ago. 2025.

METALÚRGICA PRO. **PCP e sustentabilidade: redução de desperdícios**. Metalúrgica Pro, Disponível em: <https://metalurgicapro.com.br/blog/gestao-industrial/pcp-e-sustentabilidade-reducao-de-desperdicios>. Acesso em: 31 ago. 2025.

ROSA, Douglas Larruscain da. **Previsão de demanda aplicada em setor de serviços**. Disponível em: <<https://dspace.ifrs.edu.br/xmlui/handle/123456789/702>>. Acesso em: 31 ago. 2025.

ROSSETTO, Marta. **Técnicas Qualitativas de Previsão de Demanda: um Estudo Multicasos com Empresas do Ramo de Alimentos**. Disponível em: <<https://www.aedb.br/seget/arquivos/artigos11/55814697.pdf>>. Acesso em: 28 ago. 2025.

ROSSETTO, R. **Previsão de demanda: métodos quantitativos e qualitativos**. São Paulo: Atlas, 2025.

SAADI, I. et al. An investigation into machine learning approaches for forecasting spatio-temporal demand in ride-hailing service. arXiv preprint, 2017. Disponível em: <https://arxiv.org/abs/1703.02433>. Acesso em: 23 set. 2025.

SILVA, Rafael Guilherme Fernandes de Lima. **Avaliação da Precisão dos Modelos ARIMA com e sem Transformação Estabilizadora da Variância na Previsão de Séries Temporais Anuais**. 2019. 10 f. Trabalho de Conclusão de Curso (Graduação em Gestão da Informação) – Universidade Federal de Uberlândia, Uberlândia, 2019. Disponível em: <<https://repositorio.ufu.br/bitstream/123456789/25547/1/Avalia%c3%a7%c3%a3oPrecis%c3%a3oModelos.pdf>>

SILVA, L. P. da; MALTA, P. H. F.; IRGOLICI, S. A.; ARAUJO, R. M. C. D. P. de. **Reflexões e perspectivas sobre a relevância do planejamento e controle da produção na área da logística: estudo de caso em uma indústria de peças automotivas na cidade de Barueri**. Revista Conecta, São Paulo, v. 8, n. Especial, p. 36–47, jun. 2025. Disponível em: <https://fatecrl.edu.br/revistaconecta/index.php/rc/article/view/332>. Acesso em: 31 ago. 2025.