

UNIVERSIDADE DE SÃO PAULO

ESCOLA POLITÉCNICA

GUSTAVO UEDA

ANÁLISE DE MODELOS DE PREVISÃO DE DEMANDA APLICADA AO VOLUME DE
PEDIDOS E RECEITA FATURADA

Trabalho de formatura apresentado à Escola
Politécnica da Universidade de São Paulo para
a obtenção do diploma de Engenheiro de
Produção.

São Paulo

2024

GUSTAVO UEDA

ANÁLISE DE MODELOS DE PREVISÃO DE DEMANDA APLICADA AO VOLUME DE
PEDIDOS E RECEITA FATURADA

Trabalho de formatura apresentado à Escola
Politécnica da Universidade de São Paulo para
a obtenção do diploma de Engenheiro de
Produção.

Orientador: Prof. Dr. Marcelo Schneck de
Paula Pessoa

São Paulo

2024

Aos meus amigos e familiares.

AGRADECIMENTOS

Gostaria de expressar minha sincera gratidão ao meu orientador, Prof. Dr. Marcelo Schneck de Paula Pessoa, por sua valiosa orientação, apoio e incentivo ao longo de todo o processo de elaboração deste Trabalho de Formatura. Sua paciência, sugestões enriquecedoras e constante disponibilidade foram essenciais para superar os desafios enfrentados. Este trabalho não teria sido possível sem sua experiência e dedicação.

Agradeço profundamente à minha família e aos amigos pelo suporte incondicional durante minha jornada acadêmica. Aos meus pais, por sempre acreditarem em mim e me motivarem a perseguir meus objetivos, e aos meus amigos, por estarem ao meu lado, proporcionando momentos de leveza e alegria que fizeram toda a diferença.

Por fim, deixo meu agradecimento à Escola Politécnica da Universidade de São Paulo pela oportunidade de desenvolver este Trabalho de Formatura. Um agradecimento especial ao Departamento de Engenharia de Produção, que ofereceu os recursos e a infraestrutura necessários para a realização deste estudo.

RESUMO

Este Trabalho de Formatura apresenta um estudo sobre métodos de previsão de demanda, com foco no volume de pedidos e receita da empresa fictícia PetVerso, atuante no mercado de e-commerce para pets. O objetivo é desenvolver e implementar um modelo estatístico robusto para aprimorar o método atual, baseado em intuição e médias simples, visando maior precisão nas projeções. Para este Estudo foram pesquisados diferentes métodos e modelos utilizados na previsão de demanda, dos quais foram selecionados 4 modelos para serem aprofundados: Média Móvel, Suavização Exponencial Simples, Holt e Holt-Winters. Adicionalmente, serão avaliados os erros das previsões e seus comportamentos em relação à tendência e sazonalidade. O Estudo conclui com a escolha do modelo ideal e sugestões de implementação e monitoramento para o aprimoramento estratégico da empresa.

Palavras-chave: Métodos de Previsão, Previsão de Demanda, E-Commerce, Erro de Previsão.

ABSTRACT

This Graduation Project presents a study on demand forecasting methods, focusing on the order volume and revenue of the fictional company PetVerso, which operates in the pet e-commerce market. The objective is to develop and implement a robust statistical model to improve the current method, which relies on intuition and simple averages, aiming for greater accuracy in projections. For this study, different methods and models used in demand forecasting were researched, and four models were selected for in-depth analysis: Moving Average, Simple Exponential Smoothing, Holt, and Holt-Winters. Additionally, forecasting errors and their behavior concerning trends and seasonality will be evaluated. The study concludes with the selection of the ideal model and recommendations for implementation and monitoring to enhance the company's strategic planning.

Keywords: Forecasting Methods, Demand Forecasting, E-Commerce, Forecast Error.

Lista de Gráficos

Gráfico 1: Volume de Pedidos realizado e Média Móvel para $n = 3$ ao longo dos meses.....	40
Gráfico 2: Volume de Pedidos realizado e Média Móvel para $n = 6$ ao longo dos meses.....	40
Gráfico 3: Volume de Pedidos realizado e Média Móvel para $n = 9$ ao longo dos meses.....	41
Gráfico 4: Erro Percentual Absoluto da Média Móvel em Pedidos ao longo dos meses.....	42
Gráfico 5: Receita realizada e Média Móvel para $n = 3$ ao longo dos meses.....	43
Gráfico 6: Receita realizada e Média Móvel para $n = 6$ ao longo dos meses.....	43
Gráfico 7: Receita realizada e Média Móvel para $n = 9$ ao longo dos meses.....	44
Gráfico 8: Erro Percentual Absoluto da Média Móvel em Receita ao longo dos meses	45
Gráfico 9: Volume de Pedidos realizado e SES para $\alpha = 0,47$ ao longo dos meses...	47
Gráfico 10: Receita realizada e SES para $\alpha = 0,50$ ao longo dos meses.....	47
Gráfico 11: Erro Percentual Absoluto da SES em Pedidos ao longo dos meses.....	48
Gráfico 12: Erro Percentual Absoluto da SES em Receita ao longo dos meses.....	48
Gráfico 13: Volume de Pedidos realizado e Suavização Exponencial de Holt para $\alpha = 0,43$ e $\beta = 0,35$ ao longo dos meses.....	51
Gráfico 14: Volume de Receita realizada e Suavização Exponencial de Holt para $\alpha = 0,49$ e $\beta = 0,25$ ao longo dos meses.....	51
Gráfico 15: Erro Percentual Absoluto da Suavização Exponencial de Holt em Pedidos ao longo dos meses.....	52
Gráfico 16: Erro Percentual Absoluto da Suavização Exponencial de Holt em Receita ao longo dos meses.....	52
Gráfico 17: Volume de Pedidos realizado e Suavização Exponencial de Holt-Winters para $\alpha = 0,78$, $\beta = 0,49$ e $\gamma = 1,00$ ao longo dos meses.....	55
Gráfico 18: Receita realizada e Suavização Exponencial de Holt-Winters para $\alpha = 0,85$, $\beta = 0,42$ e $\gamma = 0,00$ ao longo dos meses.....	56

Gráfico 19: Erro Percentual Absoluto da Suavização Exponencial de Holt-Winters em Pedidos ao longo dos meses.....	57
Gráfico 20: Erro Percentual Absoluto da Suavização Exponencial de Holt-Winters em Receita ao longo dos meses.....	57
Gráfico 21: Comparação da evolução do Volume de Pedidos e Modelos de Previsão.	58
Gráfico 22: Comparação da evolução da Receita e Modelos de Previsão.....	60

Lista de Tabelas

Tabela 1: Série Histórica de Pedidos e Receita da PetVerso.....	37
Tabela 2: Erro Médio Percentual para Média Móvel de Pedidos.....	41
Tabela 3: Erro Médio Percentual Absoluto para Média Móvel de Pedidos.....	41
Tabela 4: Erro Médio Percentual para Média Móvel de Receita.....	44
Tabela 5: Erro Médio Percentual Absoluto para Média Móvel de Receita.....	44
Tabela 6: Erros para SES em Pedidos.....	48
Tabela 7: Erros para SES em Receita.....	48
Tabela 8: Parâmetros alfa e beta para a previsão de Pedidos e Receita.....	49
Tabela 9: Erros para a Suavização Exponencial de Holt em Pedidos.....	52
Tabela 10: Erros para a Suavização Exponencial de Holt em Receita.....	52
Tabela 11: Parâmetros alfa, beta e gama para a previsão de Pedidos e Receita.....	53
Tabela 12: Erros para a Suavização Exponencial de Holt-Winters em Pedidos.....	55
Tabela 13: Erros para a Suavização Exponencial de Holt-Winters em Receita.....	55
Tabela 14: Erro Percentual Médio para a Previsão de Pedidos.....	58
Tabela 15: Maior Erro Percentual Absoluto para a Previsão de Pedidos.....	58
Tabela 16: MAPE para a Previsão de Pedidos.....	58
Tabela 17: Erro Percentual Médio para a Previsão de Receita.....	60
Tabela 18: Maior Erro Percentual Absoluto para a Previsão de Receita.....	60
Tabela 19: MAPE para a Previsão de Receita.....	60

Lista de Ilustrações

Figura 1: Exemplo do Modelo de Média Móvel.....	26
Figura 2: Exemplo do Modelo de Suavização Exponencial Simples.....	27
Figura 3: Exemplo do Modelo de Suavização Exponencial de Holt.....	28
Figura 4: Exemplo do Modelo de Suavização Exponencial de Holt-Winter.....	29

Sumário

1. Introdução.....	20
1.1. Descrição do problema.....	20
1.2. Objetivo do estudo.....	21
2. Revisão Bibliográfica.....	23
2.1. Sobre a previsão de demanda.....	23
2.2. Etapas da previsão de demanda.....	23
2.3. Modelos de previsão de demanda.....	24
2.3.1. Modelos qualitativos de previsão de demanda.....	25
2.3.1.1. Pesquisa de Mercado.....	26
2.3.1.2. Método Delphi.....	26
2.3.2. Modelos quantitativos de previsão de demanda.....	27
2.3.2.1. Média Móvel.....	27
2.3.2.2. Suavização Exponencial Simples (SES).....	29
2.3.2.3. Suavização Exponencial Holt.....	31
2.3.2.4. Suavização Exponencial Holt-Winter.....	32
2.4. Erros em modelos de previsão.....	33
2.4.1. Erro Médio (ME).....	33
2.4.2. Erro Médio Absoluto (MAE).....	33
2.4.3. Erro Médio Quadrado (MSE).....	34
2.4.4. Erro Médio Percentual Absoluto (MAPE).....	34
2.4.5. Erro Médio Percentual (MPE).....	35
3. Método de Aplicação dos Modelos Preditivos.....	37
3.1. Coleta de dados.....	37
3.2. Análise dos Resultados.....	37
4. Aplicação e análises dos modelos de previsão.....	39
4.1. Média Móvel.....	41
4.1.1. Resultados do modelo de Média Móvel.....	41
4.2. Suavização Exponencial Simples (SES).....	47

4.2.1. Resultados do modelo de Suavização Exponencial Simples (SES).....	48
4.3. Suavização Exponencial de Holt.....	51
4.3.1. Resultados do modelo de Suavização Exponencial de Holt.....	52
4.4. Suavização Exponencial de Holt-Winter.....	55
4.4.1. Resultados do Modelo de Suavização Exponencial Holt-Winter.....	57
5. Análise Comparativa e Modelo Escolhido.....	61
5.1. Análise Comparativa.....	61
5.2. Critérios para Escolha do Modelo e Modelo Escolhido.....	66
5.3. Implementação do Modelo.....	66
6. Conclusões e Próximos Passos.....	69
6.1. Conclusão.....	69
6.2. Próximos Passos.....	70
7. Referências Bibliográficas.....	72

1. Introdução

Este trabalho de formatura se fundamentará nos estudos de métodos preditivos utilizados no planejamento e controle da produção, com foco na previsão de pedidos e receita de uma empresa. A pesquisa será conduzida em uma empresa fictícia, denominada PetVerso, que opera no segmento de comércio eletrônico voltado para o mercado pet, disponibilizando uma vasta gama de produtos e serviços para pets, incluindo alimentos, brinquedos, acessórios e produtos de higiene, além de serviços personalizados como assinaturas e entregas em casa.

A análise se baseará em dados de vendas passadas e em modelos de previsão de demanda, visando a estimativa precisa do volume de pedidos e da receita prevista para períodos futuros. Esta previsão possibilitará uma compreensão mais aprofundada do comportamento da demanda, auxiliando no planejamento estratégico da companhia em setores como logística, armazenamento e campanhas de marketing. Assim, o estudo pretende evidenciar a relevância dos métodos preditivos na melhoria de processos de empresas do segmento de comércio online para pets, visando aumentar sua eficácia e rentabilidade.

1.1. Descrição do problema

A área de Revenue Management da PetVerso é responsável por realizar a projeção de pedidos e receita para um período de 6 meses, e essas projeções servem como metas e influenciam decisões estratégicas importantes da empresa. No entanto, o método atual de previsão não segue um padrão bem definido, misturando intuição de negócio e médias de dados passados, sem o suporte de um modelo estatístico confiável. Como resultado, há uma grande diferença entre os valores previstos e os resultados reais, o que dificulta a precisão das projeções e afeta diretamente o planejamento estratégico. Isso aponta para a necessidade de melhorar o processo de previsão, buscando maior precisão nas estimativas e, conseqüentemente, decisões mais alinhadas com a realidade do mercado.

1.2. Objetivo do estudo

O objetivo deste trabalho é analisar os diversos métodos de previsão de demanda por meio de uma revisão bibliográfica sobre o tema e implementar um modelo de previsão estatisticamente robusto para melhorar a projeção de pedidos e receitas da PetVerso, com base em uma análise detalhada da série histórica de dados da empresa. Atualmente, as previsões são feitas utilizando métodos não padronizados e sem o suporte de um modelo preditivo formal, o que gera discrepâncias significativas entre os valores projetados e os realizados. Este estudo busca explorar e comparar diferentes técnicas de modelagem preditiva.

Além de analisar a precisão dessas técnicas, o trabalho também se propõe a avaliar os fatores que mais impactam a previsão de pedidos e receitas, como sazonalidade e tendência. A intenção é fornecer um modelo preditivo que não só melhore a precisão das estimativas, mas também seja de fácil implementação e aplicabilidade dentro da rotina da equipe de revenue management.

Ao final, o modelo proposto servirá como uma ferramenta para embasar decisões estratégicas, melhorar a alocação de recursos e minimizar o risco de variações significativas entre as metas estabelecidas e os resultados obtidos. Assim, espera-se que o novo modelo contribua diretamente para o crescimento da empresa e uma gestão mais assertiva de suas operações.

2. Revisão Bibliográfica

2.1. Sobre a previsão de demanda

Segundo Hanke e Wichern (2014), a previsão de demanda desempenha um papel fundamental em várias áreas de decisão dentro de uma organização. Primeiramente, a previsão de demanda ajuda os gestores a tomarem decisões em condições de incerteza, oferecendo estimativas que permitem ajustar operações de acordo com as expectativas futuras. Isso é essencial para o planejamento de produção, gestão de estoques e definição de estratégias de marketing. Com uma previsão precisa, a empresa pode ajustar sua capacidade produtiva e alocação de recursos de maneira eficiente, mitigando riscos e otimizando resultados.

Além disso, a previsão de demanda é crucial para o planejamento de políticas e estratégias. A capacidade de prever a demanda futura permite que uma empresa organize suas operações de forma mais eficaz, evitando tanto a falta quanto o excesso de produtos. Ao prever corretamente as necessidades do mercado, a empresa pode evitar custos desnecessários, como o acúmulo de estoques excessivos ou a interrupção de vendas por falta de produtos, o que impacta diretamente sua lucratividade.

Outro ponto importante ressaltado por Hanke e Wichern (2014) é que a previsão da demanda promove uma melhor coordenação entre diferentes departamentos da empresa. Áreas como finanças, logística, marketing e produção dependem de previsões acuradas para planejar suas atividades e atingir suas metas. Dessa forma, a previsão da demanda serve como uma ferramenta de integração organizacional, permitindo que todos os setores trabalhem em harmonia em torno de um objetivo comum.

2.2. Etapas da previsão de demanda

Para a implementação de um sistema de previsão de demanda, é essencial seguir um processo estruturado que integra várias etapas fundamentais. Conforme descrito por Pellegrini e Fogliatto (2001), o desenvolvimento de um sistema de

previsão inicia-se pela definição do problema, onde se identifica o objetivo do sistema e o nível de detalhe necessário para as previsões, considerando a estrutura organizacional da empresa. Em seguida, na etapa de coleta de informações, são obtidos dados históricos e qualitativos, que formam a base para a modelagem matemática e a validação prática das previsões. Esses dados são organizados em bancos de dados que permitem segmentação através de filtros, como por regiões ou tipos de clientes.

A seleção de ferramentas computacionais adequadas é a próxima fase. Aqui, é importante escolher um software que ofereça precisão nas previsões e que sejam compatíveis com os sistemas da empresa, facilitando a análise de grandes quantidades de séries temporais. Em seguida, é realizada uma análise preliminar das séries temporais, buscando padrões, tendências e identificando valores atípicos que possam comprometer a qualidade das previsões.

A escolha e validação dos modelos é um dos momentos mais críticos do processo. A seleção do modelo depende do comportamento da série temporal em estudo. Modelos de suavização exponencial são úteis para séries com tendência e sazonalidade, enquanto os modelos ARIMA são mais indicados para séries complexas. A validação é feita comparando a precisão das previsões através de indicadores como o Erro Médio Absoluto (MAE) e o Erro Percentual Absoluto Médio (MAPE). Por fim, é necessário realizar a verificação e manutenção do sistema, ajustando os modelos com a incorporação de novos dados, garantindo que as previsões reflitam mudanças nas demandas futuras.

2.3. Modelos de previsão de demanda

Pellegrini e Fogliatto (2001) definem os métodos quantitativos e qualitativos de previsão de demanda com base em suas abordagens distintas para a análise e projeção de dados. Os métodos quantitativos, também conhecidos como métodos de forecasting, utilizam técnicas matemáticas e estatísticas para analisar séries temporais, isto é, dados históricos que refletem a demanda ao longo do tempo. Esses métodos são baseados em modelos formais que projetam padrões e tendências observados em dados passados para períodos futuros. Entre os

principais métodos quantitativos destacam-se os modelos de suavização exponencial, como o de Holt-Winters, e os modelos Box-Jenkins (ARIMA), que são particularmente úteis em situações onde há dados históricos suficientes e uma suposição de continuidade dos padrões observados. A vantagem desses métodos está na sua objetividade e precisão, especialmente quando se trata de séries temporais com características regulares, como tendência e sazonalidade.

Por outro lado, os métodos qualitativos baseiam-se em julgamentos subjetivos e na opinião de especialistas, sendo amplamente utilizados em cenários onde não há dados históricos suficientes ou quando a previsão envolve fatores difíceis de quantificar. Esses métodos incluem técnicas como o método Delphi ou o uso da Pesquisa de mercado. Apesar de sua ampla aplicação, especialmente em situações de incerteza ou mudanças bruscas de mercado, Pellegrini e Fogliatto apontam que os métodos qualitativos têm um grau de precisão geralmente menor, pois são mais suscetíveis a vieses e influências subjetivas.

A relevância da distinção entre métodos quantitativos e qualitativos é destacada por Pellegrini e Fogliatto (2001), que enfatizam a importância de uma abordagem integrada para maximizar a precisão das previsões de demanda. Enquanto os métodos quantitativos fornecem uma base sólida e objetiva para a previsão, os métodos qualitativos complementam essa análise ao incorporar insights contextuais e antecipar fatores não capturados pelos dados históricos. A combinação dessas abordagens pode resultar em previsões mais robustas e adaptáveis às dinâmicas do mercado.

A escolha entre métodos quantitativos e qualitativos depende, portanto, da disponibilidade de dados e do contexto de aplicação, mas os autores sugerem que, sempre que possível, as organizações devem adotar métodos quantitativos para obter previsões mais confiáveis e embasadas.

2.3.1. Modelos qualitativos de previsão de demanda

Os métodos qualitativos de previsão de demanda são abordagens que se baseiam em informações subjetivas, conhecimentos e opiniões de especialistas.

Eles são particularmente úteis quando há falta de dados históricos, como em situações de lançamento de novos produtos ou em mercados voláteis. Segundo Armstrong (2001), esses métodos oferecem insights valiosos ao incorporar fatores que podem não ser capturados por métodos quantitativos. Dois métodos qualitativos amplamente utilizados são a pesquisa de mercado e a técnica Delphi.

2.3.1.1. Pesquisa de Mercado

A pesquisa de mercado é uma ferramenta fundamental para a coleta de dados diretamente dos consumidores, oferecendo uma visão aprofundada das necessidades, desejos e intenções de compra. Armstrong (2001) destaca que este método envolve a utilização de entrevistas, questionários e observação direta para reunir informações sobre o comportamento e as preferências do consumidor. Os dados coletados são então analisados para identificar padrões e prever a demanda de produtos ou serviços.

Esse método é especialmente valioso para empresas que buscam entender o mercado antes de lançar novos produtos, pois permite que elas adaptem suas estratégias de acordo com a resposta dos consumidores. A pesquisa de mercado também pode segmentar os dados por demografia, região e outros fatores, proporcionando uma visão detalhada de diferentes segmentos de consumidores. No entanto, Armstrong observa que este método pode ser caro e demorado, além de depender da qualidade e da representatividade dos dados coletados.

2.3.1.2. Método Delphi

A técnica Delphi é um método estruturado que se baseia na opinião de especialistas para prever a demanda em situações onde há grande incerteza ou falta de dados históricos. De acordo com Rowe e Wright (2001), este método utiliza um painel de especialistas que respondem a uma série de questionários anônimos em várias rodadas. Após cada rodada, um resumo das respostas é compartilhado com o grupo, permitindo que os especialistas revisem suas previsões com base nas

opiniões dos demais. Esse processo continua até que se atinja um consenso ou uma convergência nas respostas.

Armstrong (2001) enfatiza que a técnica Delphi é eficaz para reduzir vieses individuais e alcançar uma previsão mais precisa, especialmente em cenários como o desenvolvimento de novas tecnologias ou mudanças significativas no mercado. A anonimidade dos participantes é uma característica essencial deste método, pois ajuda a evitar que especialistas influenciam uns aos outros, promovendo uma avaliação mais objetiva.

2.3.2. Modelos quantitativos de previsão de demanda

Os métodos quantitativos de previsão de demanda baseiam-se em dados históricos e em técnicas matemáticas para gerar previsões precisas e objetivas. Esses métodos são ideais para situações em que há uma quantidade substancial de dados disponíveis e onde a demanda é relativamente estável ao longo do tempo. Segundo Armstrong (2001), a previsão quantitativa de demanda depende da identificação de padrões e da análise de séries temporais, que permitem projetar tendências, sazonalidades e outros comportamentos passados para o futuro. Esses métodos são capazes de capturar variações complexas nos dados ao longo do tempo, tornando-se ferramentas indispensáveis em ambientes de negócios onde decisões baseadas em dados são essenciais. Através do uso de modelos estatísticos, os métodos quantitativos oferecem uma abordagem sistemática para antecipar demandas futuras, permitindo que as empresas otimizem seus processos operacionais e melhorem a eficiência no gerenciamento de estoques, produção e vendas. Este estudo terá foco nos modelos de previsão com base na Suavização Exponencial e Média Móvel.

2.3.2.1. Média Móvel

A média móvel simples é uma das técnicas mais utilizadas para a previsão de demanda, principalmente por sua simplicidade e facilidade de implementação. De acordo com Peinado e Graeml (2007), a média móvel simples é indicada para séries

temporais onde não há uma tendência clara ou sazonalidade, sendo aplicada frequentemente em contextos onde a demanda do produto ou serviço se mantém relativamente estável ao longo do tempo.


A média móvel simples calcula a média aritmética dos últimos n períodos de uma série temporal, eliminando as flutuações de curto prazo e proporcionando uma visão mais clara do comportamento da demanda. A cada novo período, o valor mais antigo é descartado e o mais recente é adicionado, mantendo constante o número de períodos considerados para a previsão.

Esse método atribui o mesmo peso a todos os períodos utilizados no cálculo, assumindo que os eventos passados têm a mesma importância para a previsão do próximo período (PEINADO; GRAEML, 2007).

Entre as vantagens da média móvel simples está sua capacidade de suavizar variações aleatórias de curto prazo, oferecendo uma previsão mais estável e fácil de interpretar. Além disso, sua simplicidade a torna de fácil aplicação e compreensão, mesmo em ambientes com pouca sofisticação tecnológica ou acesso limitado a ferramentas estatísticas avançadas.

No entanto, a média móvel simples apresenta algumas limitações. Como destaca Peinado e Graeml (2007), este método não é adequado para séries temporais com tendências ou sazonalidades, uma vez que não consegue capturar mudanças sistemáticas na demanda ao longo do tempo. Além disso, o número de períodos (n) escolhido pode influenciar a precisão da previsão: um n muito pequeno pode resultar em previsões mais sensíveis a variações aleatórias, enquanto um n muito grande pode tornar a previsão lenta para reagir a mudanças recentes no comportamento da demanda.

Figura 1: Exemplo do Modelo de Média Móvel



Fonte: Hyndman, R.J., & Athanasopoulos, G. (2018) Forecasting: principles and practice, 2nd edition, OTexts: Melbourne, Australia. OTexts.com/fpp2. Acesso em: 29 out. 2024.

2.3.2.2. Suavização Exponencial Simples (SES)


A suavização exponencial simples (SES) é uma técnica de previsão amplamente utilizada em séries temporais que não apresentam tendências ou sazonalidade clara. Segundo Armstrong (2001), este método é particularmente eficaz quando se deseja dar mais ênfase aos dados mais recentes, assumindo que eles são mais representativos para prever o futuro, enquanto os dados mais antigos têm menor relevância. A SES se destaca pela simplicidade de aplicação, ao mesmo tempo em que oferece resultados robustos em determinados contextos de previsão.

A metodologia baseia-se no uso de um fator de suavização, representado pela letra grega α , que varia entre 0 e 1. Este fator controla o peso atribuído aos novos dados: quanto maior o valor de α , maior será a ênfase nos dados mais recentes. De acordo com Armstrong (2001), a escolha apropriada do valor de α é crucial, pois um valor mais alto pode resultar em previsões mais sensíveis às últimas observações, o que pode ser benéfico em ambientes com mudanças rápidas. Entretanto, ele alerta que essa sensibilidade pode ser prejudicial em previsões de longo prazo, transmitindo ruídos ou choques aleatórios para o futuro, levando a previsões instáveis.

Armstrong também aponta que, embora a SES seja eficaz para dados estáveis e sem grande variação ao longo do tempo, ela pode não ser a melhor escolha para séries com tendências ou sazonalidade. Em tais casos, métodos mais avançados de suavização, como a suavização exponencial dupla ou a suavização de Holt-Winters, podem ser mais adequados.

Gardner (1985), citado por Armstrong, realiza uma revisão extensa sobre técnicas de suavização exponencial, destacando que o uso correto da SES depende de uma calibração cuidadosa do fator de suavização e da avaliação contínua da performance do modelo. A escolha do α deve ser feita considerando o comportamento dos dados e o horizonte de previsão. Uma vez implementada corretamente, a SES oferece uma abordagem simples e eficiente para lidar com dados que apresentam ruído e variabilidade moderada.

Figura 2: Exemplo do Modelo de Suavização Exponencial Simples




Fonte: Hyndman, R.J., & Athanasopoulos, G. (2018) Forecasting: principles and practice, 2nd edition, OTexts: Melbourne, Australia. OTexts.com/fpp2. Acesso em: 29 out. 2024.

2.3.2.3. Suavização Exponencial Holt

A suavização exponencial dupla, também conhecida como método de Holt, é uma extensão importante da suavização exponencial simples. Enquanto a suavização exponencial simples é eficaz em séries temporais que não apresentam tendência ou sazonalidade, a suavização exponencial dupla foi desenvolvida para lidar especificamente com séries temporais que possuem uma tendência linear. Segundo Armstrong (2001), este método utiliza dois parâmetros de suavização para ajustar tanto o nível quanto a tendência dos dados ao longo do tempo, oferecendo uma solução eficaz para séries que exibem uma direção ascendente ou descendente.

O valor de α (entre 0 e 1) controla a rapidez com que o modelo ajusta o nível da série em resposta a novas observações, enquanto β ajusta a taxa de resposta do modelo às mudanças na tendência. Valores maiores de α e β tornam o modelo mais sensível às alterações recentes, enquanto valores menores resultam em previsões mais estáveis.

Figura 3: Exemplo do Modelo de Suavização Exponencial de Holt



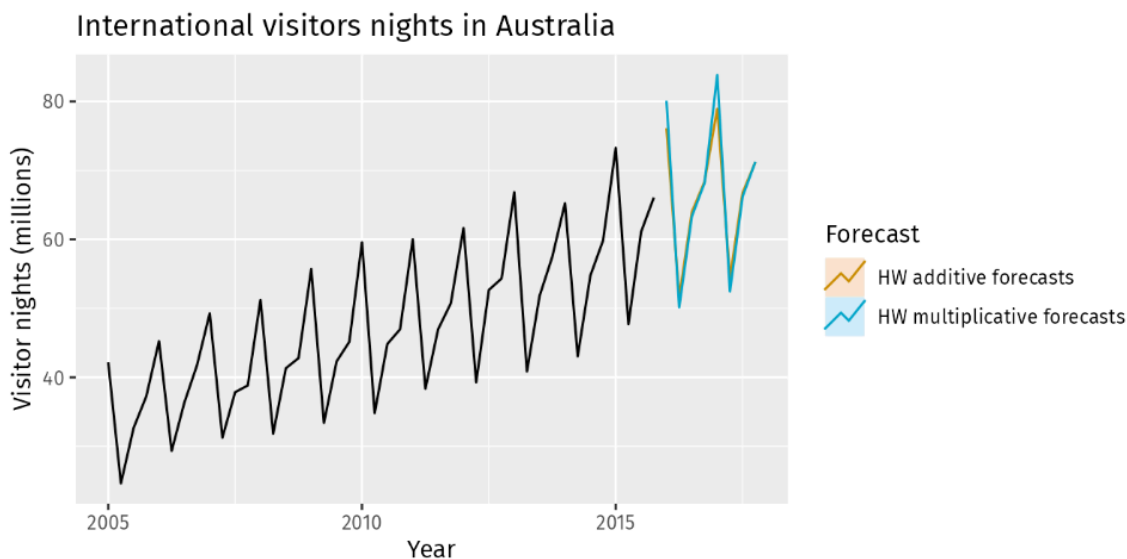
Fonte: Hyndman, R.J., & Athanasopoulos, G. (2018) Forecasting: principles and practice, 2nd edition, OTexts: Melbourne, Australia. OTexts.com/fpp2. Acesso em: 29 out. 2024.

2.3.2.4. Suavização Exponencial Holt-Winter

A suavização exponencial tripla, ou método de Holt-Winters, é uma extensão dos modelos de suavização exponencial simples e dupla, projetada para lidar com séries temporais que apresentam tanto tendência quanto sazonalidade. Segundo Armstrong (2001), o método Holt-Winters se destaca por sua capacidade de gerar previsões em cenários onde a demanda varia ao longo do tempo de forma não apenas linear, mas também sazonal, proporcionando uma solução robusta para séries temporais complexas.

O método Holt-Winters pode ser utilizado em sua forma multiplicativa quando a magnitude das flutuações sazonais varia proporcionalmente ao nível da série. Em tal caso, a sazonalidade é multiplicada pelo nível e pela tendência, resultando em um comportamento mais realista em séries temporais onde as variações sazonais crescem junto com o nível da demanda. Essa abordagem oferece maior flexibilidade e precisão para prever séries temporais com comportamento sazonal variável.

Figura 4: Exemplo do Modelo de Suavização Exponencial de Holt-Winter



Fonte: Hyndman, R.J., & Athanasopoulos, G. (2018) Forecasting: principles and practice, 2nd edition, OTexts: Melbourne, Australia. OTexts.com/fpp2. Acesso em: 29 out. 2024.

2.4. Erros em modelos de previsão

Os erros de previsão representam a discrepância entre o valor previsto por um modelo e o valor real observado. Avaliar esses erros é essencial para ajustar os modelos, melhorando sua precisão e confiabilidade. Modelos de previsão podem apresentar erros devido a fatores como mudanças no ambiente externo, erro de modelagem ou características inerentes aos dados que não são capturadas pelo modelo. Ao entender a natureza dos erros, é possível identificar oportunidades de melhoria e refinar as estratégias de previsão (Makridakis et al., 1998).

2.4.1. Erro Médio (ME)

O Erro Médio é a média dos erros das previsões e é calculado pela fórmula:

$$ME = \frac{1}{n} \sum_{t=1}^n (Y_t - F_t)$$

Onde Y_t é o valor observado e F_t é o valor previsto para a t-ésima previsão.

O ME identifica o viés do modelo, ou seja, a tendência de o modelo consistentemente superestimar ou subestimar os valores. Um ME positivo indica superestimação, enquanto um ME negativo indica subestimação. Entretanto, o ME pode mascarar a magnitude dos erros devido ao cancelamento entre erros positivos e negativos, sendo pouco informativo para avaliações de precisão em termos absolutos.

2.4.2. Erro Médio Absoluto (MAE)

O MAE considera a média dos valores absolutos dos erros, permitindo uma avaliação direta da magnitude dos erros sem considerar a direção. A fórmula do MAE é:

$$MAE = \frac{1}{n} \sum_{t=1}^n |Y_t - F_t|$$

Onde Y_t é o valor observado e F_t é o valor previsto para a t-ésima previsão.

Por não considerar a direção dos erros, o MAE fornece uma medida mais compreensível da magnitude dos erros, refletindo a média das diferenças absolutas entre previsão e observação. É adequado para situações em que a precisão média é necessária e a direção do erro é irrelevante.

2.4.3. Erro Médio Quadrado (MSE)

O MSE é uma métrica que eleva os erros ao quadrado, penalizando erros maiores de forma mais severa. A fórmula para o MSE é:

$$MSE = \frac{1}{n} \sum_{t=1}^n (Y_t - F_t)^2$$

Onde Y_t é o valor observado e F_t é o valor previsto para a t-ésima previsão.

Ao elevar ao quadrado as diferenças, o MSE aumenta significativamente o impacto de grandes erros, sendo particularmente útil em contextos onde grandes desvios podem ser mais críticos para o processo de decisão. Contudo, essa característica também torna o MSE sensível a outliers, que podem distorcer a avaliação da precisão do modelo.

2.4.4. Erro Médio Percentual Absoluto (MAPE)

O MAPE expressa o erro como uma porcentagem do valor real, facilitando comparações entre séries temporais com diferentes escalas. Sua fórmula é:

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{Y_t - F_t}{Y_t} \right| \times 100$$

Onde Y_t é o valor observado e F_t é o valor previsto para a t-ésima previsão.

O MAPE é valioso para avaliar a precisão relativa das previsões, especialmente quando se trabalha com séries de dados em diferentes unidades ou

escalas. No entanto, essa métrica pode apresentar problemas quando aplicada a séries com valores próximos de zero, pois resulta em valores percentuais extremamente altos ou indefinidos, o que pode distorcer a análise. Além disso, o MAPE tende a ser menos informativo quando os valores reais são pequenos.

2.4.5. Erro Médio Percentual (MPE)

O MPE mede a média dos erros percentuais, levando em consideração o sinal dos erros. É calculado pela fórmula:

$$MPE = \frac{1}{n} \sum_{t=1}^n \frac{Y_t - F_t}{Y_t} \times 100$$

Onde Y_t é o valor observado e F_t é o valor previsto para a t-ésima previsão.

O MPE é útil para identificar a tendência de um modelo de superestimar ou subestimar os valores, uma vez que erros positivos e negativos se mantêm, ao invés de serem eliminados como no MAPE. Um MPE positivo indica uma tendência de superestimação, enquanto um valor negativo indica subestimação. No entanto, semelhante ao MAPE, o MPE pode ser problemático em séries temporais onde os valores reais são próximos de zero, levando a valores extremos ou indefinidos.

3. Método de Aplicação dos Modelos Preditivos

3.1. Coleta de dados

Este estudo baseia-se em dados internos da PetVerso sobre receita faturada e volume de pedidos, coletados mensalmente entre janeiro de 2022 e setembro de 2024. As informações foram extraídas de uma base de dados armazenada na plataforma Google Cloud, utilizando o BigQuery para consulta e tratamento inicial. As métricas analisadas incluem exclusivamente receita e volume de pedidos, detalhadas até o nível de SKU (Stock Keeping Unit), permitindo uma visão detalhada e granular do desempenho financeiro da empresa. O tratamento dos dados ocorreu em duas etapas principais:

- BigQuery: Scripts SQL foram desenvolvidos para filtrar, limpar e organizar os dados. Esse processo envolveu remoção de duplicidades, tratamento de valores nulos e agregação mensal das receitas e pedidos. O BigQuery foi escolhido pela eficiência em lidar com grandes volumes de dados e realizar consultas complexas.
- Excel: Após a extração do BigQuery, os dados foram exportados para o Excel, onde foram realizados ajustes finais e análises exploratórias, como tabelas e gráficos. Além disso, o Excel foi utilizado para otimizar os coeficientes de nível, tendência e sazonalidade por meio do Solver, ferramenta que permitiu ajustar esses coeficientes para melhorar a precisão das previsões de receita.

Esses processos garantiram que os dados estivessem organizados e otimizados, fornecendo uma base sólida para análise e previsão da receita ao longo do período de estudo.

3.2. Análise dos Resultados

A análise dos resultados será realizada com base no comportamento dos modelos de previsão em relação aos valores reais da série histórica. Serão examinados os erros de cada modelo, avaliando-se a precisão das projeções e sua concordância com os valores observados no passado.

4. Aplicação e análises dos modelos de previsão

A aplicação dos modelos de previsão será realizada com base na série histórica de pedidos e receita, abrangendo o período de janeiro de 2022 a setembro de 2024 e projetando estes dados até o fim do ano de 2024, observando o comportamento entre os meses de Março, Junho e Novembro, meses em que existem uma maior oferta de descontos na plataforma, ou seja, onde ocorrem os picos de demanda, e os meses não promocionais que ocorrem ao longo do ano. Os modelos utilizados serão:

- Média Móvel
- Suavização Exponencial Simples
- Suavização Exponencial de Holt
- Suavização Exponencial de Holt-Winter

Conforme detalhado no Capítulo 2, esses modelos serão aplicados para analisar o comportamento das projeções em relação à demanda mensal de pedidos e receita faturada. A análise abordará as variações de sazonalidade e tendência observadas em cada modelo, permitindo uma compreensão detalhada da capacidade de cada abordagem para prever a demanda futura. A série histórica que será utilizada como base para os modelos de previsão se encontra na tabela abaixo.

Tabela 1: Série Histórica de Pedidos e Receita da PetVerso

Período	Mês	Pedidos	Receita
1	janeiro 2022	2.533.268	604.444.919
2	fevereiro 2022	2.351.807	572.505.967
3	março 2022	2.571.316	634.623.958
4	abril 2022	2.366.974	597.399.946
5	maio 2022	2.590.818	656.014.783
6	junho 2022	2.901.353	720.615.298
7	julho 2022	2.669.620	669.892.643
8	agosto 2022	2.780.932	710.486.039
9	setembro 2022	2.799.232	706.898.639
10	outubro 2022	2.851.791	718.181.689
11	novembro 2022	3.150.794	781.154.654
12	dezembro 2022	2.620.532	648.378.648
13	janeiro 2023	2.916.219	720.072.679
14	fevereiro 2023	2.671.041	666.679.983
15	março 2023	2.987.461	745.171.044
16	abril 2023	2.869.007	708.111.137
17	maio 2023	3.168.985	761.463.772
18	junho 2023	3.413.898	820.424.315
19	julho 2023	3.311.404	786.412.252
20	agosto 2023	3.344.752	795.630.755
21	setembro 2023	3.212.079	762.434.198
22	outubro 2023	3.445.680	812.526.965
23	novembro 2023	3.886.400	910.947.143
24	dezembro 2023	3.092.278	720.676.598
25	janeiro 2024	3.456.947	808.388.087
26	fevereiro 2024	3.379.293	781.299.457
27	março 2024	3.666.746	833.070.294
28	abril 2024	3.590.385	820.866.690
29	maio 2024	3.502.001	819.480.287
30	junho 2024	3.760.159	879.102.429
31	julho 2024	3.789.007	874.543.530
32	agosto 2024	3.865.796	884.009.761
33	setembro 2024	3.768.776	853.802.333

Fonte: Autoria própria

4.1. Média Móvel

Neste estudo, será aplicada a metodologia de previsão com o uso do modelo de Média Móvel Simples, utilizando três parâmetros distintos: $n = 3$, $n = 6$ e $n = 9$, que correspondem ao número de períodos considerados no cálculo da previsão. O modelo de Média Móvel é expresso por:

$$F_{t+1} = \frac{Y_t + Y_{t+1} + \dots + Y_{t-(n-1)}}{n} \quad (1)$$

F_{t+1} : Receita/Pedidos previsto para o próximo período

$Y_t + Y_{t+1} + \dots + Y_{t-(n-1)}$: valores observados de Receita/Pedidos nos últimos n períodos

n : períodos considerados para o cálculo da média

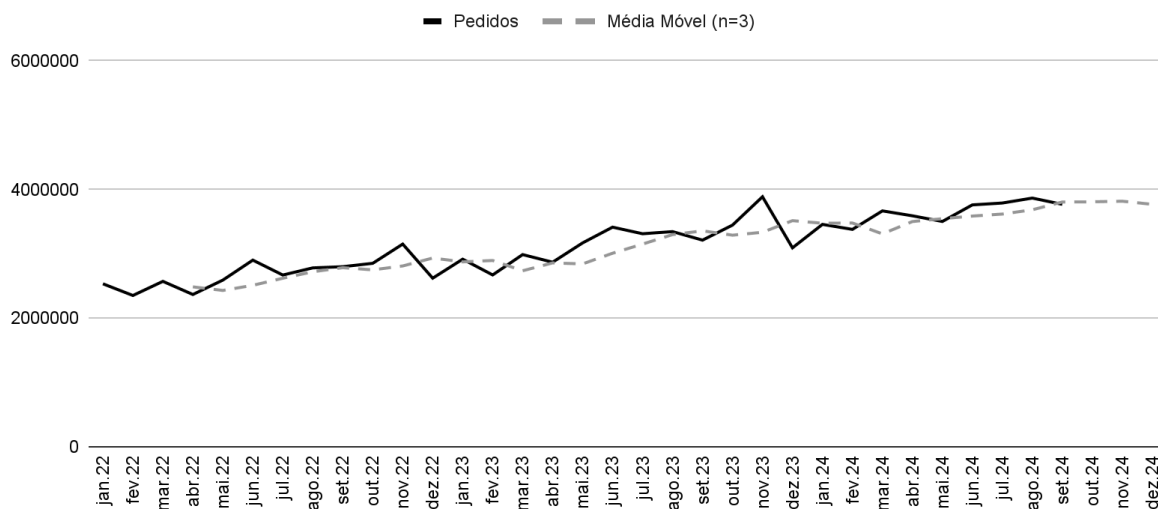
Para cada um desses parâmetros, serão conduzidos dois experimentos, com o objetivo de projetar tanto a receita quanto o volume de pedidos. Essa abordagem permitirá avaliar o desempenho do modelo em diferentes cenários e comparar os resultados obtidos para cada valor de n .

4.1.1. Resultados do modelo de Média Móvel

Visto que o modelo de Média Móvel é adequado para séries temporais onde não há grandes variações de tendência e sazonalidade, permanecendo estáveis ao longo do tempo, espera-se que a curva de previsão suavize os dados ao longo do tempo, podendo haver atrasos na identificação de mudanças de tendência ou sazonalidade.


Ao aplicar a Média Móvel Simples em Receita e Pedidos, observou-se que quanto maior o período considerado na média móvel mais rápido ocorreu a suavização da previsão, porém foram menos responsivas às mudanças de tendência e sazonalidade. Os gráficos abaixo mostram a evolução de Pedidos e a Projeção por Média Móvel para cada período n ao longo dos meses.

Gráfico 1: Volume de Pedidos realizado e Média Móvel para n = 3 ao longo dos meses



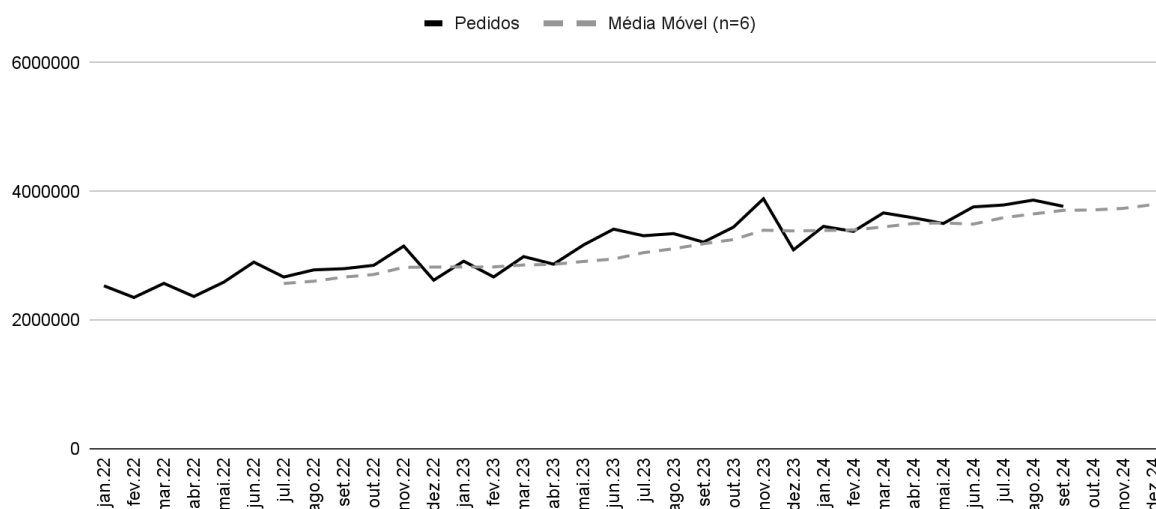
Fonte: Autoria própria

Gráfico 2: Volume de Pedidos realizado e Média Móvel para n = 6 ao longo dos meses



Fonte: Autoria própria

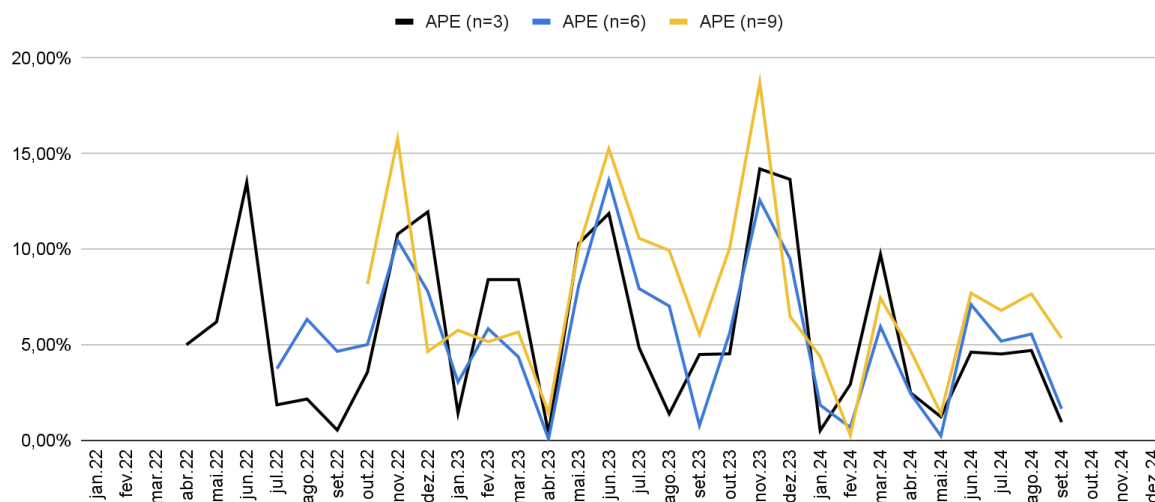
Gráfico 3: Volume de Pedidos realizado e Média Móvel para n = 9 ao longo dos meses



Fonte: Autoria própria

A partir da comparação entre o volume de Pedidos realizados dentro do período observado e o modelo de Média Móvel Simples, percebe-se que o modelo acompanha o ciclo de tendência da série, porém não absorve a sazonalidade no período, o que leva a um alto erro percentual absoluto nos meses em que os picos e vales são bem definidos. Além disso, entre os números períodos analisados, a previsão considerando um horizonte de 6 meses para Média Móvel Simples foi a que teve melhores resultados de MAPE e MPE, os quais apresentam picos de Erro Percentual Absoluto nos meses de Março, Junho, Novembro e Dezembro, e um valor negativo de MPE, ou seja, o modelo tem a tendência de subestimar a projeção em relação aos dados observados. O Gráfico e tabelas abaixo mostram os resultados dos Erros Percentuais Absolutos para o modelo de Média Móvel Simples ao longo dos meses, o Erro Médio Percentual Absoluto e Erro Médio para a previsão de Pedidos.

Gráfico 4: Erro Percentual Absoluto da Média Móvel em Pedidos ao longo dos meses



Fonte: Autoria própria

Tabela 2: Erro Médio Percentual para Média Móvel de Pedidos

Ano	MPE (n=3)	MPE (n=6)	MPE (n=9)
2022	-2,41%	-3,74%	-6,43%
2023	-2,57%	-3,98%	-6,79%
2024	-2,27%	-3,21%	-5,08%
Total	-2,43%	-3,67%	-6,10%

Fonte: Autoria Própria

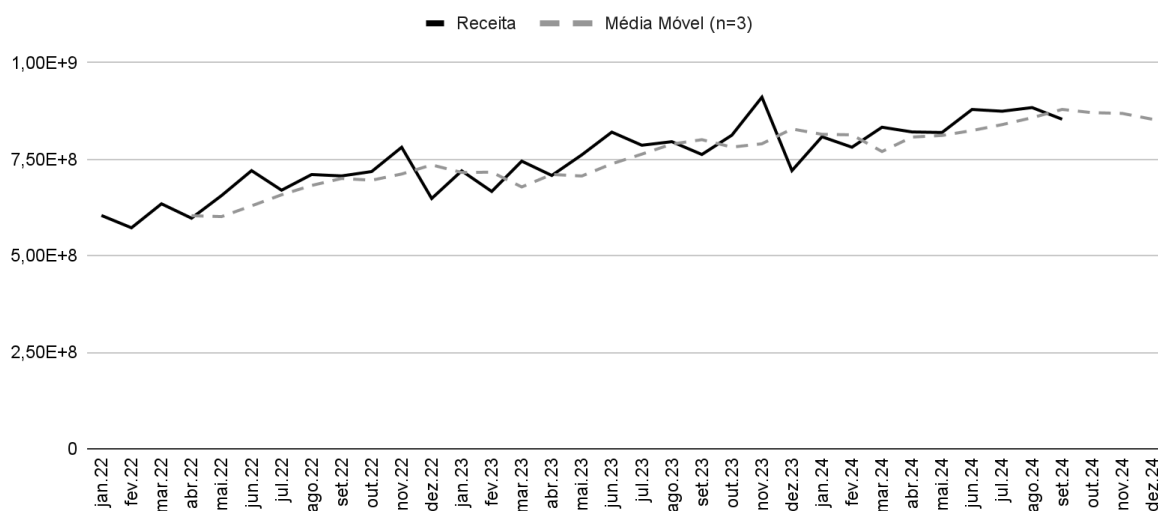
Tabela 3: Erro Médio Percentual Absoluto para Média Móvel de Pedidos

Ano	MAPE (n=3)	MAPE (n=6)	MAPE (n=9)
2022	6,18%	6,34%	9,54%
2023	7,00%	6,55%	8,73%
2024	3,53%	3,41%	5,08%
Total	5,71%	5,46%	7,46%

Fonte: Autoria Própria


Semelhante à projeção feita para pedidos, a média móvel aplicada à Receita faturada apresentou pouca influência na sazonalidade, mas seguiu os ciclos de tendência durante período observado. Os resultados da evolução Receita faturada realizada e a Média Móvel Simples estão representados nos gráficos abaixo.

Gráfico 5: Receita realizada e Média Móvel para n = 3 ao longo dos meses




Fonte: Autoria própria

Gráfico 6: Receita realizada e Média Móvel para n = 6 ao longo dos meses



Fonte: Autoria própria


Gráfico 7: Receita realizada e Média Móvel para n = 9 ao longo dos meses



Fonte: Autoria própria

Ao analisar os erros do modelo de Média Móvel aplicada à Receita faturada, verifica-se um comportamento semelhante aos erros da previsão feita no volume de pedidos. Desta forma, nos meses promocionais são onde ocorrem os maiores picos de Erro percentual Absoluto e que apresentam uma subestimação dos dados com MPE negativo, sendo n = 6 o modelo em que obteve os menores MAPE. O Gráficos e Tabelas abaixo mostram os resultados dos Erros Percentuais Absolutos para o modelo de Média Móvel Simples ao longo dos meses, o Erro Médio Percentual Absoluto e Erro Médio para a previsão da Receita.

Gráfico 8: Erro Percentual Absoluto da Média Móvel em Receita ao longo dos meses



Fonte: Autoria própria

Tabela 4: Erro Médio Percentual para Média Móvel de Receita

Ano	MAPE (n=3)	MAPE (n=6)	MAPE (n=9)
2022	6,02%	6,95%	10,05%
2023	6,28%	5,69%	7,10%
2024	3,46%	2,94%	4,11%
Total	5,36%	5,05%	6,35%

Fonte: Autoria própria

Tabela 5: Erro Médio Percentual Absoluto para Média Móvel de Receita

Ano	MPE (n=3)	MPE (n=6)	MPE (n=9)
2022	-2,79%	-3,89%	-5,94%
2023	-1,64%	-2,57%	-4,59%
2024	-1,71%	-2,44%	-3,65%
Total	-2,01%	-2,82%	-4,41%

Fonte: Autoria própria

4.2. Suavização Exponencial Simples (SES)

A Suavização Exponencial Simples é uma técnica utilizada em séries temporais para gerar previsões de curto prazo, especialmente quando os dados não apresentam tendências ou sazonalidade. É amplamente empregada devido à sua

simplicidade e eficiência na projeção de séries temporais estacionárias (Makridakis et al., 1998). O modelo de Suavização Exponencial Simples é baseado na ideia de que as previsões são geradas a partir de uma combinação ponderada da observação mais recente e da previsão anterior. Sua fórmula pode ser expressa como:

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

F_{t+1} : Receita/Pedidos previsto para o próximo período

Y_t : valor observado mais recente

F_t : Previsão Anterior

α : parâmetro de suavização; $0 \leq \alpha \leq 1$

Para os valores de α foi utilizado a ferramenta Solver do Excel com o objetivo de minimizar o MAPE da previsão em relação aos valores de Pedidos e Receita, atribuindo o intervalo entre 0 e 1 chegou-se em um parâmetro α de 0,47 e 0,50 para os modelos de Pedidos e Receita, respectivamente.

O valor inicial da previsão foi gerado a partir do segundo dado observado, ou seja, a primeira previsão é igual ao segundo dado da série. A partir disso, o modelo de previsão seguiu com formulação citada acima.

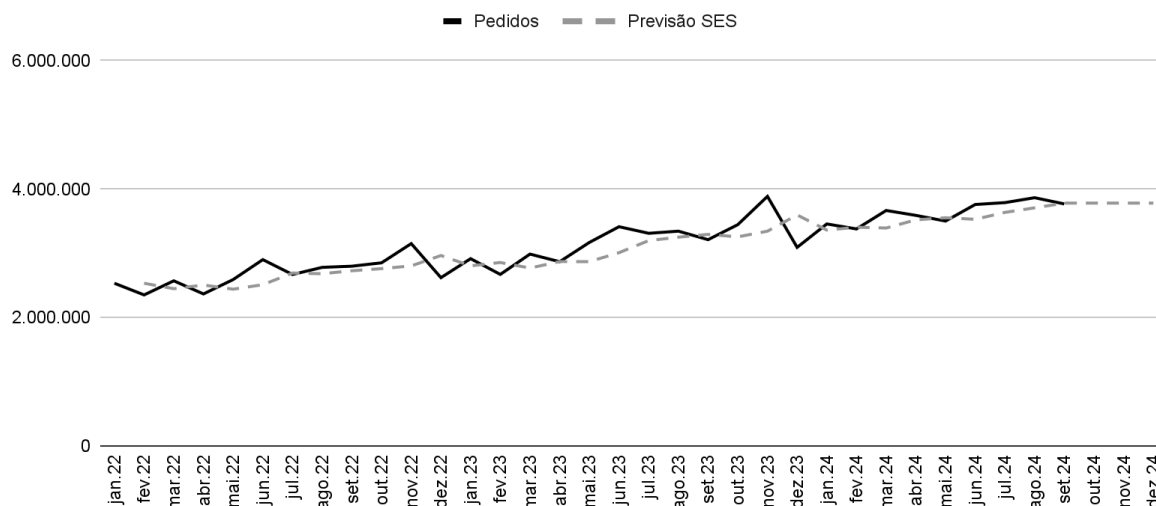
4.2.1. Resultados do modelo de Suavização Exponencial Simples (SES)

Como descrito no item 4.3., o modelo de Suavização Exponencial Simples é uma técnica recomendada para séries que não apresentam tendência ou sazonalidade, portanto espera-se que após o período dos dados observados, a previsão do Modelo se torne constante e com oscilações sazonais suavizadas, falhando em acompanhar a tendência crescente ou decrescente dos dados e resultando em previsões que não refletem os picos e vales periódicos esperados em séries temporais com sazonalidade clara.

Ao aplicar a SES ao volume de pedidos e receita faturada, observa-se que o modelo tende estabilizar o primeiro valor da previsão para os pontos futuros, sem

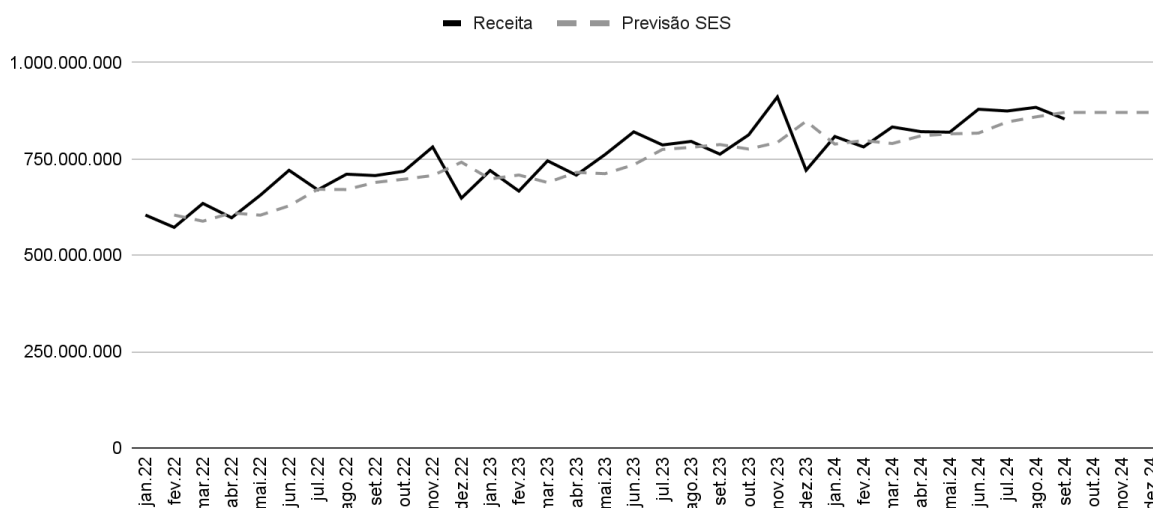
apresentar a tendência e sazonalidade observadas nos valores reais. Os gráficos abaixo mostram a evolução do Modelo de Suavização Exponencial e os valores observados de Pedidos e Receita ao longo dos meses.

Gráfico 9: Volume de Pedidos realizado e SES para $\alpha = 0,47$ ao longo dos meses



Fonte: Autoria própria

Gráfico 10: Receita realizada e SES para $\alpha = 0,50$ ao longo dos meses




Fonte: Autoria própria

Ao analisar os erros do modelo de SES aplicada ao Volume de Pedidos e Receita faturada, observa-se que os picos de Erro Percentual Absoluto estão


localizados nos meses de Junho, Novembro e Dezembro. Além disso verifica-se uma subestimação do modelo em relação aos valores observados, os quais apresentam MPE negativo. O Gráfico e tabelas abaixo mostram os resultados dos Erros Percentuais Absolutos para o modelo SES ao longo dos meses, o Erro Médio Percentual Absoluto e Erro Médio para a SES aplicada à Pedidos e Receita.

Gráfico 11: Erro Percentual Absoluto da SES em Pedidos ao longo dos meses



Fonte: Autoria própria

Gráfico 12: Erro Percentual Absoluto da SES em Receita ao longo dos meses



Fonte: Autoria própria

Tabela 6: Erros para SES em Pedidos

Ano	MAPE	MPE
2022	6,54%	-1,52%
2023	7,00%	-2,68%
2024	3,22%	-2,64%
Total	5,78%	-2,27%

Fonte: Autoria própria

Tabela 7: Erros para SES em Receita

Ano	MAPE	MPE
2022	6,43%	-2,38%
2023	6,38%	-1,69%
2024	2,96%	-2,05%
Total	5,44%	-2,03%

Fonte: Autoria própria

4.3. Suavização Exponencial de Holt

A Suavização Exponencial de Holt é uma técnica de previsão amplamente utilizada para séries temporais que apresentam uma tendência linear. Desenvolvida como uma extensão da suavização exponencial simples, o modelo de Holt incorpora dois componentes: o nível e a tendência, permitindo a previsão de séries temporais que exibem mudanças contínuas no tempo, mas sem um padrão sazonal claro (Makridakis, 1998). Sua fórmula pode ser expressa como:

$$F_{t+1} = L_t + b_t \quad (1)$$

$$F_{t+m} = L_t + b_t m \quad (2)$$

$$L_0 = Y_1 \quad (2)$$

$$L_t = \alpha Y_t + (1 - \alpha)(L_{t-1} + b_{t-1}) \quad (4)$$

$$b_0 = Y_0 - L_0 \quad (5)$$

$$b_t = \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1} \quad (6)$$

F_{t+1} = Previsão para o próximo período

F_{t+m} : Previsão para m períodos a frente dos valores observados

Y_t : valor observado mais recente

L_t : Nível da série no tempo t

b_t : tendência no tempo t

α : parâmetro de suavização para o nível da série; $0 \leq \alpha \leq 1$

β : parâmetro de suavização para a tendência da série; $0 \leq \beta \leq 1$

Para os valores de α e β foi utilizado a ferramenta Solver do Excel com o objetivo de minimizar o MAPE da previsão em relação aos valores de Pedidos e Receita, atribuindo o intervalo entre 0 e 1 para os dois parâmetros. A relação dos para α e β pode ser vista na tabela abaixo.

Tabela 8: Parâmetros alfa e beta para a previsão de Pedidos e Receita


Parâmetro	Pedidos	Receita
alpha	0,43	0,49
beta	0,35	0,25

Fonte: Autoria própria

4.3.1. Resultados do modelo de Suavização Exponencial de Holt


Ao aplicar a Suavização Exponencial de Holt ao Volume de Pedidos e Receita faturada, observa-se que o modelo apresenta um atraso de um mês em relação à sazonalidade no período analisado, ainda que acompanhe a tendência geral da série. Para os valores previstos, o modelo mantém uma tendência linear a partir do último valor observado, mas não consegue capturar as variações sazonais, resultando em previsões que ignoram essas flutuações regulares. Os gráficos abaixo mostram a evolução do Modelo de Suavização Exponencial de Holt e os valores observados de Pedidos e Receita ao longo dos meses.

Gráfico 13: Volume de Pedidos realizado e Suavização Exponencial de Holt para $\alpha = 0,43$ e $\beta = 0,35$ ao longo dos meses



Fonte: Autoria própria

Gráfico 14: Volume de Receita realizada e Suavização Exponencial de Holt para $\alpha = 0,49$ e $\beta = 0,25$ ao longo dos meses

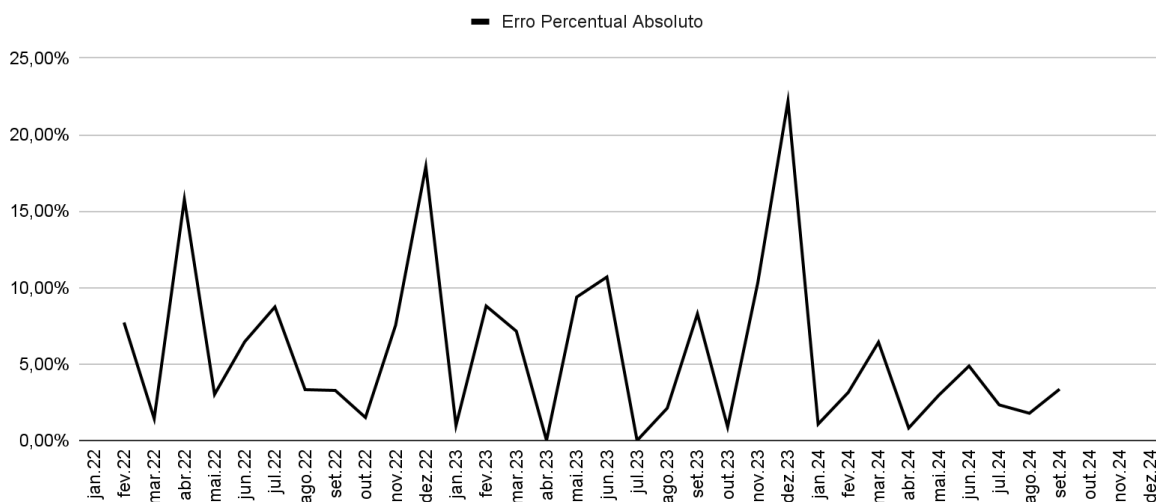


Fonte: Autoria própria

Ao analisar os erros do modelo de Suavização Exponencial de Holt aplicada ao Volume de Pedidos e Receita faturada, observa-se que os picos de Erro Percentual Absoluto ocorrem principalmente em Abril, Junho, Julho, Novembro e


Dezembro, meses em que a flutuação sazonal é bem característica. Além disso, há uma superestimação do modelo aplicado à Pedidos enquanto o modelo aplicado à Receita subestima estes valores. Abaixo seguem os resultados dos erros observados no modelo de Holt .

Gráfico 15: Erro Percentual Absoluto da Suavização Exponencial de Holt em Pedidos ao longo dos meses



Fonte: Autoria própria

Gráfico 16: Erro Percentual Absoluto da Suavização Exponencial de Holt em Receita ao longo dos meses



Fonte: Autoria própria

Tabela 9: Erros para a Suavização Exponencial de Holt em Pedidos

Ano	MAPE	MPE
2022	6,97%	4,42%
2023	6,73%	0,16%
2024	2,97%	-0,63%
Total	5,76%	1,41%

Fonte: Autoria própria

Tabela 10: Erros para a Suavização Exponencial de Holt em Receita

Ano	MAPE	MPE
2022	7,33%	-3,76%
2023	6,49%	0,59%
2024	2,51%	-0,62%
Total	5,66%	-1,25%

Fonte: Autoria própria

4.4. Suavização Exponencial de Holt-Winter

A Suavização Exponencial de Holt-Winters é uma técnica amplamente utilizada para previsão de séries temporais que exibem tanto uma tendência quanto um componente sazonal. O modelo foi desenvolvido como uma extensão do método de Holt, com o objetivo de capturar não apenas a tendência linear, mas também padrões sazonais repetitivos. Para isso, o modelo de Holt-Winters ajusta três componentes: o nível da série, a tendência e a sazonalidade (Makridakis et al., 1998).

Existem duas formas do modelo de Holt-Winters: a aditiva e a multiplicativa. O modelo aditivo é ideal para séries cuja sazonalidade é constante ao longo do tempo, enquanto o modelo multiplicativo é mais adequado para séries em que a amplitude da sazonalidade varia proporcionalmente ao nível da série (Hyndman & Athanasopoulos, 2018). Neste estudo será abordado o modelo multiplicativo, o qual segue a formulação destacada abaixo.

$$F_{t+1} = (L_t + b_t)S_{t-s} \quad (1)$$

$$F_{t+m} = (L_t + b_t m)S_{t+m-s} \quad (2)$$

$$L_t = \alpha \frac{Y_t}{S_{t-s}} + (1 - \alpha)(L_{t-1} + b_{t-1}) \quad (3)$$

$$b_t = \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1} \quad (4)$$

$$S_t = \gamma \frac{Y_t}{L_t} + (1 - \gamma)S_{t-s} \quad (5)$$

F_{t+1} : Previsão para o próximo período

F_{t+m} : Previsão para m períodos a frente dos valores observados

Y_t : valor observado mais recente

L_t : Nível da série no tempo t

b_t : tendência no tempo t

S_t : sazonalidade no tempo t

s : período da sazonalidade

α : parâmetro de suavização para o nível da série; $0 \leq \alpha \leq 1$

β : parâmetro de suavização para a tendência da série; $0 \leq \beta \leq 1$

γ : parâmetro de suavização para a sazonalidade da série; $0 \leq \gamma \leq 1$

Para a aplicação do Modelo de Holt-Winters na série de Pedidos e Receita, foi considerado o período da sazonalidade de $s = 12$, ou seja, o ciclo de sazonalidade adotado foi anual e o primeiro valor de previsão ocorre em Janeiro de 2023. Além disso, para os valores de α , β e γ foi utilizado a ferramenta Solver do Excel com o objetivo de minimizar o MAPE da previsão em relação aos valores de Pedidos e Receita, atribuindo o intervalo entre 0 e 1 para os três parâmetros. A relação para α , β e γ pode ser vista na tabela abaixo.

Tabela 11: Parâmetros alfa, beta e gama para a previsão de Pedidos e Receita

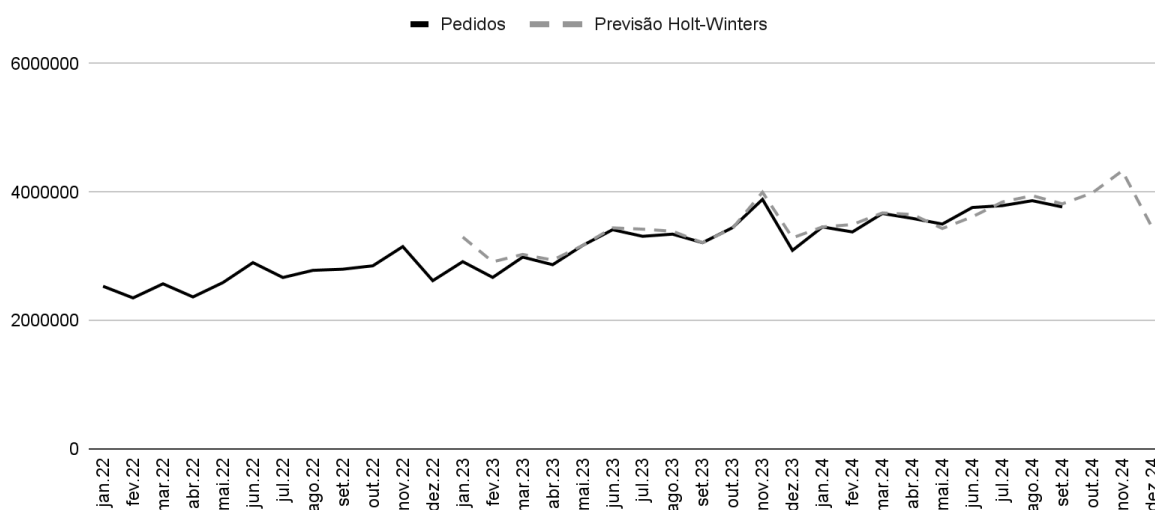
Parâmetro	Pedidos	Receita
alpha	0,78	0,85
beta	0,49	0,42
gama	1,00	0,00

Fonte: Autoria própria

4.4.1. Resultados do Modelo de Suavização Exponencial Holt-Winter


Ao aplicar o método de Holt-Winters, observa-se uma boa aproximação entre a curva dos valores observados de Pedidos e Receita, refletindo a sazonalidade e a tendência bem definida da série. As previsões geradas após os valores observados mantêm a tendência do último valor registrado e acompanham as flutuações sazonais, proporcionando uma representação consistente do comportamento da série no período projetado. Os gráficos abaixo mostram a evolução do Modelo de Suavização Exponencial de Holt-Winters e os valores observados de Pedidos e Receita ao longo dos meses.

Gráfico 17: Volume de Pedidos realizado e Suavização Exponencial de Holt-Winters para $\alpha = 0,78$, $\beta = 0,49$ e $\gamma = 1,00$ ao longo dos meses



Fonte: Autoria própria

Gráfico 18: Receita realizada e Suavização Exponencial de Holt-Winters para $\alpha = 0,85$, $\beta = 0,42$ e $\gamma = 0,00$ ao longo dos meses



Fonte: Autoria própria

O modelo apresenta um MPE positivo para os casos de Pedidos e Receita, o que indica superestimação dos valores projetados. Além disso, observa-se um erro considerável no primeiro mês de previsão, mas que se reduz ao longo dos meses, se adaptando à sazonalidade e tendência da série observada. Abaixo seguem os resultados dos erros observados no modelo de Holt-Winters.

Tabela 12: Erros para a Suavização Exponencial de Holt-Winters em Pedidos

Ano	MAPE	MPE
2023	2,55%	2,50%
2024	1,77%	0,48%
Total	2,20%	1,59%


Fonte: Autoria própria

Tabela 13: Erros para a Suavização Exponencial de Holt-Winters em Receita

Ano	MAPE	MPE
2023	2,41%	2,29%
2024	1,42%	0,30%
Total	1,97%	1,40%


Fonte: Autoria própria

Gráfico 19: Erro Percentual Absoluto da Suavização Exponencial de Holt-Winters em Pedidos ao longo dos meses



Fonte: Autoria própria

Gráfico 20: Erro Percentual Absoluto da Suavização Exponencial de Holt-Winters em Receita ao longo dos meses




Fonte: Autoria própria

5. Análise Comparativa e Modelo Escolhido

5.1. Análise Comparativa

Neste tópico, serão analisados os resultados dos modelos preditivos aplicados ao volume de pedidos e receita. A análise abordará a acurácia em relação à série histórica observada, utilizando métricas como MPE (Erro Percentual Médio), MAPE (Erro Percentual Absoluto Médio) e o Erro Percentual Absoluto Máximo, além do comportamento sazonal e a tendência dos modelos. O objetivo desta análise é identificar as limitações de cada modelo e destacar os métodos de projeção mais adequados para serem aplicados tanto na curva de pedidos quanto na de receita.

Gráfico 21: Comparação da evolução do Volume de Pedidos e Modelos de Previsão



Fonte: Autoria própria

A partir do Gráfico 21, observa-se que, durante o período analisado, as tendências dos modelos acompanham o comportamento de crescimento do volume de pedidos realizados, com uma tendência linear que facilita a adaptação dos métodos aplicados. No entanto, verifica-se que após o período observado, apenas os modelos de Média Móvel para $n = 9$, Holt e Holt-Winters apresentam a tendência de crescimento dos valores projetados, enquanto os outros modelos apresentam um comportamento constante dos valores. Desta forma, em caso de variações expressivas na tendência, os modelos que não consideram esse componente na projeção poderão apresentar dificuldades em capturar essas flutuações.

Além disso, percebe-se que apenas o método de Holt-Winters apresenta as flutuações de sazonalidade após o período realizado e que consegue acompanhar a sazonalidade dos meses sem atraso. Por outro lado, os métodos de Suavização Exponencial Simples e de Holt apresentam sazonalidade, mas apenas durante o período observado e com um certo atraso. Já o método de média móvel não incorpora qualquer componente sazonal no modelo.

Tabela 14: Erro Percentual Médio para a Previsão de Pedidos

MPE - Previsão para Pedidos						
Ano	Média Móvel (n=3)	Média Móvel (n=6)	Média Móvel (n=9)	SES	Holt	Holt-Winters
2022	-2,41%	-3,74%	-6,43%	-1,52%	4,42%	
2023	-2,57%	-3,98%	-6,79%	-2,68%	0,16%	2,50%
2024	-2,27%	-3,21%	-5,08%	-2,64%	-0,63%	0,48%
Total	-2,43%	-3,67%	-6,10%	-2,27%	1,41%	1,59%

Fonte: Autoria própria

Tabela 15: Maior Erro Percentual Absoluto para a Previsão de Pedidos

Maior Erro Percentual Absoluto - Previsão para Pedidos						
Ano	Média Móvel (n=3)	Média Móvel (n=6)	Média Móvel (n=9)	SES	Holt	Holt-Winters
2022	13,50%	10,48%	15,77%	13,46%	17,90%	
2023	14,21%	13,60%	18,74%	16,32%	22,18%	9,08%
2024	9,74%	7,12%	7,71%	7,45%	6,43%	3,85%
Total	14,21%	13,60%	18,74%	16,32%	22,18%	9,08%

Fonte: Autoria própria

Tabela 16: MAPE para a Previsão de Pedidos


MAPE - Previsão para Pedidos						
Ano	Média Móvel (n=3)	Média Móvel (n=6)	Média Móvel (n=9)	SES	Holt	Holt-Winters
2022	6,18%	6,34%	9,54%	6,54%	6,97%	
2023	5,36%	4,92%	6,96%	5,47%	5,45%	1,95%
2024	2,84%	3,62%	6,51%	2,21%	2,57%	1,65%
Total	5,57%	5,52%	7,46%	5,63%	5,43%	2,20%

Fonte: Autoria própria

Nas tabelas destacadas acima (Tabelas 14, 15 e 16), nota-se que os erros dos modelos em 2024 apresentam níveis menores e que apenas a Suavização Exponencial de Holt e Holt-Winters superestimam a projeção, o que aponta um bom uso dessas projeções como metas a serem atingidas pela companhia.

Por fim, o modelo que apresentou os melhores índices de erro total foi o método de Holt-Winters, com um MPE aceitável de 1,59% e os menores níveis tanto no Erro Percentual Absoluto Máximo quanto no MAPE, atingindo 9,1% e 2,2%, respectivamente.

Gráfico 22: Comparação da evolução da Receita e Modelos de Previsão



Fonte: Autoria própria

Semelhante aos modelos aplicados à curva de pedidos, observa-se que na curva de Receita (Gráfico 22) os modelos seguem o comportamento vistos na tendência, com apenas os modelos de Média Móvel para $n = 9$, Holt e Holt-Winters apresentando a tendência de crescimento dos valores previstos.

Assim como a tendência, a sazonalidade dos modelos aplicados à curva de Receita também demonstra comportamento semelhante à aplicada em Pedidos, de forma que apenas o modelo Holt-Winters projeta essas flutuações para os períodos futuros.

Tabela 17: Erro Percentual Médio para a Previsão de Receita

MPE - Previsão para Receita						
Ano	Média Móvel (n=3)	Média Móvel (n=6)	Média Móvel (n=9)	SES	Holt	Holt-Winters
2022	-2,79%	-3,89%	-5,94%	-2,38%	-3,76%	
2023	-1,64%	-2,57%	-4,59%	-1,69%	0,59%	2,29%
2024	-1,71%	-2,44%	-3,65%	-2,05%	-0,62%	0,30%
Total	-2,01%	-2,82%	-4,41%	-2,03%	-1,25%	1,40%

Fonte: Autoria própria

Tabela 18: Maior Erro Percentual Absoluto para a Previsão de Receita

Maior Erro Percentual Absoluto - Previsão para Receita						
Ano	Média Móvel (n=3)	Média Móvel (n=6)	Média Móvel (n=9)	SES	Holt	Holt-Winters
2022	13,42%	9,23%	14,85%	14,38%	19,43%	
2023	14,98%	11,71%	16,34%	17,66%	22,38%	10,39%
2024	7,56%	7,98%	8,12%	7,05%	6,22%	3,30%
Total	14,98%	11,71%	16,34%	17,66%	22,38%	10,39%

Fonte: Autoria própria

Tabela 19: MAPE para a Previsão de Receita

MAPE - Previsão para Pedidos						
Ano	Média Móvel (n=3)	Média Móvel (n=6)	Média Móvel (n=9)	SES	Holt	Holt-Winters
2022	6,02%	6,95%	10,05%	6,43%	7,33%	
2023	5,25%	4,52%	5,91%	5,18%	5,07%	1,60%
2024	2,98%	2,49%	4,90%	2,39%	2,61%	0,28%
Total	5,26%	5,06%	6,35%	5,31%	5,04%	1,97%

Fonte: Autoria própria

Nas tabelas destacadas acima (Tabelas 17, 18, 19), os modelos para receita apresentam redução dos níveis de erro ao longo dos anos, com a maioria das projeções subestimando os valores reais, com exceção da Suavização Exponencial de Holt-Winters, que apresenta MPE positivo. Além disso, o Modelo de Holt-Winters se mostrou o método com os melhores índices de Erro Percentual Absoluto Máximo e MAPE com 10,4% e 2%, respectivamente.

5.2. Critérios para Escolha do Modelo e Modelo Escolhido

Os critérios para a escolha do modelo a ser implementado baseiam-se em características fundamentais, como a precisão, avaliada por meio dos indicadores MPE, MAPE e o Erro Absoluto Máximo das séries, além da adequação aos dados históricos, ou seja, a capacidade de lidar com tendências e sazonalidades.

Com base nesses critérios, o modelo selecionado para projetar tanto o Volume de Pedidos quanto a Receita Faturada foi a Suavização Exponencial de Holt-Winters. Este método apresentou os menores índices de erro em comparação com outros modelos analisados e demonstrou ser eficaz em capturar as variações provocadas pela tendência e sazonalidade dos valores reais, tornando-o a opção mais consistente e precisa para atender às necessidades do estudo.

5.3. Implementação do Modelo

Para a implementação do modelo, serão empregadas diversas ferramentas para garantir eficiência e precisão. O Google BigQuery será utilizado para a extração, manipulação e tratamento dos dados da série histórica, enquanto o Google Sheets servirá como interface de conexão com o BigQuery, permitindo o desenvolvimento dos cálculos de projeção diretamente na planilha. Além disso, a ferramenta Solver do Excel será utilizada para otimizar os parâmetros alfa, beta e gama, minimizando o MAPE entre os valores projetados e os realizados.

O objetivo principal é aplicar esse modelo às curvas de volume e pedidos, estabelecendo metas claras para esses indicadores, essenciais no planejamento de processos operacionais. Entre esses processos, destacam-se a definição do nível de estoque mensal, o dimensionamento do número de funcionários nos Centros de Distribuição e a estimativa de outros custos operacionais.

O monitoramento do modelo será feito com base nos valores projetados e dos futuros valores realizados, os quais serão analisados com base nas métricas de erro utilizadas neste estudo. O objetivo será analisar o comportamento da projeção a longo prazo e identificar possíveis ajustes no modelo.

Além disso, as projeções servirão como base para o desenvolvimento de estratégias de aquisição e retenção de clientes, incluindo a criação de campanhas promocionais e ações de marketing direcionadas, potencializando a eficácia das iniciativas comerciais.

6. Conclusões e Próximos Passos

Neste tópico serão detalhadas as contribuições do estudo dos métodos de previsão de demanda aplicados a uma série histórica de pedidos e receita. Adicionalmente serão apresentados os próximos passos e possíveis melhorias no modelo que será implementado.

6.1. Conclusão

Este estudo teve como objetivo explorar e aplicar diferentes métodos de previsão de demanda em uma série histórica de pedidos e receita da PetVerso. Com isso, foi possível comparar os modelos analisados e escolher aquele que melhor reproduz o comportamento dos dados reais. O trabalho mostrou como é essencial substituir métodos baseados em intuição por abordagens mais estruturadas e estatísticas, trazendo mais confiança para as projeções e ajudando a tomar decisões estratégicas mais alinhadas com o mercado.

O modelo escolhido, a Suavização Exponencial de Holt-Winters, se destacou por conseguir lidar bem com sazonalidade e tendências nos dados. Sua aplicação terá um impacto direto nas operações da empresa, ajudando a prever a demanda de forma mais precisa, o que facilita o planejamento de estoque, a contratação de funcionários temporários e o gerenciamento de recursos em momentos de maior movimento. Isso não só reduz custos, mas também deixa os processos internos mais eficientes.

Além disso, o modelo ajuda a empresa a se preparar melhor para picos sazonais e a planejar promoções e metas financeiras com mais segurança. Com projeções mais confiáveis, a PetVerso pode tomar decisões que otimizem o uso de seus recursos e aumentem sua competitividade no mercado de e-commerce.

Em resumo, este trabalho destacou como modelos preditivos bem aplicados podem fazer toda a diferença na gestão de uma empresa. A implementação do Holt-Winters, acompanhada de ajustes e melhorias constantes, coloca a PetVerso em uma posição de destaque, ajudando a atender melhor os clientes, aumentar a eficiência e aproveitar novas oportunidades. Os aprendizados daqui também podem

ser levados para outras empresas e mercados, mostrando como os dados podem ser um grande aliado para crescer com inteligência.

6.2. Próximos Passos

Os próximos passos para melhorar o modelo de previsão incluem o uso de ferramentas mais modernas, como R e Python, que são mais práticas e flexíveis graças às suas bibliotecas específicas para trabalhar com séries temporais. Isso vai permitir análises mais detalhadas e automatizadas. Também está nos planos explorar métodos de Inteligência Artificial (IA), como redes neurais, para identificar padrões mais complexos nos dados. Além disso, a ideia é complementar as análises com métodos qualitativos, como pesquisas de mercado e a técnica Delphi, trazendo a visão de especialistas e considerando fatores externos para enriquecer as projeções.

7. Referências Bibliográficas

HANKE, J. E.; WICHERN, D. W. Business Forecasting. 9th ed. Harlow: Pearson Education, 2014.

PELLEGRINI, F. R.; FOGLIATTO, F. S. Passos para implantação de sistemas de previsão de demanda: técnicas e estudo de caso. Revista Produção, v. 11, n. 1, p. 43-58, 2001.

Hyndman, R.J., & Athanasopoulos, G. (2018) Forecasting: principles and practice, 2nd edition, OTexts: Melbourne, Australia. OTexts.com/fpp2. Acesso em 29/10/2024.

ARMSTRONG, J. S. Principles of Forecasting: A Handbook for Researchers and Practitioners. Kluwer Academic Publishers, 2001.

ROWE, G.; WRIGHT, G. Expert opinions in forecasting: The role of the Delphi technique. In: ARMSTRONG, J. S. Principles of Forecasting. Kluwer Academic Publishers, 2001.

PEINADO, Jurandir; GRAEML, Alexandre Reis. Administração da produção: operações industriais e de serviços. Curitiba: UnicenP, 2007.

MAKRIDAKIS, S.; WHEELWRIGHT, S. C.; HYNDMAN, R. J. Forecasting: Methods and Applications. 3. ed. New York: John Wiley & Sons, 1998.