



UNIVERSIDADE FEDERAL DE PERNAMBUCO
CENTRO ACADÊMICO DO AGRESTE
NÚCLEO DE TECNOLOGIA
ENGENHARIA DE PRODUÇÃO

GABRIEL HOMCI SERAPIÃO

**DESENVOLVIMENTO DE MODELO DE PREVISÃO DE DEMANDA PARA UMA
EMPRESA DO SETOR AUTOMOBILÍSTICO**

CARUARU

2024

UNIVERSIDADE FEDERAL DE PERNAMBUCO
CENTRO ACADÊMICO DO AGRESTE
NÚCLEO DE TECNOLOGIA
ENGENHARIA DE PRODUÇÃO

GABRIEL HOMCI SERAPIÃO

**DESENVOLVIMENTO DE MODELO DE PREVISÃO DE DEMANDA PARA UMA
EMPRESA DO SETOR AUTOMOBILÍSTICO**

Trabalho de Conclusão de Curso apresentado à Coordenação do Curso de Engenharia de Produção do Campus Agreste da Universidade Federal de Pernambuco – UFPE, na modalidade de monografia, como requisito parcial para a obtenção do grau de bacharel em Engenharia de Produção.

Área de concentração: Engenharia de
Produção

Orientador(a): Prof. Thalles Vitelli Garcez

CARUARU

2024

Ficha de identificação da obra elaborada pelo autor,
através do programa de geração automática do SIB/UFPE

Serapião, Gabriel.

Desenvolvimento de Modelo de Previsão de Demanda para uma Empresa do
Setor Automobilístico / Gabriel Serapião. - Caruaru, 2024.

52

Orientador(a): Thalles Garcez

Trabalho de Conclusão de Curso (Graduação) - Universidade Federal de
Pernambuco, Centro Acadêmico do Agreste, Engenharia de Produção, 2024.

1. Previsão de demanda. 2. Baterias. 3. Planejamento. I. Garcez, Thalles.
(Orientação). II. Título.

620 CDD (22.ed.)

GABRIEL HOMCI SERAPIÃO

**DESENVOLVIMENTO DE MODELO DE PREVISÃO DE DEMANDA PARA UMA
EMPRESA DO SETOR AUTOMOBILÍSTICO**

Trabalho de Conclusão de Curso apresentado à Coordenação do Curso de Engenharia de Produção do Campus Agreste da Universidade Federal de Pernambuco – UFPE, na modalidade de monografia, como requisito parcial para a obtenção do grau de bacharel em Engenharia de Produção.

Aprovado em: 20/03/2024 às 14:00

BANCA EXAMINADORA

Prof. Dr. Thalles Vitelli Garcez (Orientador)
Universidade Federal de Pernambuco

Prof. Dr. XXXXXXXX XXXXXXXX (Examinador Interno)
Universidade Federal de Pernambuco

Prof. Dr. XXXXXXXX XXXXXXXX (Examinador Externo)
Universidade Federal de Pernambuco

AGRADECIMENTOS

Gostaria agradecer a meu orientador Thalles Garcez, que com paciência, conseguiu me guiar ao longo do desenvolvimento desta monografia, gostaria também de agradecer e dedicar a meu namorado e futuro marido, Jefferson de Oliveira que me deu todo suporte emocional e boa parte das orientações acadêmicas para realização desse trabalho, não menos importante sou muito grato a meus amigos Evandro Junior e Vinícius Emanuel que me deram suporte e me acompanharam durante a construção do TCC, além das pessoa já citadas, deixo aqui meus agradecimentos a minhas colegas de trabalho e amigas Iza Fernanda e Josiele Batista que sempre foram solícitas as minhas necessidades de informação, dúvidas e me inspiraram na escolha do tema abordado.

RESUMO

A complexidade do mercado industrial, com sua sensibilidade, oscilações e incertezas destacam a necessidade de métodos e ferramentas que sejam eficazes na compreensão e antecipação de cenários futuros. Dentro desse contexto, a problemática geral desse trabalho está centrada na busca por métodos de previsão de vendas que facilitem a adaptação a volatilidade do mercado para uma empresa da indústria automobilístico na área de acumulação de energia. Seguindo o modelo de pesquisa exploratória, a definição do método de previsão consiste nas etapas de coleta de dados históricos de vendas, divisão do conjunto de dados em treinamento e teste, a aplicação dos modelos de Regressão Linear, Suavização Exponencial com Tendência e Sazonalidade, ARIMA e Média móvel simples e a comparação dos resultados de cada modelo gerado. O objetivo principal consiste em avaliar a eficácia dos métodos de previsão mencionados, destacar suas vantagens e limitações e direcionar, fornecendo insights para gestores sobre a escolha adequada dos métodos de previsão de demanda. Dos métodos apresentados, o que apresentou o melhor resultado foi o SARIMA, por se tratar de um modelo preparado para lidar com a sazonalidade de uma amostra, e conseguiu prever com melhor assertividade que todos os outros modelos testados. Com isso, foi realizada a previsão para o horizonte de dois meses, que podem dar suporte no desenvolvimento dos planos de produção. Além disso, o trabalho mostrou que com métodos de previsão simples, que requerem poucos recursos computacionais, e ferramentas de fácil acesso, havendo o conhecimento teórico de aplicação dos métodos, as empresas podem minimizar os impactos de um mercado instável prevendo com considerável acuracidade cenários futuros, oferecendo uma base que possibilita tomadas de decisões mais seguras e sustentáveis.

Palavras-chave: Previsão de demanda; baterias; planejamento.

ABSTRACT

The complexity of the industrial market, with its sensitivity, fluctuations, and uncertainties, underscores the need for methods and tools that are effective in understanding and anticipating future scenarios. Within this context, the general issue of this study is centered around the search for sales forecasting methods that facilitate adaptation to market volatility for an automotive industry company in the energy storage sector. Following the exploratory research model, the definition of the forecasting method comprises the steps of collecting historical sales data, dividing the dataset into training, and testing sets, applying the models of Linear Regression, Exponential Smoothing with Trend and Seasonality, ARIMA, and Simple Moving Average, and comparing the results generated by each model. The main objective is to assess the effectiveness of the mentioned forecasting methods, highlight their advantages and limitations, and provide insights to managers regarding the appropriate choice of demand forecasting methods. Among the presented methods, SARIMA yielded the best results as it is specifically designed to handle sample seasonality, demonstrating superior accuracy compared to all other tested models. Consequently, a two-month forecast was conducted, providing support for production planning. Furthermore, the study demonstrated that with simple forecasting methods, requiring minimal computational resources and accessible tools, companies can mitigate the impacts of an unstable market by accurately predicting future scenarios, providing a foundation for more secure and sustainable decision-making.

Keywords: Demand forecasting; batteries; planning.

SUMÁRIO

1	INTRODUÇÃO	9
1.1	Objetivo Geral	10
1.2	Objetivos Específicos	10
1.3	Empresa objeto de estudo	11
2	REVISÃO BIBLIOGRÁFICA	12
2.1	Regressão linear Simples	17
2.2	Suavização exponencial tripla.....	17
2.3	ARIMA.....	18
2.4	SARIMA	19
2.5	Média móvel simples.....	20
3	MATERIAIS E MÉTODOS	21
3.1	Ferramentas Computacionais utilizadas no estudo	22
3.2	Coleta de Dados	22
3.3	Análise dos Dados.....	23
3.4	Aplicação dos modelos.....	25
3.4.1	<i>Regressão Linear</i>	25
3.4.2	<i>Suavização Exponencial com tendência e sazonalidade</i>	30
3.4.3	SARIMA	36
3.4.4	<i>Média móvel simples</i>	41
3.4.5	<i>Escolha do modelo</i>	42
3.5	Análise gerencial	43
4	CONCLUSÃO	44
	REFERÊNCIAS	45
	APÊNDICE A - CÓDIGO UTILIZADO PARA REALIZAR OS TESTES DE SAZONALIDADE	48
	APÊNDICE B - CÓDIGO UTILIZADO PARA AJUSTAR MODELO SARIMA	49

APÊNDICE C: CÓDIGO UTILIZADO PARA PREVER O HORIZONETE DE PLANEJAMENTO PELO MODELO SARIMA.....	51
--	-----------

1 INTRODUÇÃO

A previsão de demanda é um processo que visa antecipar necessidades futuras do mercado, permitindo que organizações se adaptem proativamente às variações nas demandas por produtos ou serviços (Ackermann, 2022). Além disso, normalmente, é um processo que impacta toda a cadeia produtiva, influenciando a produção, gestão de cadeia de suprimentos e marketing/vendas. A previsão de vendas pode ter várias funcionalidades, mas é comumente utilizada na orientação do planejamento estratégico para gestão eficaz e eficiente de recursos, otimização da gestão de estoques e da capacidade operacional (Armstrong, 2001). A previsão de demanda quando bem desenvolvida, tem impacto crucial na satisfação dos clientes internos, externos e finais, seja de produto, ou de serviço, pois auxilia a indústria a garantir adequados níveis de estoques para atendimento.

De todas as informações que podem servir de input para o desenvolvimento de um planejamento estratégico, o desenvolvimento da previsão de vendas é uma das atividades mais complexas devido à incerteza dos negócios que podem ser afetados por variáveis como sazonalidade, flutuações econômicas, avanços tecnológicos, entre outros, e por isso costumam englobar métodos estatísticos e técnicas para estimar a demanda futura por produtos ou insumos para a produção, geralmente se baseando em informações históricas, análises estatísticas e fatores socioeconômicos.

De forma geral, existem vários métodos de previsão de demanda, mas podemos dividir eles em dois grandes grupos: Métodos qualitativos e quantitativos. O foco desse estudo é a aplicação de métodos quantitativos para a previsão. Podemos definir que “Os métodos quantitativos analisam o comportamento e padrão das séries no passado e traçam projeções futuras sobre elas” (Reis, 2014). Nesse trabalho serão aplicados quatro métodos de previsão de demanda: Regressão Linear Simples, Suavização Exponencial com Tendência e Sazonalidade, SARIMA e Média móvel simples. Com base em uma análise visual da curva de faturamento, representada graficamente, ao ser observado padrões sazonais e tendenciais, os modelos SARIMA e Suavização exponencial tripla foram escolhidos por sua adaptação para lidar com essas características. Além disso, foram escolhidos também, os métodos de Média Móvel Simples e Regressão Linear Simples, pois eles demonstraram como a previsão gerada se comportou ao ser desconsiderada as componentes sazonais e tendenciais da curva de faturamento.

Assim como toda empresa do cenário industrial, o mercado abarcado pela indústria automobilística possui uma demanda variável ao longo do tempo, essas flutuações, acarretam custos relacionados a matéria prima, logística, capacidade, mão de obra entre outros, além de exigir um planejamento bem amarrado para que os impactos das variações do mercado sejam minimizados. A base para a maioria das decisões orientadas para o futuro das empresas é estabelecida pela previsão de demanda (BERMUDEZ, 2006), então, é correto dizer que há previsão de demanda é uma ferramenta fundamental para que a empresa desenvolva um planejamento alinhado e preparado para as inconstâncias do mercado.

Um dos principais produtos da empresa estudada é a venda de baterias para motos no Brasil. A empresa em questão possui um portfólio de 10 modelos de baterias para moto, sendo que o de maior representatividade no faturamento terá seu desempenho analisado por este trabalho.

1.1 Objetivo Geral

O objetivo desse trabalho é definir o melhor modelo de previsão de demanda e a partir dele realizar a previsão de demanda de baterias de moto de uma indústria do setor automobilístico e estimar os volumes futuros de vendas em um horizonte de 2 meses visto que esse intervalo é utilizado para desenvolver os planos de produção mensal.

1.2 Objetivos Específicos

- Reconhecer os padrões sazonais e curva de tendência de médio e longo prazo para acompanhamento de possíveis ciclos que impactam na variável dependente Faturamento;
- Aplicar métodos de previsão de demanda para estimar os valores futuros da variável para que seja possível aumentar o conhecimento e gerar insights para desenvolvimento de uma previsão de vendas com maior acuracidade;
- Aumentar o grau de confiabilidade das previsões desenvolvidas facilitando as decisões que envolvem a criação do plano mensal de produção, fazendo com que ele possa absorver as variações da demanda sem prejudicar o atendimento;

- Sugerir previsões que facilitem o planejamento de recursos, principalmente no que se trata das aquisições de matéria prima, alocação de mão de obra, políticas de estoque e orçamento.
- Demonstrar que métodos simples de previsão podem ser eficientes em estimar valores futuros que sirvam de base para decisões estratégicas.

1.3 Empresa objeto de estudo

A empresa que será o objeto de estudo desse trabalho é uma empresa do setor automobilístico, especializada no desenvolvimento de produtos especializados em acumulação de energia. Atualmente, a empresa é constituída por seis plantas industriais, onde cinco estão localizadas no Brasil, e uma na Argentina que produzem os mais variados tipos de baterias chegando a uma média de 7,5 milhões de baterias vendidas anualmente. A empresa se divide em dois grandes setores, o automotivo, responsável pela produção e venda de baterias para carros, e industrial, que serve para a produção de todas as outras aplicações, incluindo, motos, carrinhos de golfe, torres telefônicas, empilhadeiras, sistemas de alarme, entre muitos outros.

Uma das divisões mais promissoras do mercado de baterias para essa indústria é a venda de baterias para moto, devido ao grande volume de veículos desse porte no Brasil, que segundo o último censo realizado em 2022 Instituto Brasileiro de Geografia e Estatística (IBGE), é de 25.746.762, representando 27% dos veículos do país.

Na corporação estudada, os planos de produção para os modelos de bateria de moto são feitos de maneira a garantir o atendimento da demanda prevista para o primeiro mês mais 21 dias da demanda prevista para o mês seguinte. Por isso é importante que as previsões dentro desse horizonte sejam assertivas para que não haja excesso de estoque ou falta de produto para venda.

2 REVISÃO BIBLIOGRÁFICA

Desenvolver previsões, apesar de um conceito facilmente compreendido, na prática, é uma atividade bastante difícil e arriscada de executar. Nesse contexto existem vários fatores conhecidos e quase infinitos fatores desconhecidos que podem afetar a realidade no futuro, seja ele de curto, médio ou longo prazo, um exemplo, apesar de grosseiro, da complexidade na assertividade da previsão é Thomas Watson, antigo CEO da IBM, que tentou prever a demanda por computadores, no ano de 1950, na qual Thomas acreditava que no “novo milênio haveria uma demanda de 5 computadores para o mundo todo” (Ávila, 2017), cenário que obviamente não se concretizou.

Modelos de previsões de demanda vem sendo amplamente estudados em sistemas produtivos devido a sua utilidade e aplicação no planejamento agregado e integrado de toda a fábrica. Geralmente se baseando em um comportamento histórico, sua principal ideia é procurar antecipar as necessidades do mercado criando um cenário de maior previsibilidade para indústria em questão. MOREIRA (2009) afirma que:

“A previsão de demanda é, pois, um processo racional de busca de informações acerca do valor das vendas futuras de um item ou de um conjunto de itens. Tanto quando possível, a previsão deve fornecer também informações sobre a qualidade e localização (lugar onde serão necessários) dos produtos no futuro.”

Existem inúmeros modelos para diversas situações e circunstâncias, nos quais aqueles que são baseados em horizontes de planejamento e aqueles que são baseados na quantidade de informações, dados e tempo disponíveis para realizar a análise. De forma geral, é possível separar as previsões em três tipos, segundo Cachon e Terwiesch (2017):

- Previsões de curto prazo: As previsões de curto prazo são usadas para apoiar decisões que são tomadas por curtos períodos, desde o nível diário até o nível mensal. Em casos extremos, as previsões podem mesmo ser feitas a nível de horário. Essas previsões são usadas para auxiliar decisões relacionadas a pessoal (restaurantes têm mais servidores no almoço do que à tarde) e precificação de curto prazo.

- Previsões de médio prazo: São previsões que são feitas a partir do nível mensal para o anual nível. Eles conduzem decisões relacionadas à capacidade (recrutamento, aquisição de máquinas), mas também são utilizados para planejamento financeiro.
- Previsões de longo prazo: São previsões que são feitas ao longo de vários anos. Essas previsões ajudar em decisões estratégicas, como entrar em novos mercados, lançar novos produtos ou serviços, ampliando a capacidade investindo em novas instalações, ou fechando instalações.

Os métodos quantitativos podem ser classificados em dois tipos, i) Análises de Séries Temporais e ii) Métodos Causais (REIS, 2024). Muitas vezes os modelos podem trabalhar em conjunto gerando modelos híbridos ou HI – *Hybrid Intelligent Systems* (BAHRAMMIZAEI, 2010). De forma resumida, modelos quantitativos causais fazem a previsão estabelecendo uma relação de causa e efeito entre a variável de demanda e cofatores que possam afetá-la, enquanto os modelos quantitativos do tipo séries temporais utilizam o histórico de demanda para prever o futuro, assumindo que os padrões de dados passados, como tendência e sazonalidade, permanecerão inalterados (BONOTTO, 2015).

Em qualquer caso, a previsão de demanda se baseia em análises estatísticas e cálculos para descrever e prever o comportamento de uma curva. Porém, apesar dos variados modelos existentes, todos eles possuem pontos em comum, os métodos de previsão geralmente assumem que as mesmas causas que estiveram presentes no passado, configurando a demanda, continuarão presentes no futuro. Isso quer dizer que o comportamento do passado é a base para se inferir sobre o comportamento do futuro e os métodos não conduzem resultados perfeitos, e a chance de erro é tanto maior quanto mais nos aprofundarmos no futuro, ou seja, quanto maior seja nosso horizonte de previsão (MOREIRA, 2009).

Logo, independentemente do horizonte de planejamento, volume de dados disponíveis e recursos para desenvolvimento, todo modelo de previsão está sob risco de não assertividade e erros. Por isso devem ser utilizados como estimativas de um possível horizonte de eventos e não como uma determinação do que ocorrerá.

Uma previsão de demanda bem realizada impacta em toda a cadeia produtiva da empresa (CACHON e TERWIESCH, 2017). Explicando de forma sucinta, a previsão de vendas é o principal input para o desenvolvimento dos planos de produção

e aquisição de insumos. Através dela sabe-se como utilizar a capacidade da fábrica para transformar a matéria-prima que se encontra nos almoxarifados de produto acabado, assim como a necessidade de reposição de material para garantir a constância e sustentabilidade do processo produtivo.

Um dos conceitos essenciais para a avaliação de modelos de previsão é a acurácia, podendo ser tratada como um dos principais indicadores para medição de assertividade de uma projeção. Ela se refere a medida de quão corretas e precisas são os valores apresentadas por um modelo em relação aos valores reais. Esse indicador pode vir acompanhado de algumas métricas, as mais conhecidas são (CACHON e TERWIESCH, 2017):

- Erro médio quadrático (RSME): Uma medida que avalia a qualidade de uma previsão ao observar o erro médio quadrático.
- Erro médio absoluto (MAE): Uma medida que avalia a qualidade de uma previsão ao observar o valor absoluto médio do erro de previsão.
- Erro percentual absoluto médio (MAPE): Esta medida não observa os erros de previsão em termos absolutos, mas em termos relativos. Isso é alcançado dividindo os erros de previsão pela demanda real.

No geral essas métricas servem para medir o quão a previsão está se aproximando das vendas reais, permitindo comparações entre diferentes modelos e abordagens fazendo assim com que seja possível avaliar o desempenho de diferentes previsões, destacando como o mais adequado, aquele que obtiver a maior percentual de acuracidade ou menor erro médio.

Uma outra aplicação bastante utilizada para a acurácia é na detecção de padrões de sazonalidade ou tendências de erros que ocorrem no conjunto de dados, observando a ocorrência e periodicidade de outliers, por exemplo, que pode indicar que há algum fator externo as variáveis escolhidas para compor o modelo, levando a percentuais fora do padrão em determinado período, fazendo assim com que o analista possa corrigir e ajustar sua previsão.

Além da sua aplicação na determinação da confiança de uma previsão de vendas, a acurácia é um indicador eficiente em vários cenários, podendo destacar:

- Tomadas de decisões precisas: Para qualquer empresa, quanto maior a assertividade na tomada de decisão para atingir um objetivo, menor os desperdícios como alocação de recursos desnecessários, aquisição de insumos errados, perda de oportunidades ímpares. A acurácia vem para

umentar o grau de certeza e embasar a tomada de decisão nos principais departamentos industriais.

- Controle de processos: Auxiliando na garantia de entrega de produtos seguros e confiáveis, a acurácia pode ser um indicador que determina o grau de conformidade de um produto ou sistema de produção, podendo servir de parâmetro para definir se um item está conforme as especificações ou necessita de retrabalho por exemplo.
- Melhoria contínua: Por se tratar de um indicador que avalia a qualidade atual de um modelo, a acurácia pode servir de diagnóstico e direcionador para melhorias em um sistema, pegando como exemplo a própria previsão de vendas, a acurácia pode indicar a necessidade de um olhar mais criterioso para as instabilidades do mercado para desenvolver melhores modelos de previsão.
- Análise de desempenho: Principalmente se tratando de produção de modelo MTS, em que há políticas de estoque e metas de produção, a acurácia pode comparar o que está sendo produzido com as metas estipuladas pela gerência auxiliando a avaliar se as capacidades e recursos produtivos da fábrica estão sendo utilizados da melhor forma, em um processo dividido por várias etapas por exemplo, se calculado a acurácia por subprocesso, podemos identificar gargalos e atuar na resolução deles.

Antes da aplicação de qualquer um dos métodos de previsão de demanda, seja regressão linear, suavização exponencial com tendência e sazonalidade ou ARIMA, se faz necessária a aplicação de dois testes. O primeiro é o teste de estacionariedade, que segundo Shumway e Stoffer (2017), na qual define-se que uma série estacionária é aquela que para a qual o comportamento probabilístico de cada conjunto de valores $\{x_{t_1}, x_{t_2}, \dots, x_{t_k}\}$ é idêntico ao do conjunto deslocado no tempo $\{x_{t_1+h}, x_{t_2+h}, \dots, x_{t_k+h}\}$. Isto é expresso matematicamente como:

$$P \{x_{t_1} \leq c_1, \dots, x_{t_k} \leq c_k\} = P \{x_{t_1+h} \leq c_1, \dots, x_{t_k+h} \leq c_k\}$$

para todo $k = 1, 2, \dots$, todos os pontos da série temporal t_1, t_2, \dots, t_k , todos os números c_1, c_2, \dots, c_k e todos os deslocamentos temporais $h = 0, \pm 1, \pm 2, \dots$.

Portanto, quer dizer que suas propriedades estatísticas não variam com o tempo, sendo assim, independente do intervalo que se analisar, propriedades como média, covariância e correção são os mesmos em todos os pontos. Esse conceito é importante porque alguns métodos de previsão, como o ARIMA, por exemplo, podem-se fazer necessário a aplicação de métodos para transformar séries não estacionárias em estacionárias.

O segundo teste necessário é o teste de sazonalidade, que serve para verificar se há padrões sistemáticos ou cíclicos que ocorrem em intervalos regulares de tempo. Um dos testes mais comuns é o teste de Kruskal-Wallis. Ele também é usado para testar se um conjunto de amostras provêm da mesma distribuição – testa-se a hipótese nula de que todas as populações possuem funções de distribuição iguais contra a hipótese alternativa de que ao menos duas das populações possuem funções de distribuição diferentes (Monolito Nimbus, 2024).

Portanto, é importante definir se há sazonalidade na série temporal pois esse comportamento pode dar insights sobre o comportamento da série, tornando as variações mais previsíveis para modelar, sem contar que facilita a tomada de decisões com base no período temporal no qual o tomador de decisão se encontra.

2.1 Regressão linear Simples

“Um modelo de Regressão é um modelo matemático que descreve a relação entre duas ou mais variáveis de tipo quantitativo. Se o estudo incidir unicamente sobre duas variáveis e o modelo matemático for a equação de uma reta, então designa-se por regressão” (Graça Martins, 2019).

A maior vantagem desse método é a simplicidade de sua aplicação. Ferramentas como o EXCEL nos permitem realizá-lo com apenas alguns cliques, mas apesar de simples, quando os dados são apresentados um comportamento constante, é uma excelente maneira de prever a demanda com bom grau de acuracidade. Devido a sua sensibilidade a valores “estranhos”, esse modelo normalmente precisa ser ajustado, onde algumas observações podem precisar ser retiradas para que ele seja aplicado, essas observações “estranhas” são conhecidas com outliers.

Uma regressão linear simples é basicamente uma equação, que pode ser escrita na forma $y = ax + b$ que representa o comportamento da curva que relaciona as variáveis dependente e independente, conhecidas comumente como x e y respectivamente. Como o próprio nome implica, a regressão linear não captura a sazonalidade presente em uma distribuição, mas por ser um método prático, pode apresentar resultados interessantes, por isso a ideia principal é tentar entender como o modelo gerado por esse método será adequado para prever o comportamento futuro da curva mesmo desconsiderando variáveis como sazonalidade, para que assim, seja observado o impacto que a exclusão desse fator pode gerar em uma análise e desenvolvimento do modelo de previsão.

2.2 Suavização exponencial tripla

A suavização exponencial, de forma sucinta, é um método que decompõe a série nas componentes de tendência e sazonalidade, suavizando os dados históricos exponencialmente se apoiando apenas nos dados da própria série, isso faz com que não seja necessária a existência da variável dependente trazendo rapidez ao método visto que não se faz necessária a análise de outras variáveis (COELHO, 2008). Segundo Reitsch e Wichern (2001), existem três tipos básicos de suavização exponencial, a Simples, que trata apenas do nível da série, dupla, que trata a tendência e o nível, e por fim, a Tripla, que além das outras características também trata da sazonalidade, sem a necessidade de os dados serem estacionados.

Nesse trabalho é aplicado o método de suavização exponencial tripla. Este modelo é considerado uma série em que seu ciclo sazonal é constante com o tempo, a definição mais adequada para o método aplicado é Suavização Exponencial Tripla para efeitos sazonais aditivos. Matematicamente podemos descrever o modelo de previsão como sendo representado pela equação 1: $Y_t = E_t + T_t + S_t + \epsilon_t, t = 1, 2, \dots$ (ALVES, 2019). Além disso, é preciso adicionar os índices de Nível, Tendência e Sazonalidade, que podem ser calculados pelas equações (2), (3) e (4) respectivamente (ALVES, 2019):

$$E_t = \alpha(Z_t - S_{t-p}) + (1 - \alpha)(E_{t-1} + T_{t-1}) \quad (2)$$

$$T_t = \beta(E_t - E_{t-1}) + (1 - \beta)(T_{t-1}) \quad (3)$$

$$S_t = \gamma(Y_t - E_t) + (1 - \gamma)(S_{t-p}) \quad (4)$$

Onde Alfa, Beta e Gamma, são os parâmetros de suavização referentes ao nível (E_t), a tendência (T_t) e a sazonalidade (S_t) no período t , em que existe uma estimativa do índice sazonal no período $t-p$ (ALVES, 2019).

2.3 ARIMA

O modelo ARIMA é um modelo autorregressivo, ou seja, um modelo estatístico em que o valor atual de uma variável é determinado pela combinação linear de seus valores passados, que surgiu do modelo ARMA e pode ser aplicado quando há estacionalidade (BOX et al., 2016). De forma matemática, o modelo ARIMA pode ser denotado como $ARIMA(p, d, q)$, sendo p o operador autorregressivo, d o operador diferença e q o operador de médias móveis, da qual a equação é dada pela equação (5) e resumida pela equação (6) (Araújo, 2023):

$$W_t = \phi_1 W_{t-1} + \dots + \phi_p W_{t-p} + \epsilon_t - \theta_1 \epsilon_{t-1} - \dots - \theta_q \epsilon_{t-q} \quad \text{em que} \quad W_t = \nabla^d Z_t. \quad (5)$$

Podendo ser escrita como:
$$\phi(B)((1 - B)^d Z_t - \alpha) = \theta(B)\epsilon_t \quad (6)$$

Etapas de aplicação do ARIMA:

Pode-se resumir as etapas de aplicação em três, identificação do modelo, estimação dos parâmetros e verificação.

Na etapa de identificação é onde são definidos os parâmetros p , d e q (LIMA, 2019). Além disso, nessa etapa também é realizado o teste de estacionalidade, neste trabalho, é utilizado o método ADF .

A próxima etapa é a de estimação dos parâmetros dos parâmetros. Um método bastante aplicado é o de Máxima Verossimilhança, que é comumente aplicado nos softwares estatísticos. Com isso, é possível estimar o modelo que descreverá o comportamento da amostra e realizará as previsões.

Na última etapa, validação, é realizada a análise dos resíduos que irão determinar a qualidade do modelo preditivo, nesse estudo, os indicadores utilizados serão o MAE, MAPE e RMSE. Nessa etapa geralmente parte da amostra é dividida em duas amostras menores, onde uma servirá para teste e outra para validação, na amostra de validação, o modelo será aplicado, na amostra de teste, as previsões serão realizadas e analisadas.

2.4 SARIMA

Em alguns casos, as séries temporais apresentam padrões repetitivos em um mesmo intervalo de tempo ao longo da distribuição. Uma vez que estes padrões permitem definir o comportamento de uma curva. Para o faturamento estudando neste trabalho é adicionado esse parâmetro na análise do modelo. Para isso Box e Jenkins (1976) incrementaram o modelo ARIMA e desenvolveram o modelo SARIMA que pode ser representado pela equação (7):

$$\phi_p(B)\phi_p(B^s)\Delta^d\Delta_s^D z_t = \theta_q(B)\theta_q(B^s)a_t \quad (7)$$

onde, $\Delta_s^D z_t = (1 - B^s)^D z_t$, D é a ordem de diferenciação sazonal, $\phi_p(B^s)$ é o operador sazonal AR(p) definido por $\phi_p(B^s) = 1 - \phi_1(B^s) - \phi_2(B^s) - \dots - \phi_p(B^{ps})$; $\theta_q(B^s)$ é o operador sazonal MA(q) definido por $\theta_q(B^s) = 1 - \theta_1(B^s) - \theta_2(B^s) - \dots - \theta_q(B^{qs})$, e ϕ_1, \dots, ϕ_p são parâmetros do modelo sazonal AR(p) e $\theta_1, \dots, \theta_q$ são parâmetros do modelo sazonal MA(q) (Walter, 2013).

De forma simplificada, tem-se que adicionar os parâmetros de sazonalidade no método ARIMA para que esse comportamento seja incluso no ajuste do modelo ficando assim SARIMA(p, q, d)(P, Q, D)(s), sendo (s) o período sazonal.

2.5 Média móvel simples

O método de média móvel é utilizado para estimar a média de uma série temporal e filtrar variações aleatórias. Calcula-se a média para os n períodos mais recentes (ZAN, 2007). O método é representado matematicamente de acordo com a equação (8):

$$F_{t+1} = \frac{x_t + x_{t-1} + \dots + x_{t-n+1}}{n} \quad (8)$$

onde, x_t é a demanda real do período t , n é o número total de períodos na média e F_{t+1} é a previsão para o período $t + 1$.

A maior vantagem desse método é a simplicidade operacional, por se tratar de uma fórmula simples, com poucos recursos computacionais é possível desenvolver um modelo de previsão baseado em médias móveis:

“Quanto maior o número de períodos passados utilizados no cálculo, maior a suavização das variações aleatórias e menor a sensibilidade do modelo a mudanças de patamar nas vendas, caso venha a ocorrer. Apesar dos problemas, os modelos de média móvel são úteis quando se busca um modelo simples e de baixo custo para prever vendas de muitos itens com histórico de pequenas flutuações e sem indicações de tendências.” (CORRÊA, 2001).

A ideia de aplicar esse modelo, é semelhante a ideia apresentada no método de regressão linear simples. Apesar de ser uma abordagem diferente, a média móvel se destaca também pela sua simplicidade operacional, podendo apresentar resultados interessantes com pouco esforço computacional.

3 MATERIAIS E MÉTODOS

O Método de pesquisa escolhido para esse trabalho é a Pesquisa Experimental, esse modelo de pesquisa consiste em “determinar um objeto de estudo, selecionar as variáveis capazes de influenciá-lo e definir as formas de controle e de observação dos efeitos que a variável produz no objeto” (Gil, 2019). É um método em que o pesquisador irá, como agente ativo, manipular as variáveis das observações a fim de testar uma hipótese. Para tanto, para ser classificada com pesquisa experimental, deve abordar três propriedades principais (Gil, 2019):

- Manipulação: o pesquisador precisa fazer alguma coisa para manipular pelo menos uma das características dos elementos estudados;
- Controle: o pesquisador precisa introduzir um ou mais controles na situação experimental, sobretudo criando um grupo de controle;
- Distribuição aleatória: a designação dos elementos para participar dos grupos experimentais e de controle deve ser feita aleatoriamente.

Para tanto, o método de pesquisa experimental foi escolhido devido à sua capacidade de controlar variáveis independentes e manipular condições para observar os efeitos causais. Essa abordagem permitirá avaliar o desempenho de diferentes modelos de previsão sob condições específicas, contribuindo para uma compreensão mais aprofundada de suas aplicações.

Um dos objetivos desse trabalho é mostrar que com métodos de previsão, pode-se desenvolver modelos preditivos eficientes para uma indústria, por isso, foram escolhidos modelos de fácil aplicação e disponíveis em softwares de comum acesso, como Excel, e programação que não exija alta complexidade utilizando R.

O estudo aplica os métodos de Regressão linear, Suavização Exponencial com Tendência e Sazonalidade, SARIMA e Média móvel Simples para o desenvolvimento de modelos de previsão de demanda. De forma geral, o banco de dados possui uma variável independente, que são os meses percorridos de 2020 a 2023 e uma variável dependente tem-se o faturamento mensal. As previsões concernem e visualizam um cenário de faturamento em um horizonte de dois meses para dar suporte ao planejamento da produção.

Para muitos modelos de séries temporais é necessário que a estacionalidade da série seja comprovada para que os métodos de previsão funcionem corretamente, para isso, foi aplicado o teste ADF que “considera a ausência de estacionalidade como

hipótese nula. Ao não rejeitar esta hipótese nula, não é encontrada evidência de estacionalidade, razão pela qual é mais plausível considerar a sua ausência. Neste caso, uma prática frequentemente adotada consiste na diferenciação sucessiva da série até atingi-la, sendo a última diferenciação determinante de sua ordem de integração.” (Silveira, 2022).

Para comparar a qualidade das previsões geradas por cada modelo, foram avaliados os principais indicadores de erro, MAE (Erro médio absoluto), MAPE (Erro percentual absoluto médio) e RSME (Erro Quadrático Médio da Raiz), sendo o MAPE o principal indicador que definiu o melhor método, o MAE e o RSME serviram mais para caso houvesse necessidade de um critério de desempate.

3.1 Ferramentas Computacionais utilizadas no estudo

A pesquisa desenvolvida utilizar-se-á de forma principal três ferramentas, o software R version 4.2.2 (2022-10-31 ucrt) e o ambiente de desenvolvimento Rstudio 2023.07.2+576 e o EXCEL (Versão 2401 Build 16.0.17231.20236). A escolha dessas ferramentas se deu pela sua ampla utilização na comunidade científica e na quantidade considerável de bibliotecas estatísticas. Dentro das ferramentas, foram utilizadas principalmente as bibliotecas “forecast”, que inclui os modelos de previsão desenvolvidos, “data.table”, para converter as observações da coluna da variável independente para formatos de data e “xts”, especializada em lidar com séries temporais.

3.2 Coleta de Dados

A base de dados que foi inserida no software R e no Excel se encontrava no SharePoint da empresa estudada. Para isso, foi necessário realizar a importação dos dados e tratamento das informações, que foram integradas as etapas de coleta, manipulação e processamento de dados. Foi utilizado uma amostra com 48 observações, compreendendo os meses de janeiro de 2020 até dezembro de 2023. Abaixo é mostrada a tabela 1 que representa o faturamento por mês no intervalo citado:

Tabela 1: Dados Coletados: Faturamento por Mês

Nº DE OBS.	DATA	FATURAMENTO	Nº DE OBS.	DATA	FATURAMENTO
1	01/01/20	20.292	25	01/01/22	26.068
2	01/02/20	24.336	26	01/02/22	36.098
3	01/03/20	31.473	27	01/03/22	51.242
4	01/04/20	12.663	28	01/04/22	50.784
5	01/05/20	34.865	29	01/05/22	51.904
6	01/06/20	52.228	30	01/06/22	46.011
7	01/07/20	46.896	31	01/07/22	49.716
8	01/08/20	48.318	32	01/08/22	42.879
9	01/09/20	40.200	33	01/09/22	39.126
10	01/10/20	44.550	34	01/10/22	36.581
11	01/11/20	46.794	35	01/11/22	39.906
12	01/12/20	25.029	36	01/12/22	40.290
13	01/01/21	48.936	37	01/01/23	35.556
14	01/02/21	28.002	38	01/02/23	39.626
15	01/03/21	28.798	39	01/03/23	56.333
16	01/04/21	36.760	40	01/04/23	48.632
17	01/05/21	46.380	41	01/05/23	52.722
18	01/06/21	57.409	42	01/06/23	58.172
19	01/07/21	40.200	43	01/07/23	52.468
20	01/08/21	42.265	44	01/08/23	54.192
21	01/09/21	51.888	46	01/09/23	54.408
22	01/10/21	43.332	46	01/10/23	50.282
23	01/11/21	33.886	47	01/11/23	50.646
24	01/12/21	37.674	48	01/12/23	41.487

Fonte: O autor (2024)

3.3 Análise dos Dados

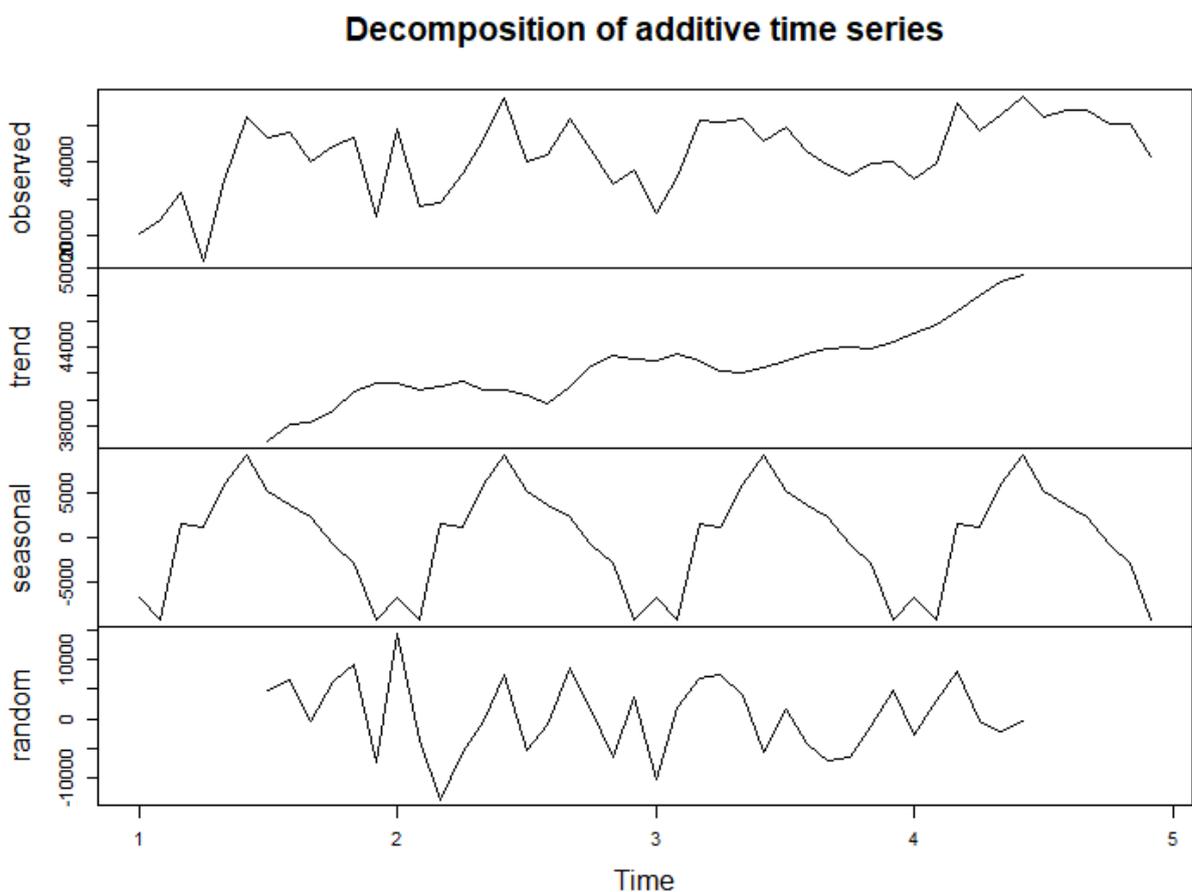
A primeira etapa do processo de análise se deu na realização do teste de estacionalidade ADF, considerando o valor padrão do R para o grau de significância de 0,05, para ser comparado com o valor- p retornado pelo software utilizado. Posteriormente, aplica-se o método de Kruskal-Wallis e Dickey-Fuller para o teste de sazonalidade para identificação de possíveis padrões cíclicos.

Ao realizar o Teste ADF, foi obtido o seguinte resultado: Dickey-Fuller = -4.8126, Lag order = 3, p -value = 0.01. Sabendo que a hipótese nula (H_0) era de que a série temporal não é estacionária e que quanto mais negativo o valor do teste for, maior a evidência contra H_0 . O valor- p de 0,01 que é menor que o nível de significância que considerado nesse trabalho, de 0,05. Logo, pode-se concluir que há evidências de que a série é estacionária, podendo assim rejeitar a hipótese nula.

Com relação ao teste de Kruskal-Wallis, obteve-se o seguinte resultado: Kruskal-Wallis chi-squared = 10.644, df = 3, p -value = 0.01382. Nesse teste, a hipótese nula é de que as medianas de todos os grupos são iguais. Ao observar os resultados, teve-se uma estatística de qui-quadrado de 10.644, quanto maior esse valor, maior a chance de rejeitar a hipótese nula. Obteve-se também um valor- p de

0,01382, menor que o nível de significância de 0,05 considerados nesse trabalho, o que sugere que há evidências para rejeitar H_0 . Em resumo, há diferenças significativas no faturamento que possam sugerir uma estacionalidade. Desta forma esse teste não indica a origem dessas variações e, para isso, foi realizada a decomposição sazonal da amostra, e esses gráficos foram retornados, conforme mostrado na Figura 1. Nessa imagem, pode-se observar no campo de seasonal o comportamento sazonal da distribuição, essa imagem em trend, também nos mostra a linha de tendência, sendo ela crescente no decorrer do tempo.

Figura 1: Decomposição de séries temporais aditivas.



Fonte: O autor (2024)

A amostra passou pelo ajuste de modelo correspondente a cada um dos métodos estatísticos testados para desenvolver as previsões, Regressão Linear, Suavização exponencial tripla, SARIMA e Média Móvel.

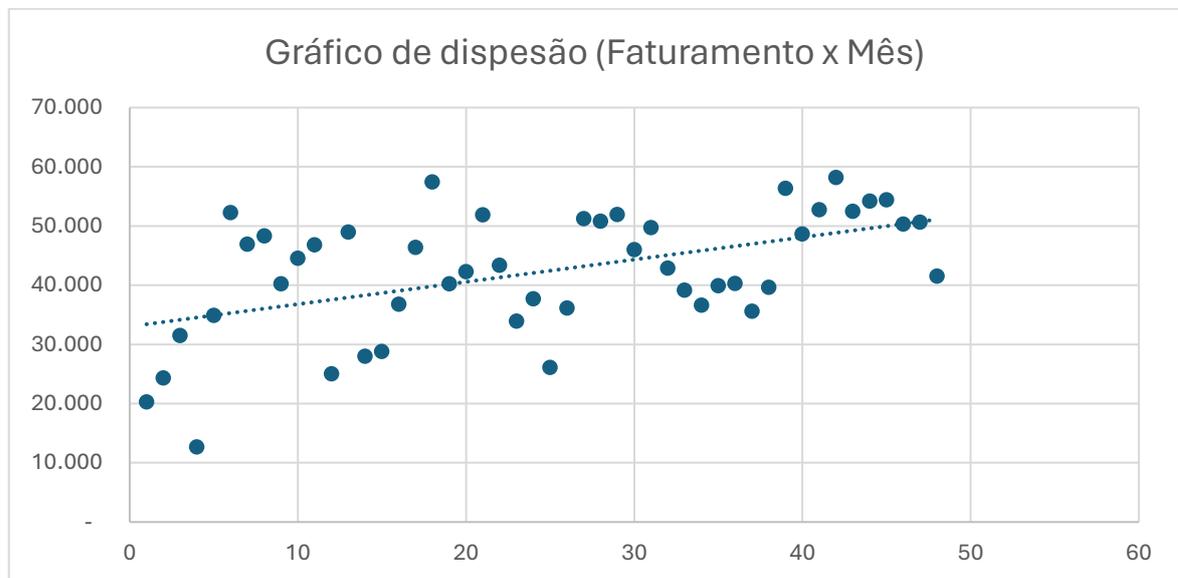
Para verificar a qualidade das previsões geradas e comparar os métodos entre si, foram realizados os testes de MAE, MAPE e RSME. Também foi gerado um gráfico de resíduo, para avaliar se o modelo é adequado ou se há necessidade de considerarmos um método mais complexo de previsão.

3.4 Aplicação dos modelos

3.4.1 Regressão Linear

A primeira etapa desse método consistiu na construção de uma tabela para organizar os dados. Na Tabela 1 pode-se observar como o faturamento se comportou de janeiro a 2020 até dezembro de 2023. Com os dados organizados em tabela, é calculado a correlação entre as variáveis dependentes e independentes, utilizando a fórmula do Excel =CORREL, encontrando uma correlação de 0,5317. Graficamente, podemos observar como as variáveis se organizam em torno da linha de tendência na Figura 2.

Figura 2: Linha de Tendência

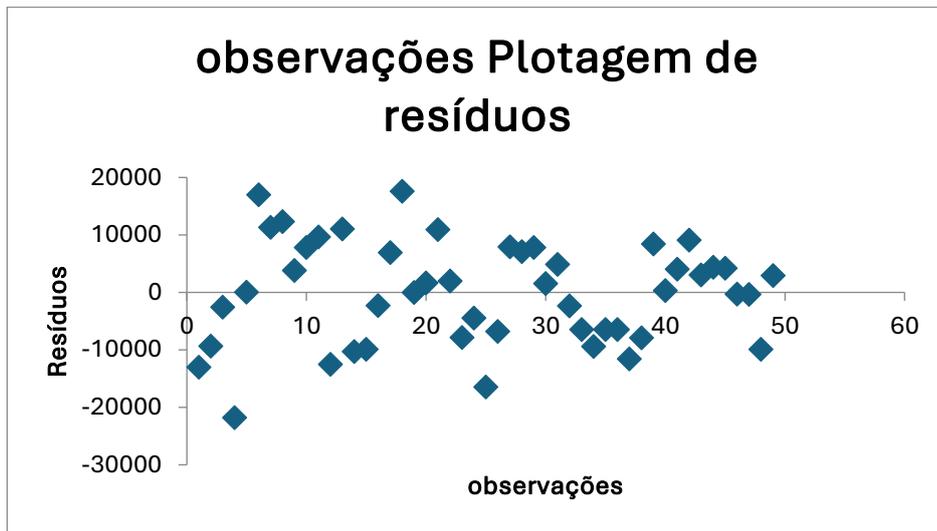


Fonte: O autor (2024)

A correspondência encontrada não possui um valor alto, mas também não é baixo suficiente para que se possa desconsiderá-la, pela linha de tendência entre as variáveis Faturamento e Mês, pode-se observar pelo comportamento do gráfico na Figura 2 que os valores de Faturamento estão cada vez maiores com o passar dos meses.

Mais uma forma que podemos indicar a possibilidade de adotar o modelo de regressão linear é a forma com que os erros estão dispostos em uma linha central, conforme mostrado na Figura 3.

Figura 3: Gráfico de Resíduos

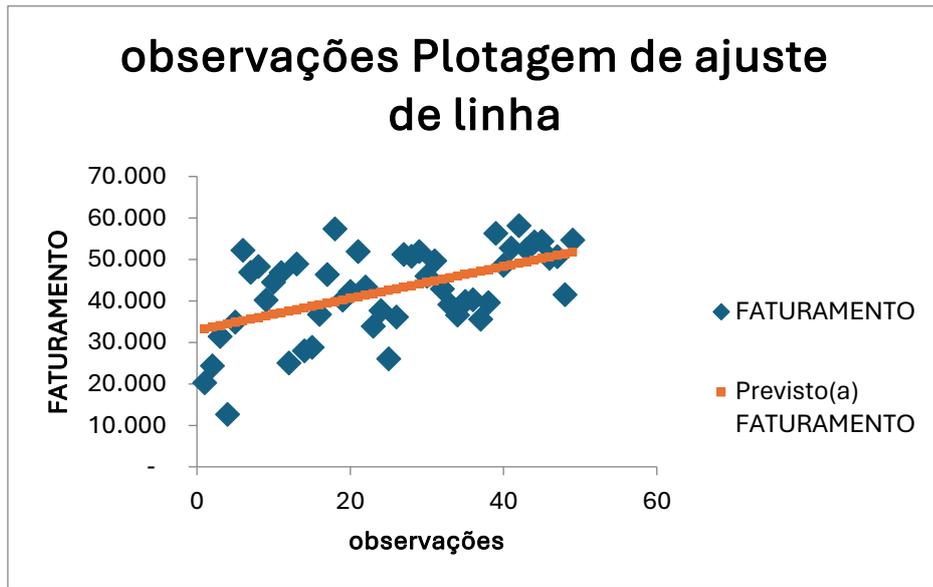


Fonte: O autor (2024)

Como não se pode observar nenhum padrão na distribuição dos resíduos em torno da linha central, pode-se afirmar que os resultados são aleatórios, isso quer dizer que a variação dos erros, não afeta sistematicamente o resultado do modelo.

Além disso, pode-se analisar na Figura 4 que os valores apresentados pela linha ajustada não são iguais aos valores observados, mas seguem a mesma tendência, o que pode indicar que um modelo de previsão satisfatório poderá ser encontrado, mesmo com uma correlação encontrada pouco satisfatória.

Figura 4: Ajuste de linha



Fonte: O autor (2024)

A regressão retorna a seguinte equação: $y = 376,6844876x + 33027,5425531915$. Na Tabela 2 tem-se os principais indicadores estatísticos da regressão:

Tabela 2: Estatísticas da regressão

<i>Estatística de regressão</i>	
R múltiplo	0,526202
R-Quadrado	0,276889
R-quadrado ajustado	0,261504
Erro padrão	8971,95
Observações	49

Fonte: O autor (2024)

Uma forma de avaliarmos se o modelo é significativo para prever a amostra é usando o ANOVA, conforme mostrado na Tabela 3.

Tabela 3: Teste ANOVA

	<i>GI</i>	<i>SQ</i>	<i>MQ</i>	<i>F</i>	<i>F de significação</i>
Regressão	1	1448679116	1,45E+09	17,99693	0,000103039
Resíduo	47	3783306423	80495881		
Total	48	5231985540			

Fonte: O autor (2024)

Onde *GI* representa os graus de liberdade, que indica o número de parâmetros no modelo regressivo, *SQ* representa a soma dos quadrados das diferenças entre os valores previstos e média observada, *MQ* representa a média dos quadrados dividido pelo grau de liberdade, *F* representando a razão entre a média dos quadrados da regressão e a média dos quadrados do resíduo e por fim o *F de significação* que indica a probabilidade de obter uma estatística *F* igual ou mais extrema que a observada, considerando como H_0 que todos os coeficientes de regressão são iguais a zero. Geralmente um *F de significação* baixo, sugere que a regressão estatística é significativa.

Por padrão o EXCEL considera uma significância de 0,05, ao observar a Tabela 3, pode-se notar que o *F de significação* dado é bem menor que o tabelado, $0,000103039 < 0,05$. Logo, considerando a hipótese nula de que não há efeito global, ou seja, todas as inclinações das variáveis independentes no modelo de regressão são iguais a zero, um *F de significação* baixo implica que podemos rejeitar essa hipótese e isso é um indicador de que a regressão é significativa a um grau de 0,05 de significância.

Apesar disso, existem outros indicadores que podem mensurar a qualidade do modelo preditivo, sendo esses o MAE, MAPE e RMSE. Na Tabela 4 pode-se observar os resultados.

Tabela 4: Análise dos erros do modelo de previsão

<i>Observação</i>	<i>Previsto</i>	<i>FATURAMENTO</i>	<i>MAE</i>	<i>MAPE</i>	<i>RMSE</i>
1	33282,10694	20292	-12990,10694	0,640159025	168742878,3
2	33666,58633	24336	-9330,586327	0,383406736	87059841,2
3	34051,06571	31473	-2578,065714	0,081913568	6646422,827
4	34435,5451	12663	-21772,5451	1,719382856	474043720,2
5	34820,02449	34865	44,9755102	0,00128999	2022,796518
6	35204,50388	52228	17023,49612	0,325945779	289799420,2
7	35588,98327	46896	11307,01673	0,24110834	127848627,4
8	35973,46265	48318	12344,53735	0,255485271	152387602,3

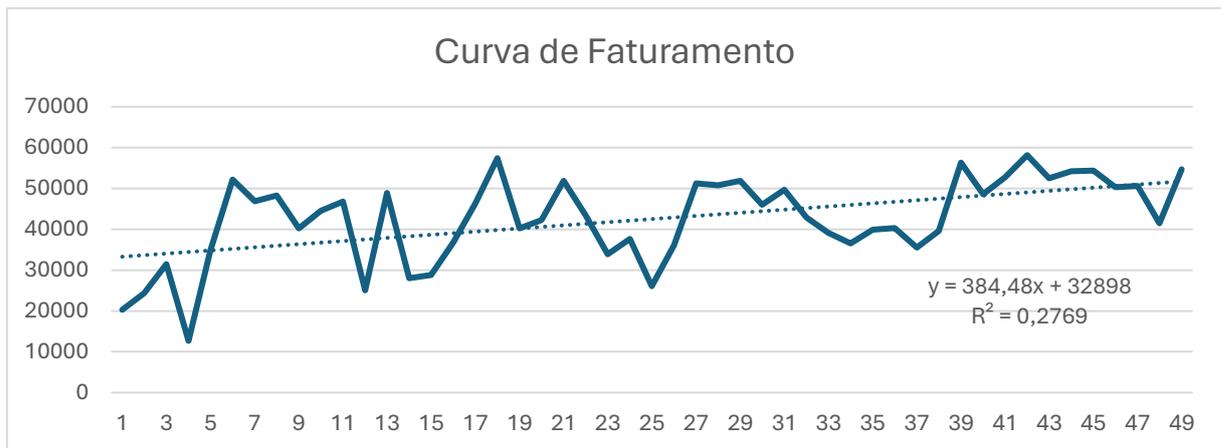
9	36357,94204	40200	3842,057959	0,095573581	14761409,36
10	36742,42143	44550	7807,578571	0,175254289	60958283,15
11	37126,90082	46794	9667,099184	0,206588434	93452806,63
12	37511,3802	25029	-12482,3802	0,498716697	155809815,6
13	37895,85959	48936	11040,14041	0,225603654	121884700,2
14	38280,33898	28002	-10278,33898	0,367057317	105644252,2
15	38664,81837	28798	-9866,818367	0,342621653	97354104,69
16	39049,29776	36760	-2289,297755	0,06227687	5240884,212
17	39433,77714	46380	6946,222857	0,149767634	48250011,98
18	39818,25653	57409	17590,74347	0,306410902	309434255,8
19	40202,73592	40200	-2,735918367	6,80577E-05	7,485249313
20	40587,21531	42265	1677,784694	0,039696787	2814961,479
21	40971,69469	51888	10916,30531	0,210382079	119165721,5
22	41356,17408	43332	1975,825918	0,045597386	3903888,06
23	41740,65347	33886	-7854,653469	0,231796419	61695581,12
24	42125,13286	37674	-4451,132857	0,118148666	19812583,71
25	42509,61224	26068	-16441,61224	0,630720126	270326613,2
26	42894,09163	36098	-6796,091633	0,188267816	46186861,48
27	43278,57102	51242	7963,42898	0,155408239	63416201,11
28	43663,05041	50784	7120,949592	0,140220337	50707923,09
29	44047,5298	51904	7856,470204	0,151365409	61724124,07
30	44432,00918	46011	1578,990816	0,034317681	2493211,998
31	44816,48857	49716	4899,511429	0,098549993	24005212,24
32	45200,96796	42879	-2321,967959	0,054151635	5391535,203
33	45585,44735	39126	-6459,447347	0,165093476	41724460,03
34	45969,92673	36581	-9388,926735	0,256661292	88151945,23
35	46354,40612	39906	-6448,406122	0,161589889	41581941,52
36	46738,88551	40290	-6448,88551	0,16006169	41588124,32
37	47123,3649	35556	-11567,3649	0,325328071	133803930,7
38	47507,84429	39626	-7881,844286	0,198905877	62123469,34
39	47892,32367	56333	8440,676327	0,149835378	71245016,85
40	48276,80306	48632	355,1969388	0,00730377	126164,8653
41	48661,28245	52722	4060,717551	0,077021311	16489427,03
42	49045,76184	58172	9126,238163	0,156883693	83288223,01
43	49430,24122	52468	3037,758776	0,057897362	9227978,378
44	49814,72061	54192	4377,279388	0,080773535	19160574,84
45	50199,2	54408	4208,8	0,077356271	17713997,44
46	50583,67939	50282	-301,6793878	0,005999749	91010,453
47	50968,15878	50646	-322,1587755	0,006360992	103786,2766
48	51352,63816	41487	-9865,638163	0,237800713	97330816,37
49	51737,11755	54668	2930,882449	0,053612396	8590071,93
MÉDIA			1,59E-12	21%	77210335,17

Fonte: O autor (2024)

3.4.2 Suavização Exponencial com tendência e sazonalidade

A primeira etapa desse método, que constituiu uma análise da curva de faturamento, além dos testes de Kruskal-Wallis e de decomposição confirmarem a existência de sazonalidade, ela pôde ser observada ao fazer a plotagem da curva no Figura 4.

Figura 4: Curva de Faturamento



Fonte: O autor (2024)

Analisando a curva, pode-se observar que a sazonalidade performa em um ciclo de 12 meses, ou 12 observações, também é apresentado um coeficiente de determinação de 0,27, muito baixo, indicando que a curva de tendência/equação do gráfico, não representa bem a distribuição. Pela equação ser uma função de primeiro grau, ela não capta a sazonalidade presente na curva. Para obtermos uma equação mais fiel, foi necessário linearizar a distribuição fazendo a diferenciação da amostra.

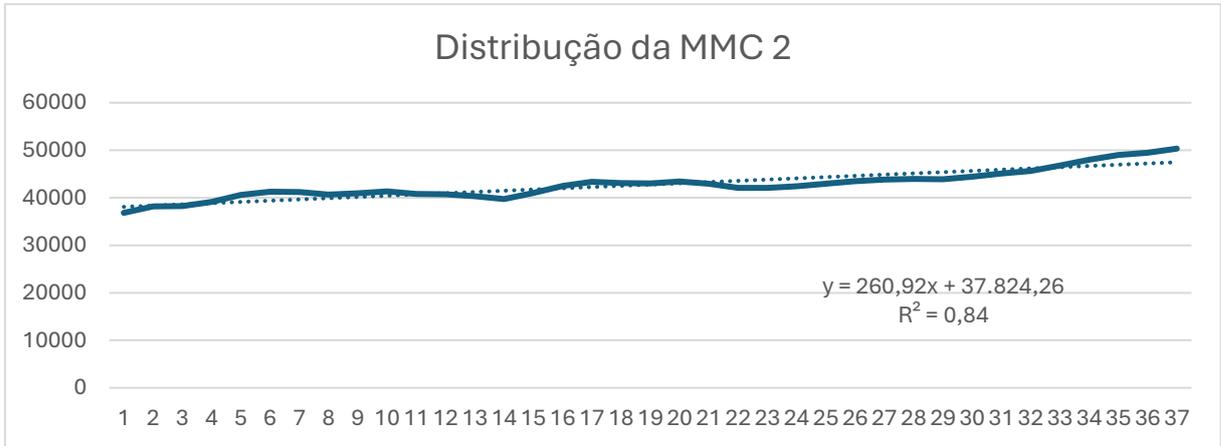
Para o método de suavização exponencial funcionar, é necessário que a distribuição se comporte de forma estacionária, para isso, foram realizadas duas diferenciações calculando as médias móveis centradas tendo como base o período sazonal encontrado, conforme mostrados na Tabela 5 e na Figura 5.

Tabela 5: Diferenciação realizada calculando as duas médias móveis centradas

Observação	FATURAMENTO	MMC1	MMC2
1	20292		
2	24336	35637	
3	31473	38024	36830,5
4	12663	38329,5	38176,75
5	34865	38106,583	38218,042
6	52228	40114,667	39110,625
7	46896	41074,25	40594,458
8	48318	41506	41290,125
9	40200	40948	41227
10	44550	40443,583	40695,792
11	46794	41417,583	40930,583
12	25029	41316,083	41366,833
13	48936	40240,417	40778,25
14	28002	41294,167	40767,292
15	28798	39388,5	40341,333
16	36760	40063,167	39725,833
17	46380	41933,5	40998,333
18	57409	43102,167	42517,833
19	40200	43562,5	43332,333
20	42265	42612,667	43087,583
21	51888	43405,667	43009,167
22	43332	43456,833	43431,25
23	33886	42393,333	42925,083
24	37674	41830,75	42112,042
25	26068	42332,417	42081,583
26	36098	42550,417	42441,417
27	51242	43341,083	42945,75
28	50784	43635,083	43488,083
29	51904	44059,333	43847,208
30	46011	43880	43969,667
31	49716	43948,167	43914,083
32	42879	44961,583	44454,875
33	39126	45190,917	45076,25
34	36581	46133,667	45662,292
35	39906	47407,167	46770,417
36	40290	48548,917	47978,042
37	35556	49443,917	48996,417
38	39626	49543,667	49493,792
39	56333	51136,333	50340

Fonte: O autor (2024)

Figura 5 : Curva de tendência calculada pela diferenciação da amostra



Fonte: O autor (2024)

Pode-se observar que o coeficiente de determinação mostrado na Figura 5 está bem mais próximo de 1, o que indica que a reta de tendência e equação explicam bem o comportamento dos dados da MMC2.

Pela fórmula gerada pelo gráfico, é extraída a interceptação (a) e o coeficiente angular (b) de valores respectivamente 37824,2618243244 e 260,923512328115.

Entrada a equação da reta, representando a tendência, é calculado também o índice de sazonalidade, que represa uma relação de divisão da demanda real pela média móvel centrada 2, pode-se observar os resultados da Tabela 6.

Tabela 6: Índices de Sazonalidade

MMC2	INDICE DE SAZONALIDADE
36830,5	0,854536322
38176,75	0,331694028
38218,042	0,912265477
39110,625	1,335391598
40594,458	1,155231574
41290,125	1,170207162
41227	0,975089141
40695,792	1,094707786
40930,583	1,143252702
41366,833	0,605049939
40778,25	1,200051498
40767,292	0,686874179
40341,333	0,713858408
39725,833	0,925342451
40998,333	1,131265499

42517,833	1,350233431
43332,333	0,927713716
43087,583	0,98090904
43009,167	1,206440487
43431,25	0,997714779
42925,083	0,78942188
42112,042	0,894613477
42081,583	0,619463384
42441,417	0,850537113
42945,75	1,193179767
43488,083	1,167768182
43847,208	1,18374697
43969,667	1,046425945
43914,083	1,132119726
44454,875	0,964551132
45076,25	0,867995896
45662,292	0,801120545
46770,417	0,853231655
47978,042	0,839759161
48996,417	0,725685722
49493,792	0,800625668
50340	1,119050457

Fonte: O autor (2024)

Com isso, foi realizada a construção da Tabela 7, que representa a sazonalidade para cada ciclo de 12 meses pela média dos IS em seus respectivos períodos.

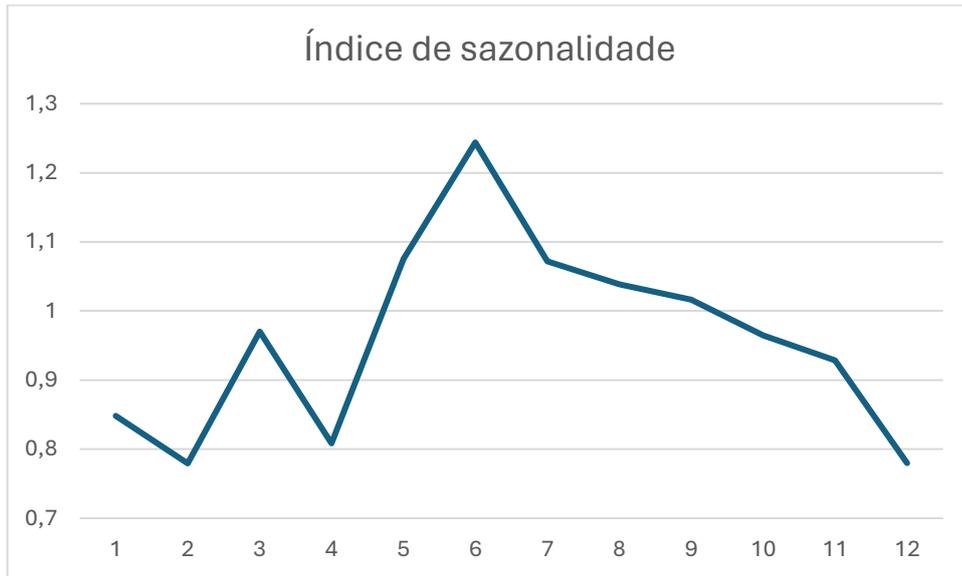
Tabela 7: Índice de sazonalidade por período

Período	Índice de sazonalidade
1	0,848400201
2	0,779345653
3	0,970156239
4	0,808268221
5	1,075759315
6	1,244016991
7	1,071688339
8	1,038555778
9	1,016508508
10	0,96451437
11	0,928635412
12	0,779807526

Fonte: O autor (2024)

Ao observar a Tabela 7 dos índices de sazonalidade, nota-se que há tendência de crescimento nos 6 primeiros meses, e decréscimo nos próximos 6, podemos observar esse comportamento na Figura 6.

Figura 6: Plotagem dos índices de sazonalidade



Fonte: O autor (2024)

Com as componentes tendência, representada pela equação da reta da MMC2 e com os índices de sazonalidade, foi construído a Tabela 8 e a figura 7 que representa graficamente a curva de faturamento e a previsão gerada pelo modelo.

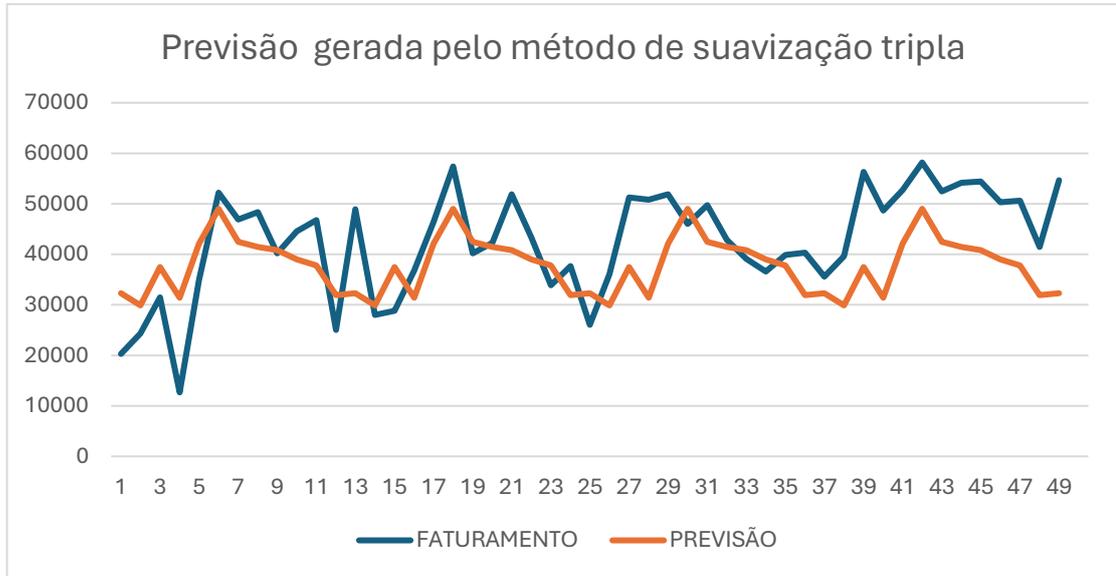
Tabela 8: Previsão gerada e cálculos dos erros

FATURAMENTO	PREVISÃO	desvio padrão	MAE	MAPE	RMSE
20292	32311,4789	8499,055038	-12019,4789	0,592326	144467873,1
24336	29884,87325	3923,645904	-5548,873251	0,228011	30789994,35
31473	37454,8533	4229,809032	-5981,8533	0,190063	35782568,9
12663	31415,73353	13260,18504	-18752,73353	1,480908	351665014,8
34865	42093,25649	5111,149178	-7228,256487	0,207321	52247691,84
52228	49001,58409	2281,420567	3226,415907	0,061776	10409759,6
46896	42493,22112	3113,234799	4402,778876	0,093884	19384461,83
48318	41450,47464	4856,073755	6867,525364	0,142132	47162904,62
40200	40835,76268	449,5521054	-635,7626845	0,015815	404194,191
44550	38998,68884	3925,369764	5551,311157	0,124609	30817055,57
46794	37790,27993	6366,59152	9003,720073	0,192412	81066975,16
25029	31937,28544	4884,895481	-6908,28544	0,276011	47724407,72
48936	32311,4789	11755,3116	16624,5211	0,33972	276374701,7
28002	29884,87325	1331,392444	-1882,873251	0,067241	3545211,679

28798	37454,8533	6121,319672	-8656,8533	0,300606	74941109,05
36760	31415,73353	3778,967062	5344,266471	0,145383	28561184,12
46380	42093,25649	3031,185407	4286,743513	0,092427	18376169,95
57409	49001,58409	5944,9408	8407,415907	0,146448	70684642,23
40200	42493,22112	1621,552208	-2293,221124	0,057045	5258863,124
42265	41450,47464	575,9564081	814,5253637	0,019272	663451,568
51888	40835,76268	7815,111953	11052,23732	0,213002	122151949,7
43332	38998,68884	3064,113704	4333,311157	0,100003	18777585,59
33886	37790,27993	2760,742812	-3904,279927	0,115218	15243401,75
37674	31937,28544	4056,469767	5736,71456	0,152273	32909893,94
26068	32311,4789	4414,80627	-6243,478902	0,239507	38981028,8
36098	29884,87325	4393,344057	6213,126749	0,172118	38602944
51242	37454,8533	9748,984925	13787,1467	0,269059	190085414,1
50784	31415,73353	13695,43256	19368,26647	0,381385	375129746,1
51904	42093,25649	6937,243267	9810,743513	0,189017	96250688,28
46011	49001,58409	2114,662292	-2990,584093	0,064997	8943593,217
49716	42493,22112	5107,275922	7222,778876	0,145281	52168534,69
42879	41450,47464	1010,119972	1428,525364	0,033315	2040684,715
39126	40835,76268	1208,984788	-1709,762685	0,043699	2923288,437
36581	38998,68884	1709,564175	-2417,688843	0,066091	5845219,339
39906	37790,27993	1496,040011	2115,720073	0,053018	4476271,429
40290	31937,28544	5906,261107	8352,71456	0,207315	69767840,52
35556	32311,4789	2294,22287	3244,521098	0,091251	10526917,15
39626	29884,87325	6888,016781	9741,126749	0,245827	94889550,34
56333	37454,8533	13348,86555	18878,1467	0,335117	356384422,8
48632	31415,73353	12173,73877	17216,26647	0,354011	296399831,2
52722	42093,25649	7515,656614	10628,74351	0,2016	112970188,7
58172	49001,58409	6484,463274	9170,415907	0,157643	84096527,91
52468	42493,22112	7053,233784	9974,778876	0,190112	99496213,62
54192	41450,47464	9009,618987	12741,52536	0,235118	162346468,6
54408	40835,76268	9597,021042	13572,23732	0,249453	184205625,7
50282	38998,68884	7978,505834	11283,31116	0,224401	127313110,7
50646	37790,27993	9090,366841	12855,72007	0,253835	165269538,6
41487	31937,28544	6752,667924	9549,71456	0,230186	91197048,18
54668	32311,4789	15808,44767	22356,5211	0,408951	499814035,6
		MÉDIA	4652,848	21%	9782,88

Fonte: O autor (2024)

Figura 9: Previsão gerada pelo método de suavização tripla



Fonte: O autor (2024)

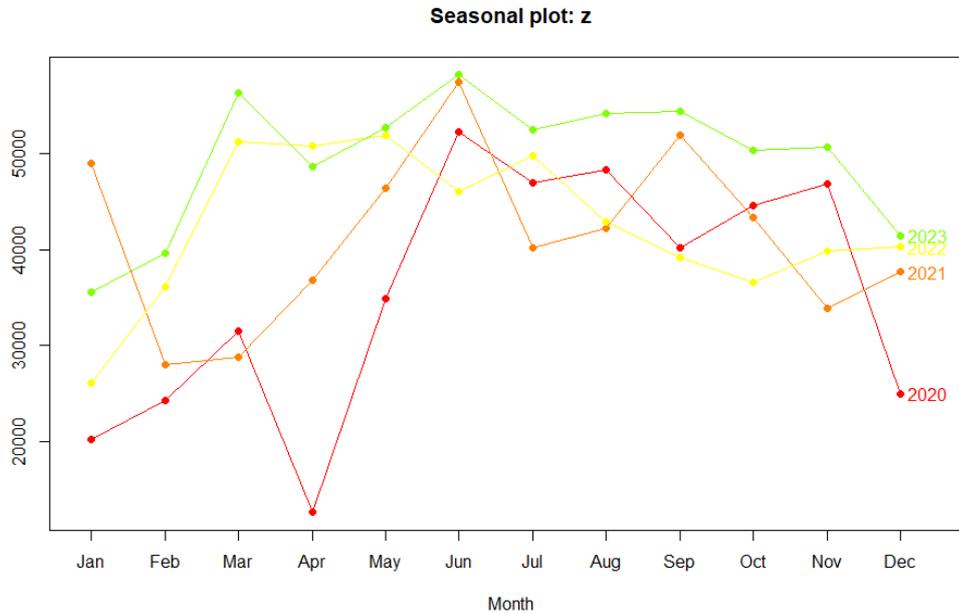
Ao observar o gráfico na figura 9, é possível notar como o método conseguiu capturar o comportamento sazonal da distribuição, apesar dos valores de faturamento e previsão não serem iguais, o que pode ser mais bem observado ao analisar os valores na tabela 7.

3.4.3 SARIMA

O modelo SARIMA, devido a sua complexidade, foi desenvolvido todo no software R. Foram utilizadas duas bibliotecas `forecast` e `lmtest`, sendo a `forecast` responsável por tratar de séries temporais e onde o pacote SARIMA se encontra e o `lmtest` que é utilizado para fazer testes de hipótese.

No primeiro passo, foi utilizada a função `seasonplot` para mostrar a Figura 7 que representa a sazonalidade de cada ano.

Figura 7: Sazonalidade

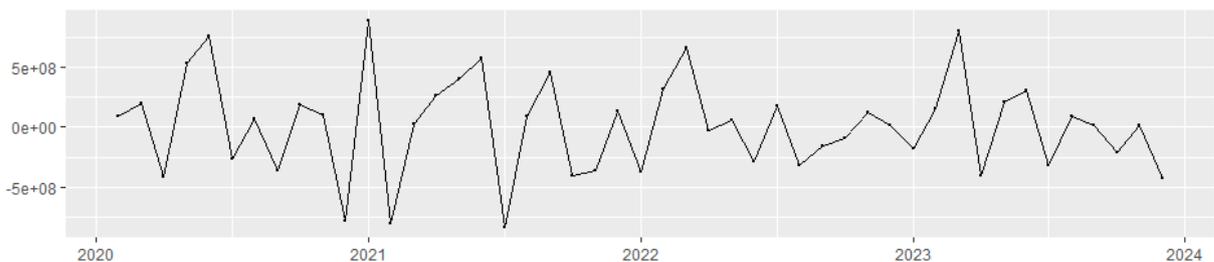


Fonte: O autor (2024)

Apesar dos pontos fora da curva nos meses de abril de 2020, janeiro de 2021 e setembro de 2021, pode-se observar que os anos se comportam de forma parecida, crescentes até o meio do ano e decrescentes no final.

Da mesma forma que seguindo o método de suavização exponencial, foi necessário fazer diferenciações no modelo, para o SARIMA a mesma etapa foi aplicada apenas com o incremento da função ndiffs que indicou a quantidade de diferenciações necessárias, nesse caso, apenas uma diferenciação, que gerou um gráfico sem sua componente de tendência, estacionalizando a distribuição, conforme mostrado na Figura 8.

Figura 8: Plotagem da distribuição diferenciada



Fonte: O autor (2024)

Na Figura 8 fica perceptível que a componente de tendência da curva foi retirada, o que indica uma média constante. Esse processo é necessário porque caso não seja realizada diferenciação não haveria a estabilização da variância.

A partir da nova curva, foi calculada a necessidade de fazer diferenciação sazonal, pelo código nsdiffs, porém não houve necessidade aparente.

Realizado todo o tratamento da base de dados, é ajustado o modelo SARIMA. Para isso, a série foi particionada em duas amostras, uma amostra de teste de tamanho 36, e uma amostra de 12 para validação, a escolha dessa divisão se deu pela necessidade de atribuição do maior volume de dados possível na amostra da validação, mas em ciclos sazonais fechados, como a distribuição apresenta ciclos de 12 meses a amostra de validação teve o tamanho de um ciclo sazonal. Essa etapa se faz necessária para validar o desempenho do modelo, visto que muitas vezes ele gera bons valores para a base de dados, mas não consegue projetar valores interessantes para o futuro. Inicialmente a função `auto.arima` foi aplicada para que os parâmetros fossem definidos automaticamente pelo software, porém os valores gerados não apresentaram boa acuracidade, então foi realizado o incremento dos parâmetros $SARIMA(p, q, d)(P, Q, D)[s]$ de forma manual, conforme modelo e resultados mostrados na Tabela 9.

Quadro 1: Modelo SARIMA e resultados

```
Series: z_ARIMAajuste
ARIMA(1,1,0)(1,1,1)[12]
Box Cox transformation: lambda= TRUE
Coefficients:
    ar1  sar1  sma1
-0.3591 -0.1664 -0.8735
s.e.  0.1980  0.6568  4.8188

sigma^2 = 135307087: log likelihood = -252.76
AIC=513.51 AICc=515.73 BIC=518.05

Training set error measures:
    ME  RMSE  MAE  MPE  MAPE  MASE  ACF1
-775.3238 8670.098 6063.054 -3.240125 15.63796 0.5829415 -0.06238132
```

Esses resultados representam o desempenho do ajuste SARIMA para a amostra de teste. A partir desse resultado, é realizada as previsões para os próximos meses. Para validar os coeficientes que foram escolhidos para o modelo, um teste de hipótese

z foi realizado e apresentou os resultados, conforme mostrado no Quadro 2.

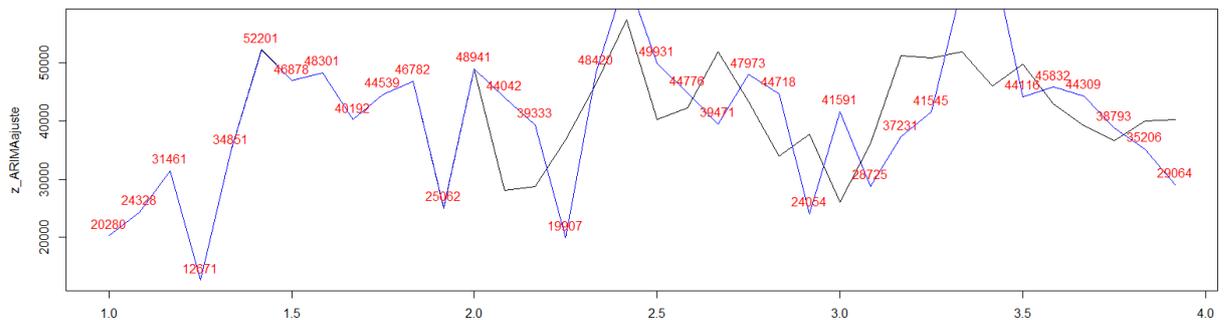
Quadro 2: Teste de hipótese

z test of coefficients:				
	Estimate	Std. Error	z value Pr(> z)	
ar1	-0.35915	0.19803	-1.8137	0.06973 .
sar1	-0.16643	0.65684	-0.2534	0.79998
sma1	-0.87353	4.81879	-0.1813	0.85615

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1				

Apesar de apenas o ar1 ter apresentado nível de significância adequado a um grau de 0,1 (10%), não foi possível encontrar nenhuma outra configuração nos parâmetros que apresentassem resultados melhores. Na Figura 9 pode-se observar a representação das previsões para a amostra de teste, na qual a linha azul representa o ajuste e a linha preta o faturado. Pode-se observar que no início da distribuição, não há diferença entre o ajuste e o faturado, porém no decorrer da série, os números se diferenciam. Apresentando comportamento semelhante, essa variação pode ser representada pelo MAE e MAPE descritos na Tabela 9.

Figura 9: Plotagem das previsões para amostra teste



Fonte: O autor (2024)

Tabela 9: Análise dos erros do ajuste da amostra teste

<i>RMSE</i>	<i>MAE</i>	<i>MAPE</i>
8670,098	6063,054	15,91318

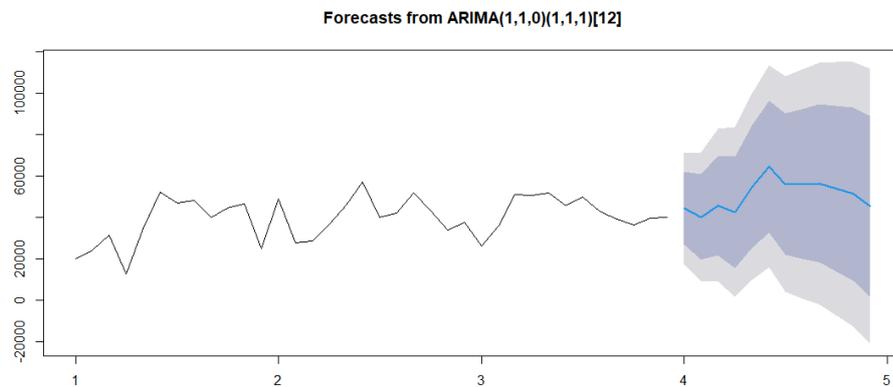
Fonte: O autor (2024)

O valor de RMSE de 8670,098 indica que em média, as previsões do modelo têm um erro quadrado de aproximadamente 8670 unidades em relação aos valores reais. Um MAE de 6063,054 indica que as previsões têm um desvio absoluto de aproximadamente 6063

unidades. Por fim, um MAPE de 15,91, indica que as previsões erram percentualmente em média 15,91% dos valores em relação ao realizado

Uma vez validado o modelo ajustado de teste, foi aplicado ao modelo de validação, para que sejam geradas e comparadas com o faturado. Pode-se observar as previsões, assim como a análise dos erros do modelo na Figura 10 e Tabelas 10 e 11.

Figura 10: Previsões geradas para os próximos 12 meses



Fonte: O autor (2024)

Na Figura 10 pode-se visualizar a projeção gerada, sendo a faixa azul mais escura, os limites a 0,05 graus de significância, e a faixa azul mais clara a 0,1 grau de significância. Portanto, apesar do valor previsto não se igualar ao faturado, é possível observar que ao considerar um grau de significância de 0,05, se o faturamento se encontra dentro desse intervalo, pode-se dizer que a previsão foi assertiva

Tabela 10: Previsões para h=12

	Validação	Previsões
1	35556	44445.47
2	39626	40300.53
3	56333	45959.84
4	48632	42635.36
5	52722	54956.02
6	58172	64734.42
7	52468	56210.18
8	54192	56175.40
9	54408	56562.38
10	50282	53960.28
11	50646	51358.56
12	41487	45384.29

Fonte: O autor (2024)

Tabela 11: Análise dos erros do modelo

RMSE	MAE	MAPE
5187,336	4241,528	8,6084

Fonte: O autor (2024)

O valor de RMSE de 5187,336 indica que em média, as previsões do modelo têm um erro quadrado de aproximadamente 5187 unidades em relação aos valores reais. Um MAE de 4241,528 indica que as previsões têm um desvio absoluto de aproximadamente 4241 unidades. Por fim, um MAPE de 8,6084, indica que as previsões erram percentualmente em média 8,6084% dos valores em relação ao realizado

3.4.4 Média móvel simples

Na Tabela 13, podemos observar a aplicação do modelo de médias móveis simples.

Tabela 12: Previsão gerada pela média móvel simples:

DATA	FATURAMENTO	PREVISÃO
2020	20292	
2020	24336	
2020	31473	22314
2020	12663	27904,5
2020	34865	22068
2020	52228	23764
2020	46896	43546,5
2020	48318	49562
2020	40200	47607
2020	44550	44259
2020	46794	42375
2020	25029	45672
2021	48936	35911,5
2021	28002	36982,5
2021	28798	38469
2021	36760	28400
2021	46380	32779
2021	57409	41570
2021	40200	51894,5
2021	42265	48804,5
2021	51888	41232,5
2021	43332	47076,5
2021	33886	47610
2021	37674	38609
2022	26068	35780
2022	36098	31871
2022	51242	31083
2022	50784	43670
2022	51904	51013
2022	46011	51344
2022	49716	48957,5

2022	42879	47863,5
2022	39126	46297,5
2022	36581	41002,5
2022	39906	37853,5
2022	40290	38243,5
2023	35556	40098
2023	39626	37923
2023	56333	37591
2023	48632	47979,5
2023	52722	52482,5
2023	58172	50677
2023	52468	55447
2023	54192	55320
2023	54408	53330
2023	50282	54300
2023	50646	52345
2023	41487	50464

Fonte: O autor (2024)

Por se tratar de um modelo simples, não houve necessidade de análises mais detalhadas. Para validar a qualidade do modelo, encontra-se na Tabela 13 os respectivos parâmetros de desempenho.

Tabela 14: Análise dos erros do modelo de previsão

MAE	MAPE	RMSE
702,7826	20%	95543542,33

Fonte: O autor (2024)

O valor de RMSE de 95543542,33 indica que em média, as previsões do modelo têm um erro quadrado de aproximadamente 95543542 unidades em relação aos valores reais. Um MAE de 702,7826 indica que as previsões têm um desvio absoluto de aproximadamente 702,7826 unidades. Por fim, um MAPE de 20, indica que as previsões erram percentualmente em média 20% dos valores em relação ao realizado

3.4.5 Escolha do modelo

Para avaliar o método que melhor se adequa ao caso apresentado, foram comparados os principais indicadores de erro de cada um deles, os resultados podem ser observados na Tabela 14.

Tabela 14: Desempenho dos modelos de previsão

	MAE	MAPE	RSME
Regressão Linear Simples	1,59E-12	21%	77210335,17
Suavização exponencial tripla	4652,848	21%	9782,88
SARIMA	4241,52	9%	5187,33
Média móvel simples	702,786	20%	95543542,33

Fonte: O autor (2024)

É considerado um bom modelo de previsão, quanto menor for suas medidas de erro, de forma comparativa, é possível notar que o modelo que apresentou o melhor desempenho foi o SARIMA, visto que nos indicadores de MAE, MAPE e RMSE ele apresentou as menores medidas, o que já era esperado que ele apresentasse bons resultados, visto que ele é pensado para lidar com sazonalidade e tendência de uma série temporal. Aplicando o modelo SARIMA para os meses de previsão dos meses de janeiro/24 e fevereiro/24, foi obtido o resultado apresentado na Tabela 15.

Tabela 16: Previsões geradas pelo modelo SARIMA

<i>FATURAMENTO</i>	<i>PREVISÃO</i>	<i>MAE</i>	<i>MAPE</i>	<i>RMSE</i>
54.668	49.404	5264,36	10%	27713486,21
69.066	46.725	22.341	32,34%	499.120.281

Fonte: O autor (2024)

3.5 Análise gerencial

A ideia de desenvolver métodos de previsão mais assertivos já era um tema em alta na empresa, principalmente entre os departamentos comerciais e o S&OP. Ao apresentar o trabalho para a gerência, além da proposta agora ser utilizada para embasar o desenvolvimento de previsões para o modelo de moto especificado, foi também levantada a necessidade de aprimoramento das formas com que as previsões são realizadas para os outros modelos de bateria. Atualmente a empresa utiliza uma planilha desenvolvida por uma consultoria externa que gera as previsões, mas por não haver suporte para ajustes, e o sistema ficar nas mãos do comercial, não há como realizar correções e análises mais profundas dos modelos de previsão por parte do S&OP.

Com esse trabalho, a gerência do S&OP viu que agora existe base para desenvolvimento dos próprios modelos que poderão ser confrontados com as previsões repassadas pelo comercial para que números melhores sejam desenvolvidos para criação do plano de produção.

4 CONCLUSÃO

No decorrer desse trabalho, foi realizada uma análise comparativa entre quatro métodos estatísticos que são amplamente utilizados no desenvolvimento de modelos de previsão baseados em séries temporais e correlação: Regressão Linear Simples, Suavização Exponencial Tripla, Média Móvel Autorregressiva Integrada Sazonal (SARIMA) e Média móvel Simples. O trabalho atendeu o principal objetivo, conseguiu analisar a curva de faturamento da amostra apresentada e com base na avaliação das medidas de erro de cada método estatístico proposto, conseguiu escolher a que obteve o melhor desempenho e gerou as previsões para o horizonte de dois meses proposto.

Cada método obteve desempenhos diferentes que a depender do cenário, podem apresentar o melhor resultado. Os modelos de Regressão Linear Simples e Média Móvel Simples, tiveram um desempenho semelhante. Ambos mostraram uma previsão sem viés sazonal e com uma tendência ascendente, evidenciando que em situações de poucas oscilações, podem ser métodos interessantes. O modelo de Suavização exponencial tripla foi importante ao tentar capturar tendências sazonais de curto prazo, em distribuições onde a sazonalidade seja mais definida, atribuindo importância as variáveis mais recentes, o modelo SARIMA se destacou quando avaliamos os comportamentos de forma sazonal considerando uma dependência temporal de valores passados nas previsões geradas.

É importante frisar que não existe um método perfeito para desenvolvimento de previsões. Os cenários do mundo corporativo, sempre dinâmicos, exigem atualizações constantes nas análises para representarem melhor a realidade do mercado. Por isso, a análise estatística dos erros serviu para definir, temporariamente, qual o melhor método para prever a demanda. De todos os métodos aplicados, o SARIMA apresentou os melhores resultados na análise dos erros, principalmente do MAPE. Considerando que esse seria o melhor critério para a escolha, o SARIMA seria a metodologia adequada para o momento.

Esse estudo contribui para a compreensão da aplicabilidade de métodos estatísticos no desenvolvimento de previsões para o mercado e que apesar da complexidade do negócio, métodos simples podem ser bastante úteis na busca de previsibilidade e estabilidade de posicionamento de mercado diante de um cenário dinâmico e competitivo.

REFERÊNCIAS

- ACKERMANN, A. E. F.; SELBITTO, M. A. Métodos de previsão de demanda: uma revisão da literatura. *Innovar*, Bogotá , v. 32, n. 85, p. 83-99, Sept. 2022 . Disponível em: http://www.scielo.org.co/scielo.php?script=sci_arttext&pid=S0121-50512022000300083&lng=en&nrm=iso. Acesso em: 02 Mar. 2024.
- ALVES, Custodio da Cunha et al. Aplicação de métodos estatísticos com suavização exponencial dupla e tripla para previsão de demanda na gestão de estoques. **Produção Online**, v. 17, n. 3, p. 1001-1026, 2019. Disponível em: <https://www.producaoonline.org.br/rpo/article/download/3539/1832>. Acesso em: 04 mar. 2024.
- AVENTURAS NA HISTÓRIA. Não vai dar em nada: invenções revolucionárias que foram desprezadas em seu tempo. **Aventuras na História**, 23 out. 2017. Disponível em: <https://aventurasnahistoria.uol.com.br/noticias/reportagem/nao-vai-dar-em-nada-invencoes-revolucionarias-que-foram-desprezadas-em-seu-tempo.phtml>. Acesso em: 02 mar. 2024.
- BAHRAMMIZADEE, A. A comparative survey of artificial intelligence applications in finance: artificial neural networks, expert system and hybrid intelligent systems. *Neural Comput; Applic* v. 19, p. 1165-1195. 2010.
- Bermudez, J. D.; Segura, J. V.; Vercher, E. A decision support system methodology for forecasting of time series based on soft computing. *Computational Statistics & Data Analysis*, v. 51, p.177-191, 2006.
- BONOTTO, Giulia. Previsão de demanda a partir de métodos quantitativos aplicada ao setor varejista. 2015. 102 f. Dissertação (Mestrado em Administração) - Universidade Federal do Rio Grande do Sul, Porto Alegre, RS, 2015.
- BOX, G. E. P. et al. *Time series analysis. Forecasting and control*. 5th ed. Hoboken, NJ: John Wiley & Sons, 2016. 712 p.
- CACHON, G.; TERWIESCH, C. *Operations Management: From Manufacturing to Services*. New York, NY: McGraw-Hill Education, 2017.
- COELHO, Leandro Callegari. Utilização de modelos de suavização exponencial para previsão de demanda com gráficos de controle combinados Shewhart-CUSUM. 2008. 112 f. Dissertação (Mestrado em Engenharia de Produção) - Universidade Federal de Santa Catarina, Florianópolis, SC, 2008.
- DE ARAÚJO, E. G. et al. Modelagem e previsão de modelos de séries temporais do consumo de energia elétrica na Região Nordeste do Brasil. *Sigmae*, v. 12, n. 1, p. 10-28, 2023.
- FORMIGONI CARVALHO WALTER, O. M.; HENNING, E.; MORO, G.; WAYNE SAMOBYL, R. Aplicação de um modelo SARIMA na previsão de vendas de motocicletas. *Exacta*, v. 11, n. 1, p. 77-88, 2013.
- GIL, A. C. *Como elaborar projetos de pesquisa*. 5. ed. São Paulo: Atlas, 2010.

HANKE, John L.; REITSCH, Arthur G.; WICHERN, Dean W. Business Forecasting. New Jersey: Prentice Hall, 2001.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). Frota de Veículos. [S.l.], s.d. Disponível em:

<https://cidades.ibge.gov.br/brasil/pesquisa/22/28120>. Acesso em: 03 de março de 2024.

LIMA, J. E. C.; CASTRO, L. F. de; CARTAXO, G. A. A. Aplicação do modelo sarima na previsão de demanda no setor calcadista/application of the sarima model in the forecast for demand in the footwear sector. REVISTA DE PSICOLOGIA, v. 13, n. 46.

MARTINS, E. G. M. Regressão linear simples. Rev. Ciência Elem., v. 7, n. 3, p. 45, 2019.

MINITAB. Augmented Dickey-Fuller Test. 2022. Disponível em:

<https://support.minitab.com/pt-br/minitab/21/help-and-how-to/statistical-modeling/time-series/how-to/augmented-dickey-fuller-test/methods-and-formulas/methods-and-formulas/>. Acesso em: 03 de março de 2024.

MONOLITONIMBUS. Tendência e Sazonalidade. Monolito Nimbus. Disponível em:

<https://www.monolitonimbus.com.br/tendencia-e-sazonalidade/>. Acesso em: 25/02/2024.

MONTGOMERY, D. C.; JENNINGS, C. L.; KULAHCI, M. Introduction to time series analysis and forecasting. [S.l.]: John Wiley & Sons, 2015.

MOREIRA, D. Administração da Produção e Operações. São Paulo: Pioneira Thomson Learning, 2001

MOREIRA, Daniel Augusto. Administração da produção e operações. 2. ed. rev. ampl. São Paulo: Cengage Learning, 2009.

REIS, Filipe Drummond; GOMES, Orlando Abreu; PARREIRAS, Fernando Silva. Métodos quantitativos de previsão de vendas: uma revisão sistemática da literatura. In: **XXXIV ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO**, Curitiba, PR, Brasil, 07 a 10 de outubro de 2014. Anais... Curitiba: ABEPRO, 2014. p. 1-16.

REIS, Filipe Drummond; GOMES, Orlando Abreu; PARREIRAS, Fernando Silva. Métodos Quantitativos de Previsão de Vendas: uma revisão sistemática da literatura. **Revista de Estudos em Engenharia e Gestão**, Curitiba, v. 2, p. 2, out. 2014.

SHUMWAY, R.; STOFFER, D. Time series analysis using the R Statistical Package. [S.l.]: free dog publishing, 2017.

SILVA, A. G. et al. Análise do Valor-p Determinado pela Estatística τ na Aplicação do Teste de Dickey-Fuller Aumentado. Trends in Computational and Applied Mathematics, v. 23, n. 2, p. 283–298, 2022. Disponível em <https://doi.org/10.5540/tcam.2022.023.02.00283>. Acesso em: 05 mar.2024.

WALLACE, T. F. Planejamento de vendas e operações: guia prático. 3º edição. São Paulo: IMAM, 2012.

ZAN, G. L.; SELLITTO, M. A. Técnicas de previsão de demanda: um estudo de caso triplo com dados de venda de materiais eletro-mecânicos. Revista Gestão da Produção Operações e Sistemas, [S. l.], n. 3, p. Pag. 95, 2007. DOI: 10.15675/gepros.v0i3.171. Disponível em: <https://revista.feb.unesp.br/gepros/article/view/171>. Acesso em: 8 mar. 2024.

APÊNDICE A - CÓDIGO UTILIZADO PARA REALIZAR OS TESTES DE SAZONALIDADE

```
library(forecast)
library(lmtest)
library(tseries)
install.packages('coin')
library(coin)
# Criar o dataframe com os dados fornecidos
dados <- data.frame(
  DATA = rep(c(2020, 2021, 2022, 2023), each = 12),
  FATURAMENTO = c(
    20292, 24336, 31473, 12663, 34865, 52228, 46896, 48318, 40200, 44550, 46794, 25029,
    48936, 28002, 28798, 36760, 46380, 57409, 40200, 42265, 51888, 43332, 33886, 37674,
    26068, 36098, 51242, 50784, 51904, 46011, 49716, 42879, 39126, 36581, 39906, 40290,
    35556, 39626, 56333, 48632, 52722, 58172, 52468, 54192, 54408, 50282, 50646, 41487
  ),
  Mes = rep(c(
    "janeiro", "fevereiro", "março", "abril", "maio", "junho",
    "julho", "agosto", "setembro", "outubro", "novembro", "dezembro"
  ), times = 4)
)
# Aplicar o teste ADF para testar a estacionaridade
adf_test_result <- adf.test(dados$FATURAMENTO)

# Imprimir o resultado do teste ADF
cat("Resultado do Teste ADF:\n")
print(adf_test_result)

# Converta a variável DATA para fator
dados$DATA <- as.factor(dados$DATA)

# Aplicar o teste de Kruskal-Wallis
kruskal_test_result <- kruskal.test(FATURAMENTO ~ DATA, data = dados)
# Carregue as bibliotecas necessárias
library(ggplot2)

# Converta a variável DATA para fator
dados$DATA <- as.factor(dados$DATA)

# Aplicar a análise de decomposição sazonal
decomposicao <- decompose(ts(dados$FATURAMENTO, frequency = 12))

# Plotar os componentes da decomposição
par(mfrow = c(4,1))
plot(decomposicao)

# Imprimir o resultado do teste de Kruskal-Wallis
cat("\nResultado do Teste de Kruskal-Wallis:\n")
print(kruskal_test_result)
```

APÊNDICE B - CÓDIGO UTILIZADO PARA AJUSTAR MODELO SARIMA

```
#SARIMA
# Carregamento dos pacotes
library(data.table)
library(xts)
library(forecast)

# Dados
dados <- fread("DATA;FATURAMENTO
01/01/2020;20292
01/02/2020;24336
01/03/2020;31473
01/04/2020;12663
01/05/2020;34865
01/06/2020;52228
01/10/2020;44550
01/11/2020;46794
01/12/2020;25029
01/01/2021;48936
01/02/2021;28002
01/03/2021;28798
01/04/2021;36760
01/05/2021;46380
01/06/2021;57409
01/07/2021;40200
01/08/2021;42265
01/09/2021;51888
01/10/2021;43332
01/11/2021;33886
01/12/2021;37674
01/01/2022;26068
01/02/2022;36098
01/03/2022;51242
01/04/2022;50784
01/05/2022;51904
01/06/2022;46011
01/07/2022;49716
01/08/2022;42879
01/09/2022;39126
01/10/2022;36581
01/11/2022;39906
01/12/2022;40290
01/01/2023;35556
01/02/2023;39626
01/03/2023;56333
01/04/2023;48632
01/05/2023;52722
01/06/2023;58172
01/07/2023;52468
```

```

01/08/2023;54192
01/09/2023;54408
01/10/2023;50282
01/11/2023;50646
01/12/2023;41487", sep = ";")

# Conversão da coluna DATA para formato de data
dados$DATA <- as.Date(dados$DATA, format = "%d/%m/%Y")

# Criação de um objeto de série temporal
serie_temporal <- xts(dados$FATURAMENTO, order.by = dados$DATA)

# Identificação da ordem ARIMA e da ordem sazonal usando auto.arima
modelo_arima <- auto.arima(serie_temporal)

# Fazendo previsões para os próximos 3 meses de 2024
previsao_sarima <- forecast(modelo_arima, h = 3)

# Imprimindo as previsões
print(previsao_sarima)

# Plot das previsões
plot(previsao_sarima, main = "Previsões usando SARIMA")

# ... (código anterior)

# Valores reais para os 3 primeiros meses de 2024
valores_reais <- c(47000, 43000, 43200)

# Avaliação do modelo
accuracy_sarima <- accuracy(previsao_sarima)
mape_sarima <- accuracy_sarima[, "MAPE"]
rmse_sarima <- sqrt(mean((previsao_sarima$mean - valores_reais)^2))

# Impressão de métricas
cat("Erro Médio Absoluto (MAE):", accuracy_sarima[, "MAE"], "\n")
cat("Erro Médio Percentual Absoluto (MAPE):", mape_sarima, "\n")
cat("Raiz do Erro Quadrático Médio (RMSE):", rmse_sarima, "\n")

# Gráfico de Resíduos
plot(residuals(modelo_arima), main = "Gráfico de Resíduos")

# Comparação Gráfica
plot(serie_temporal, main = "Comparação entre Dados Reais e Previsões (SARIMA)", col =
"blue", lwd = 2)
lines(previsao_sarima$mean, col = "red", lwd = 2)
points(x = index(previsao_sarima$mean), y = valores_reais, col = "green", pch = 16)
legend("topright", legend = c("Real", "Previsão SARIMA", "Valores Reais"), col = c("blue", "red",
"green"), lwd = 2)

```

Apêndice C: CÓDIGO UTILIZADO PARA PREVER O HORIZONETE DE PLANEJAMENTO PELO MODELO SARIMA

```

# Carregamento de Bibliotecas
library(forecast)
library(lmtest)

# Criação do DataFrame com Dados Fornecidos
dados <- data.frame(
  DATA = rep(c(2020, 2021, 2022, 2023, 2024), each = 12),
  FATURAMENTO = c(
    20292, 24336, 31473, 12663, 34865, 52228, 46896, 48318, 40200, 44550, 46794, 25029,
    48936, 28002, 28798, 36760, 46380, 57409, 40200, 42265, 51888, 43332, 33886, 37674,
    26068, 36098, 51242, 50784, 51904, 46011, 49716, 42879, 39126, 36581, 39906, 40290,
    35556, 39626, 56333, 48632, 52722, 58172, 52468, 54192, 54408, 50282, 50646, 41487, 0,
    0,0,0,0,0,0,0,0,0,0
  ),
  Mes = rep(c(
    "janeiro", "fevereiro", "março", "abril", "maio", "junho",
    "julho", "agosto", "setembro", "outubro", "novembro", "dezembro"
  ), times = 5)
)

# Ordenação dos Dados pelo Ano e Mês
dados <- dados[order(dados$DATA, match(dados$Mes, c("janeiro", "fevereiro", "março", "abril",
"maio", "junho", "julho", "agosto", "setembro", "outubro", "novembro", "dezembro"))), ]

# Criação da Série Temporal
ts_dados <- ts(dados$FATURAMENTO, start = c(2020, 1), frequency = 12)

# Visualização Gráfica da Série Temporal
print(ts_dados)

# Conversão da Série Temporal para Vetor
vetor <- as.numeric(ts_dados)
z <- ts(vetor, frequency = 12, start = c(2020,1))

# Visualização Gráfica da Série Temporal
ts.plot(z)

# Gráfico de Sazonalidade
seasonplot(z, col = rainbow(12), year.labels = TRUE, type = "o", pch = 16)

# Determinação da Ordem de Diferenciação Não Sazonal
ndiffs(z_bc)

# Aplicação da Diferenciação Não Sazonal

```

```

z_diff <- diff(z_bc, 1)

# Análise Gráfica da Série Temporal Diferenciada Não Sazonal
ggtsdisplay(z_diff)

# Determinação da Ordem de Diferenciação Sazonal
nsdiffs(z_diff)

# Ajuste do Modelo ARIMA com Dados de Treinamento
z_ARIMAajuste <- ts(z[1:36], frequency = 12)
z_ARIMAVALIDA <- ts(z[37:60], frequency = 12)
fit <- Arima(y = z_ARIMAajuste, order = c(1, 1, 0), seasonal = list(order = c(1, 1, 1), period = 12),
lambda = TRUE)

# Resumo Estatístico do Modelo Ajustado
summary(fit)

# Teste de Hipóteses nos Coeficientes do Modelo
coefstest(fit)

# Plotagem dos Dados Observados e Ajustados
plot(z_ARIMAajuste)
lines(fit$fitted, col = 'red')
text(time(z_ARIMAajuste), fit$fitted, labels = round(fit$fitted), pos = 3, col = "red", offset = 0.5)
# Avaliação da Precisão do Modelo
accuracy(z_ARIMAajuste, fit$fitted)

# Realização de Previsões para os Próximos 12 Meses
predi <- forecast(fit, h = 24)
plot(predi)

# Comparação das Previsões com os Dados de Validação
plot(as.numeric(z_ARIMAVALIDA), type = 'l')
lines(as.numeric(predi$mean), col = 'blue')

# Criar tabela com dados de validação e previsões
tabela_previsoes <- data.frame(Validacao = as.numeric(z_ARIMAVALIDA), Previsoes =
as.numeric(predi$mean))
print(tabela_previsoes)

# Avaliação da Precisão das Previsões
accuracy(as.numeric(z_ARIMAVALIDA), as.numeric(predi$mean))

```