

**UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ
COORDENAÇÃO DE ENGENHARIA DE PRODUÇÃO
CURSO DE ENGENHARIA DE PRODUÇÃO**

BRUNA KASTNER OLIVI FINKLER

GERSON LOURENÇO JUNIOR

**APLICAÇÃO DE MÉTODOS DE PREVISÃO DE DEMANDA EM UMA
EMPRESA DE SERVIÇOS AUTOMOTIVOS NO PARANÁ**

TRABALHO DE CONCLUSÃO DE CURSO

MEDIANEIRA

2019

BRUNA KASTNER OLIVI FINKLER

GERSON LOURENÇO JUNIOR

**APLICAÇÃO DE MÉTODOS DE PREVISÃO DE DEMANDA EM UMA
EMPRESA DE SERVIÇOS AUTOMOTIVOS NO PARANÁ**

Trabalho de conclusão de curso apresentado ao Curso de Graduação, em Engenharia de Produção, da Universidade Tecnológica Federal do Paraná – UTFPR, Campus Medianeira, como requisito parcial à obtenção do título de Bacharel em Engenharia de Produção.

Orientador(a): Prof. Me. Peterson Diego Kunh
Coorientador: Prof. Dr. Jairo Marlon Correa

MEDIANEIRA

2019



TERMO DE APROVAÇÃO

APLICAÇÃO DE MÉTODOS DE PREVISÃO DE DEMANDA EM UMA EMPRESA DE SERVIÇOS AUTOMOTIVOS NO PARANÁ

Por

BRUNA KASTNER OLIVI FINKLER

GERSON LOURENÇO JUNIOR

Este trabalho de conclusão de curso foi apresentado às 15:50h do dia 17 de junho de 2019 como requisito parcial a obtenção do título de Bacharel em Engenharia de Produção, da Universidade Tecnológica Federal do Paraná, Campus Medianeira. Os candidatos foram arguidos pela Banca Examinadora composta pelos professores abaixo assinados. Após deliberação, a Banca Examinadora considerou o trabalho de diplomação aprovado.

Prof. Me. Peterson Diego Kunh (Orientador)
Universidade Tecnológica Federal do Paraná

Prof. Dr. Jairo Marlon Correa (Coorientador)
Universidade Tecnológica Federal do Paraná

Prof. Dr Diego Venâncio Thomaz
Universidade Tecnológica Federal do Paraná

Prof^a. Me Carine Cristiane Machado Urbim Pasa
Universidade Tecnológica Federal do Paraná

AGRADECIMENTOS

Ao Prof. Me. Orientador Peterson e ao Prof Dr. Coorientador Jairo, pela ajuda em todas as etapas deste trabalho.

A minha família, pela confiança e motivação.

Aos amigos, pela força e pela vibração desde o início desta jornada.

Aos profissionais entrevistados, pela concessão de informações valiosas para a realização deste estudo.

A todos que, com boa intenção, colaboraram para a realização e finalização deste trabalho.

"A persistência é o menor caminho do êxito".

(Charles Chaplin)

RESUMO

FINKLER, Bruna Kastner Olivi; LOURENÇO JUNIOR, Gerson. **Aplicação de métodos de previsão de demanda em uma empresa de serviços automotivos no Paraná.** 2019. 54 f. Monografia (Bacharel em Engenharia de Produção) - Universidade Tecnológica Federal do Paraná.

A busca pela redução de custos e o aumento da competitividade vem sendo um grande desafio no âmbito empresarial. Sendo assim, a capacidade de prever dados futuros torna-se uma ferramenta de grande importância dentro de uma empresa. Para a elaboração deste trabalho, a empresa foi dividida entre os setores de condicionadores de ar e de radiadores. A partir disto, foram selecionados os três produtos mais vendidos nos últimos quatro anos, resultando em seis séries de dados. Com isto, foi feito um comparativo entre os métodos de previsão de demanda: Médias móveis, Holt-Winters e ARMA. Para três dos seis produtos, sendo eles compressor, evaporador e aditivo, o modelo que apresentou o menor erro no ajuste foi o de Médias móveis, já para os demais produtos, que são condensador e caixa plástica, o modelo com o melhor ajuste foi o ARMA.

Palavras-chave: Planejamento; Modelos de previsão; Séries temporais.

ABSTRACT

FINKLER, Bruna Kastner Olivi; LOURENÇO JUNIOR, Gerson. **Application of methods of forecast of demand in a company of automotive services of Paraná.** 2019. 54 f. Monografia (Bacharel em Engenharia de Produção) - Universidade Tecnológica Federal do Paraná.

The pursuit of cost reduction and increased competitiveness has been a major challenge at the corporate level. Thus, the ability to forecast future data becomes a tool of great importance within a company. For the elaboration of this work, the company was divided between the sectors of air conditioners and radiators. From this, the three best-selling products in the last four years were selected, resulting in six data series. With this, a comparison was made between the methods of forecasting demand: Moving averages, Holt-Winters and ARMA. For three of the six products, being compressor, evaporator and additive, the model that presented the smallest error in the adjustment was the Moving averages, for the other products, which are condenser, radiator and plastic box, the model with the best fit was the ARMA.

Key-words: Planning; Forecasting models; Time series.

LISTA DE FIGURAS

| | |
|--|----|
| Figura 1 – Fluxo financeiro, de informações e de produto em uma cadeia de suprimentos..... | 13 |
| Figura 2 - Métodos de previsão de demanda..... | 17 |
| Figura 3 - Etapas para a construção de um modelo ARIMA | 27 |
| Figura 4 - Classificação das Pesquisas..... | 29 |
| Figura 5 - Gráfico de linha das vendas no setor de condicionadores de ar..... | 36 |
| Figura 6 - Gráfico de linha das vendas no setor de radiadores | 36 |
| Figura 7 - Gráfico da demanda real e prevista para compressores..... | 38 |
| Figura 8 - Gráfico da demanda real e prevista para condensadores..... | 40 |
| Figura 9 - Gráfico da demanda real e prevista para evaporadores | 42 |
| Figura 10 - Gráfico da demanda real e prevista para aditivo..... | 44 |
| Figura 11 - Gráfico da demanda real e prevista para caixa plástica..... | 46 |
| Figura 12 - Gráfico da demanda real e prevista para aditivo..... | 48 |

LISTA DE QUADROS E TABELAS

| | |
|--|----|
| Quadro 1 - Comportamentos associados com uma série temporal..... | 19 |
| Quadro 2 - Equações comparativas entre o modelo aditivo e multiplicativo de Holt-Winters | 23 |
| Quadro 3 - Modelos usados para o cálculo de previsão da demanda..... | 37 |
| Quadro 4 - Erros calculados..... | 38 |
| Quadro 5 - Erros calculados..... | 40 |
| Quadro 6 - Cálculo dos erros | 42 |
| Quadro 7 - Cálculo dos erros das previsões da demanda de aditivo | 44 |
| Quadro 8 - Cálculo dos erros das previsões da demanda de caixa plástica | 46 |
| Quadro 9 - Cálculo dos erros das previsões da demanda de radiador | 48 |
| Tabela 1 - Vendas de Compressores por mês | 33 |
| Tabela 2 - Vendas de Condensadores por mês | 33 |
| Tabela 3 - Vendas de Evaporadores por mês | 34 |
| Tabela 4 - Vendas de aditivo..... | 34 |
| Tabela 5 - Vendas de caixa plástica..... | 35 |
| Tabela 6 - Vendas de radiador | 35 |
| Tabela 7 - Demanda real e prevista | 38 |
| Tabela 8 - Variáveis e coeficientes do modelo ARMA..... | 39 |
| Tabela 9 - Demanda real e prevista | 40 |
| Tabela 10 - Demanda real e prevista | 42 |
| Tabela 11 - Demanda real e prevista de aditivo | 44 |
| Tabela 12 - Demanda real e prevista para caixa plástica..... | 45 |
| Tabela 13 - Variáveis e coeficientes do modelo ARMA para caixa plástica | 46 |
| Tabela 14 - Demanda real e prevista para radiador | 47 |

SUMÁRIO

| | |
|---|-----------|
| 1 INTRODUÇÃO | 10 |
| 2 OBJETIVOS | 12 |
| 2.1 OBJETIVO GERAL | 12 |
| 2.2 OBJETIVOS ESPECÍFICOS | 12 |
| 3 FUNDAMENTAÇÃO TEÓRICA | 13 |
| 3.1 CADEIA DE SUPRIMENTOS | 13 |
| 3.2 PLANEJAMENTO E CONTROLE DA PRODUÇÃO | 14 |
| 3.3 PREVISÃO DE DEMANDA | 15 |
| 3.3.1 Modelos de Previsão | 15 |
| 3.3.1.1 Métodos Qualitativos | 157 |
| 3.3.1.2 Métodos Quantitativos | 158 |
| 3.4 SÉRIES TEMPORAIS | 18 |
| 3.4.1 Análise de erros | 18 |
| 3.5 MEDIA MÓVEL SIMPLES | 20 |
| 3.6 MEDIA MÓVEL PONDERADA | 21 |
| 3.7 MODELO DE HOLT-WINTERS | 22 |
| 3.8 MODELO BOX-JENKINS | 24 |
| 3.8.1 Modelo Autorregressivo (AR) e Modelo de Média Móvel (MA) | 244 |
| 3.8.2 Modelo ARIMA | 24 |
| 3.8.3 Metodologia de Box-Jenkins para a construção de Modelos ARIMA | 24 |
| 4 PROCEDIMENTOS METODOLÓGICOS | 28 |
| 4.1 CARACTERIZAÇÃO DA EMPRESA | 28 |
| 4.2 CLASSIFICAÇÃO DA PESQUISA | 28 |
| 4.3 ETAPAS DA PESQUISA | 30 |
| 4.3.1 Visita Técnica | 30 |
| 4.3.2 Revisão Bibliográfica | 30 |
| 4.3.3 Coleta de Dados | 30 |
| 4.3.4 Análise dos Resultados | 30 |
| 5 RESULTADOS E DISCUSSÃO | 32 |
| 5.1 SETOR DE CONDICIONADORES DE AR | 37 |
| 5.1.1 Modelos de Previsão de demanda de Compressores | 37 |
| 5.1.2 Modelos de Previsão de demanda de Condensadores | 37 |
| 5.1.3 Modelos de Previsão de demanda de Evaporadores | 37 |
| 5.2 SETOR DE RADIADORES | 43 |
| 5.1.3 Modelos de Previsão de demanda de Aditivo | 37 |
| 5.1.3 Modelos de Previsão de demanda de Caixa Plástica | 37 |
| 5.1.3 Modelos de Previsão de demanda de Radiador | 37 |
| 6 CONSIDERAÇÕES FINAIS | 50 |
| REFERÊNCIAS | 511 |

1 INTRODUÇÃO

A competição nos mercados globais vem aumentando cada vez mais. Na atualidade, a feroz competição nos mercados globais, o aparecimento de produtos com ciclos de vida curtos e as maiores expectativas dos clientes forçam as empresas do setor de produção a investir e concentrar esforços nas cadeias de suprimentos (SIMCHI-LEVI; KAMINSKY; SIMCHI-LEVI, 2010). Com esse cenário, cresce a motivação em relação à evolução constante da cadeia de suprimentos e de técnicas diferentes para a sua gestão eficiente.

Em um ambiente cada vez mais competitivo, é preciso que as empresas mantenham uma estratégia visando a redução de riscos, melhoria dos processos e a tomada de decisões. Assim sendo, a capacidade de prever dados futuros se torna uma ferramenta de suma importância dentro da organização. Para Fernandes e Godinho Filho (2010) as previsões desempenham um papel fundamental no ambiente competitivo, levando a empresa para o planejamento estratégico da produção, finanças e vendas.

De acordo com Moreira (2008), planejar é algo normal em qualquer organização, e faz parte do cotidiano das empresas seja qual for o seu segmento. Deste modo, se faz necessário saber algumas questões básicas do andamento da empresa e de sua expectativa futura. Para conseguir uma evolução na cadeia de suprimentos e melhorar sua gestão é preciso realizar o planejamento e controle da produção. Com isso, a capacidade de prever uma demanda em uma organização é um fator de extrema importância, pois fortalece sua vantagem competitiva, ajudando a empresa a quantificar e alocar somente os recursos necessários para compra, transporte, movimentação e armazenagem dos produtos, reduzindo os custos e consequentemente maximizar os lucros.

Segundo Moreira (2008), a previsão de demanda é um processo lógico que busca informações sobre o valor das vendas futuras de um produto ou de um conjunto de produtos. Quando possível, a previsão deve fornecer também informações sobre a qualidade e a localização (caso necessário, lugar onde se tem maior índice de demanda) dos produtos no futuro.

Vários são os métodos de previsão disponíveis e cada um possui uma classificação diferenciada. Estes métodos são estudados pela empresa e a partir disso é escolhida a metodologia apropriada. Neste trabalho será realizado o estudo e análise de previsão de demanda de radiadores, condicionadores de ar e seus respectivos acessórios, com utilização dos métodos quantitativos, visando selecionar um modelo de previsão de demanda que auxilie a empresa no seu planejamento e nas decisões que serão tomadas pelo gestor.

2 OBJETIVOS

2.1 OBJETIVO GERAL

Realizar a previsão de demanda com base no histórico de vendas da empresa.

2.2 OBJETIVOS ESPECÍFICOS

- a) Obter e analisar os dados históricos de demanda;
- b) Levantar os métodos de previsão de demanda que podem ser aplicados;
- c) Comparar os resultados entre os modelos de previsão, identificando o melhor método de previsão para cada série de dados;
- d) Testar e apresentar as previsões de consumo.

3 FUNDAMENTAÇÃO TEÓRICA

3.1 CADEIA DE SUPRIMENTOS

O conceito de uma cadeia de suprimentos é um conjunto de relacionamento entre fornecedor, indústria, distribuição, varejo e consumidor. Esse conjunto conta com um fluxo de financeiro e de produto que vai do fornecedor até o consumidor, e no sentido contrário a esse fluxo, voltam as informações de elo em elo, a Figura 1 representa esse conjunto.



Figura 1 – Fluxo financeiro, de informações e de produto em uma cadeia de suprimentos

Fonte: Adolfo Neto (2016)

É crucial um bom gerenciamento desses elos e desses fluxos dentro de uma cadeia de suprimentos, isso gera um aperfeiçoamento nos seus métodos de trabalho e busca processos mais eficientes e produtivos, aumentando seus resultados. Vivaldini e Pires (2010) definem uma Cadeia de suprimentos como sendo os processos envolvendo fornecedores-clientes ligando empresas desde a fonte inicial de matéria prima até o ponto de consumo do produto acabado.

Por sua vez, Ballou (2006) define a Logística/Cadeia de suprimentos como um conjunto de atividades funcionais (transportes, controle de estoques, etc.) que se repetem inúmeras vezes ao longo do canal pelo qual matérias primas vão sendo convertidas em produtos acabados, aos quais se agrega valor ao consumidor.

Já Chopra e Meindl (2011), explica que uma cadeia de suprimentos consiste em todas as partes envolvidas, direta ou indiretamente, na realização do pedido de um cliente. Ela inclui não apenas o fabricante e os fornecedores, mas também transportadoras, armazéns, varejistas e até mesmo os próprios clientes.

Simchi-levi, Kaminsky e Simchi-levi (2010, p 33) definem uma cadeia de suprimentos da seguinte forma:

A gestão da Cadeia de suprimentos é um conjunto de abordagens que integra, com eficiência, fornecedores, fabricantes, depósitos e pontos comerciais, de forma que a mercadoria é produzida e distribuída nas quantidades corretas, aos pontos de entregas e nos prazos corretos, com o objetivo de minimizar os custos totais do sistema sem deixar de atender as exigências em termos de nível de serviço.

Produtos e serviços não têm valor a menos que estejam em poder dos clientes quando (tempo) e onde (lugar) pretendem consumi-los. (BALLOU, 2006). Por isso, Chopra e Meindl (2011) afirma que, objetivo de cada cadeia de suprimentos deve ser maximizar o valor geral gerado. O valor que uma cadeia de suprimentos gera pode ser definido como a diferença entre o que o produto final vale para o cliente e os custos que incorrem a ela ao atender à solicitação do cliente.

Portanto, é de uma suma importância o entendimento desses conceitos dentro da empresa estudada, uma vez que ela terá uma noção de quantos pedidos haverá nos próximos meses, evitando recursos desnecessários e agregando um maior lucro.

3.2 PLANEJAMENTO E CONTROLE DA PRODUÇÃO

Com as definições de cadeia de suprimentos, deve-se entender a importância de um bom planejamento e controle da mesma. Só a partir disso é possível alcançar os resultados desejados.

O bom planejamento é um ponto essencial dentro da gestão de uma empresa. Planejar é entender como a consideração conjunta da situação presente e da visão de futuro influencia as decisões tomadas no presente para que se atinjam determinados objetivos no futuro (CORREA, GIANESI, CAON, 2001 apud CORREA, 2012).

Para Lustosa et al. (2008), do ponto de vista do planejamento e controle da produção, as previsões de demanda são utilizadas nas decisões referentes ao planejamento de recursos da produção (planejamento da capacidade), às metas de produção e estoques (planejamento agregado da produção) e às prioridades de produção e expedição de produtos (programação e controle da produção).

Segundo Lustosa et al. (2008), a capacidade projetada de uma planta industrial é sua capacidade máxima sob condições ideais de operação. O planejamento agregado é um processo pelo qual uma empresa determina os níveis ideais de capacidade, produção, subcontratação, estoque, falta de estoque e até mesmo preços, por um horizonte de tempo especificado. Já Chopra e Meindl (2011) explica que o objetivo do planejamento agregado é satisfazer a demanda enquanto maximiza o lucro.

De acordo com Slack, Chambers e Johnston (2009) o planejamento e controle da produção gerenciam atividades de operação produtiva, de forma a satisfazer a contínua demanda de seus clientes. Para Ballou (2006), o planejamento e controle das atividades da cadeia de suprimentos/logística dependem de estimativas acuradas dos volumes de produtos e serviços a serem processados pela cadeia de suprimentos. Tais estimativas ocorrem tipicamente na forma de planejamentos e previsões.

Moreira (2008), afirma que para todo planejamento, a base comum é a previsão de demanda. Através das análises de previsão de demanda, a empresa deve colocar como objetivo aonde quer chegar, por meio de metas. A partir do momento em que se houve a previsão de demanda, podem-se planejar as vendas futuras, este é o ponto de partida para estimar o potencial de mercado.

3.3 PREVISÃO DE DEMANDA

Tendo em vista essa necessidade de uma boa gestão da cadeia de suprimentos para satisfazer as necessidades atuais, vale ressaltar Chopra e Meindl (2011): As previsões de demanda formam a base de todo o planejamento da cadeia de suprimentos.

Entende-se por demanda a disposição dos clientes ao consumo de bens e serviços ofertados por uma organização. Essa demanda é influenciada por uma série de fatores que se estendem desde as condições macroeconômicas até questões operacionais como a disponibilidade do produto e preço no ponto de venda (LUSTOSA et al., 2008).

Segundo Lustosa et al. (2008), a previsão de demanda assume um papel central no processo de planejamento da empresa de manufatura. Com base nessa informação são tomadas as principais decisões financeiras, comerciais e operacionais. Dessa forma, a capacidade de prever terá impacto direto no resultado econômico da empresa.

Previsões são necessárias para suportar o processo decisório em operações. Como diferentes decisões tem inercias decisórias diferentes, previsões de diferentes horizontes são necessárias para um adequado suporte a decisão (CORREA; CORREA, 2012).

De acordo com Chopra e Meindl (2011, p 191):

A técnica básica é dividida em seis etapas, mostradas a seguir, que ajudam a organização a realizar uma previsão eficaz:

I. Entender o objetivo da previsão.

II. Integrar o planejamento da demanda e a previsão por toda a cadeia de suprimentos.

III. Entender e identificar os segmentos de clientes.

IV. Identificar os principais fatores que influenciam a previsão da demanda.

V. Determinar a técnica de previsão apropriada.

VI. Estabelecer medidas de desempenho e erro para a previsão.

É fato conhecido que as previsões de demanda incluem uma margem de erro e que a incerteza das previsões é tanto maior quanto maior o horizonte de planejamento, ou seja, as previsões de venda dos próximos meses são mais confiáveis que aquelas de um ano adiante (LUSTOSA et al., 2008).

3.3.1 Modelos de Previsão

Os métodos de previsão têm como objetivo prever a demanda de vendas de maneira mais correta possível, refletindo uma estimativa precisa.

Slack, Chambers e Johnston (2009, p 175) explicam as abordagens principais para a previsão:

Existem duas abordagens principais para a previsão. Os gerentes algumas vezes usam métodos qualitativos baseados em opiniões, experiência passada, mesmo boas adivinhações. Existe, também, a gama de técnicas quantitativas de previsão disponíveis para ajudar os gerentes a avaliar tendências e relacionamentos causais e fazer previsões sobre o futuro.

A Figura 2 apresenta alguns desses métodos de previsão de demanda.

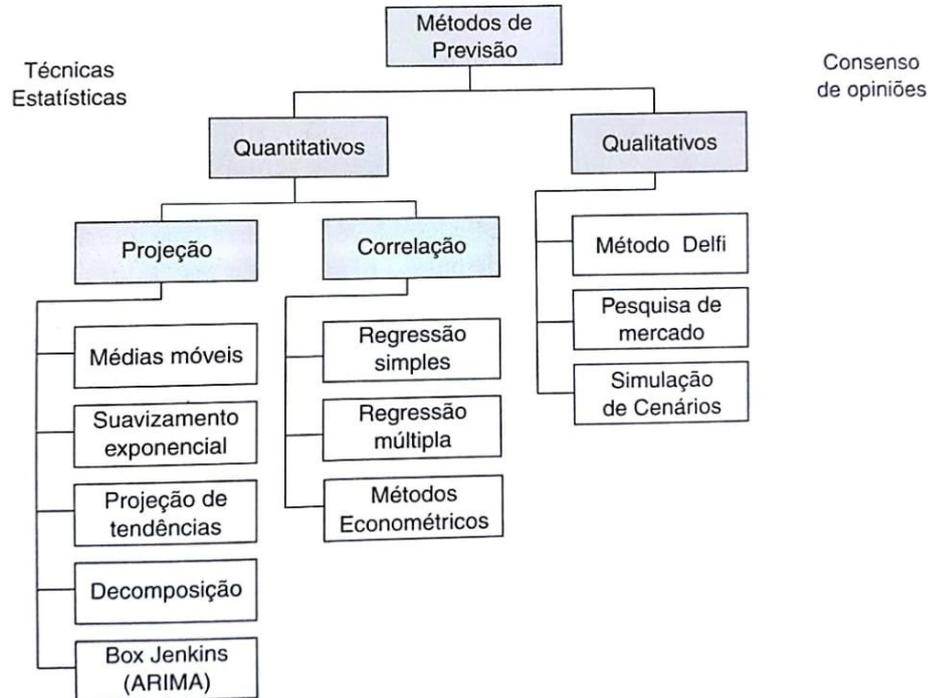


Figura 2 - Métodos de previsão de demanda
Fonte: Lustosa et al. (2008).

Alguns dos métodos de previsão quantitativos apresentados na Figura 3 serão detalhados a seguir.

3.4.1.1 Métodos Qualitativos

Ballou (2006) define métodos qualitativos como sendo aqueles que recorrem a julgamento, intuição, pesquisas ou técnicas comparativas a fim de produzir estimativas sobre o futuro. As informações relativas aos fatores que afetam a previsão são tipicamente não quantitativas, flexíveis e subjetivas.

Já Correa e Correa (2012), diz que os métodos qualitativos incorporam mais fatores de julgamento e intuição, em geral mais subjetivos, nas análises dos

dados disponíveis. Opiniões de especialistas, experiências e julgamentos individuais e outros fatores não quantitativos podem ser levados em conta.

3.4.1.2 Métodos Quantitativos

Segundo Correa e Correa (2012), métodos quantitativos são os métodos de previsão baseados em séries de dados históricos nas quais se preocupa, através de análises, identificar padrões de comportamento para que estes sejam então projetados para o futuro.

Quando se dispõe de um número razoável de dados históricos e a tendência e variações sazonais nas séries de tempo são estáveis e bem definidas, a projeção desses dados no futuro pode representar uma maneira eficiente de previsão de curto prazo. (BALLOU, 2006). Com isso, o tratamento de uma série temporal de dados pressupõe a decomposição da série em seus elementos.

Para a realização deste trabalho, de acordo com os dados e a bibliografia estudada, foram utilizados os Métodos quantitativos baseados em séries temporais, dentre eles os métodos Médias móveis, Holt-Winters e ARIMA para realizar a previsão de demanda.

3.4 SÉRIES TEMPORAIS

Para Morettin e Tolo (2006), série temporal pode ser definida como uma coleção de observações feitas sequencialmente ao longo do tempo, podendo ser do tipo discreta ou contínua. Uma série temporal é dita discreta quando as suas medidas são obtidas em intervalos de tempo regularmente espaçados; já as contínuas são aquelas em que suas observações são realizadas continuamente no tempo. É importante ressaltar que, em muitos casos, as séries temporais discretas são obtidas por amostragem de uma série temporal contínua.

De acordo com Chatfield (1996), as séries temporais estão presentes em diversos campos de atuação, da engenharia à economia, e os métodos para analisá-las fazem parte de uma importante área da estatística.

Segundo Moreira (2008), uma série temporal é sequência de observações da demanda ao longo do tempo. O autor afirma ainda que, as observações podem compreender um período de tempo como dias, semanas, meses, trimestres, anos entre outros.

Stevenson (2001) cita que a decomposição de séries temporais se dá por meio de cinco principais componentes: tendência, sazonalidade, ciclos, variações irregulares e variações aleatórias. Já Moreira (2008), afirma que se o período observado for longo o bastante, o padrão de demanda resultante possibilita distinguir quatro comportamentos associados com uma série temporal conforme descrito no Quadro 1.

| | |
|------------------------------|--|
| Efeito de tendência | Confere à demanda uma tendência de crescimento ou decrescimento com o tempo. A demanda, também, pode se manter estacionária, variando em torno de um valor médio. |
| Efeito sazonal | Representa o fato de que a demanda de muitas mercadorias assume comportamentos parecidos em épocas bem definidas do ano. |
| Ciclos de negócios | Os ciclos são flutuações econômicas de ordem geral, de periodicidade variável, devidas a uma multiplicidade de causas ainda em debate. |
| Variações irregulares | São variáveis devidas às causas não identificadas, ocorrem no curto prazo, diferentemente dos ciclos de negócios. Pelo fato de ocorrerem ao acaso, essas variações não podem ser previstas por modelo algum de previsão. |

Quadro 1 - Comportamentos associados com uma série temporal

Fonte: O autor, adaptado de Moreira (2008).

Assim sendo, a escolha do método de previsão a ser utilizado se baseará dentro das características de comportamento das séries temporais (PEINALDO; GRAEML, 2007).

3.4.1 ANÁLISE DE ERROS

De acordo com Pegels (1990), um fator importante na seleção de um método de previsão é a precisão, no entanto, o custo de oportunidade de erros de

previsão e a complexidade de cada método utilizado é o que determina a escolha da medida de precisão a ser utilizada para avaliar o método de previsão.

Segundo Pacheco e Silva (2003), existem vários tipos de medidas de erro de previsão que podem mensurar os desvios entre os valores previstos e os valores observados. Dentre essas medidas estão o erro médio absoluto, do inglês *mean absolute error* (MAE), a raiz do erro quadrático médio, do inglês *root-mean-square error* (RMSE) e o erro percentual absoluto médio, do inglês *mean absolute percentage error* (MAPE).

A média do erro quadrático (MSE), pode ser comparado com a variância incondicional da série (ANDRADE et al., 2012) e é calculado elevando os erros ao quadrado, somando-os e dividindo esta soma pelo número de períodos. O inconveniente deste método se encontra na unidade de medida dos erros, que é avaliada elevando-se ao quadrado, o que pode ser contornado utilizando-se sua raiz quadrada, denominada RMSE. Moura et al. (2010), cita que o cálculo da raiz do erro quadrático médio (RMSE) e tem o objetivo de mostrar a dimensão do erro de uma determinada estimativa.

Segundo Goodwin e Lawton (1999), para se comparar diferentes séries, a medida MAPE (erro percentual absoluto médio) é a mais adequada, uma vez que, por ser uma unidade métrica livre, consegue relacionar o tamanho do erro para uma observação proporcionalmente real. Para Carvalho (2012), ela é definida por meio do percentual da diferença entre o previsto e o realizado, em módulo, sendo independente de escala.

De acordo com Carvalho (2012), uma medida muito comum no controle de estoque é o erro médio absoluto (MAE), que consiste no módulo da diferença entre o previsto e o realizado, medido na mesma unidade da série, diferenciando-se assim, do MAPE, que é medido em porcentagem.

3.5 MEDIA MÓVEL SIMPLES

Para Ragsdale (2009) o método de média móvel simples é considerado um dos mais fáceis de ser aplicado devido a simples compreensão dos elementos estacionários. Já Corrêa e Corrêa (2012) enfatizam que, os modelos de médias

móveis assumem que a melhor estimativa do futuro é dada pela média dos n últimos períodos.

A Equação 1 é citada por Krajewski, Ritzman, Malhotra (2009) para o cálculo das médias móveis simples.

$$P_{t+1} = \frac{D_t + D_{t-1} + D_{t-2} + \dots + D_{t-n+1}}{n} \quad (1)$$

Em que:

D_t = demanda real no período t

n = Número total de períodos da média

P_{t+1} = Previsão para o período $t+1$

As desvantagens desse modelo estão relacionadas à falta de exatidão ao lidar com séries históricas que apresentam tendência ou sazonalidade. De acordo com Tubino (2009), uma das desvantagens refere-se ao fato de que as observações mais antigas recebem o mesmo peso que as observações recentes. Em outras palavras, a denominação média móvel advém do fato da técnica substituir a observação mais antiga pela mais recente para calcular a média mais atual, sendo que a previsão dos valores futuros é dada pela última média móvel.

Uma boa alternativa para suavizar esse erro é a utilização da média ponderada para tentar construir um padrão mais próximo à realidade, conforme é apresentado na seção abaixo.

3.6 MEDIA MÓVEL PONDERADA

Segundo Martins e Laugeni (2005), a média móvel ponderada é semelhante ao método da média móvel simples, porém tendo como principal diferença a atribuição de pesos distintos em períodos de tempo distintos.

Krajewski, Ritzman, Malhotra (2009), citam que para calcular a média ponderada deve-se multiplicar os pesos de cada período pelo valor desse período, somando-os no final.

De acordo com Peinaldo e Graeml (2007) os dados que possuem períodos mais recentes são considerados mais relevantes e, por isso, recebem pesos mais elevados do que os períodos anteriores.

Desta maneira, a previsão pode ser obtida por meio da Equação 2.

$$P_j = (D_1 \times PE_1) + (D_2 \times PE_2) + \dots + (D_n \times PE_n) \quad (2)$$

Em que:

P_j = Previsão para o período j;

D_n = Demanda do período i;

PE_n = Peso atribuído ao período i;

Sendo que:

$$PE_1 + PE_2 + PE_3 + \dots + PE_n = 1 \quad (3)$$

A desvantagem na utilização da média móvel ponderada é a necessidade de conhecimento para determinar os pesos a serem utilizados (DAVIS; AQUILANO; CHASE, 2001).

3.7 MODELO DE HOLT-WINTERS

Os modelos de Holt-Winters descrevem acertadamente dados de demanda em que se verifica a geração da tendência linear, e um componente de sazonalidade (PELLEGRINI; FLOGIATTO, 2000). No modelo aditivo, a amplitude de variação sazonal permanece constante, ou seja, a diferença entre o maior e o menor ponto de demanda nos ciclos permanece constante com o passar do tempo. Já no

modelo multiplicativo, a amplitude de sazonalidade cresce com o tempo, ou seja, a diferença entre o maior e o menor ponto de demanda nos ciclos aumenta com o passar do tempo (ALBUQUERQUE; SERRA, 2006).

De acordo com Albuquerque e Serra (2006), o modelo de Holt-Winters é um dos mais utilizados para a previsão em curto prazo, uma vez que, é simples, tem baixo custo de operação e boa precisão.

Para Morettin e Tolo (2006) o modelo de Holt-Winters tem um fácil entendimento e baixo custo computacional, além de serem próprios para série com padrão de comportamento. No entanto, há certa dificuldade com a determinação das constantes de suavização e/ou impossibilidade em estudar as propriedades estatísticas, como média e variância de previsão, e por sua vez, a construção de um intervalo de confiança.

O Quadro 2 apresenta as equações dos modelos Holt-Winters aditivo e multiplicativo.

| | Holt-Winters Aditivo | Holt-Winters Multiplicativo |
|---------------------|---|--|
| Nível | $L_t = \alpha(Y_t - S_{t-s}) + (1 - \alpha)(L_{t-1} + b_{t-1})$ | $L_t = \alpha \frac{Y_t}{S_{t-s}} + (1 - \alpha)(L_{t-1} + b_{t-1})$ |
| Tendência | $b_t = \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1}$ | $b_t = \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1}$ |
| Sazonalidade | $S_t = \gamma(Y_t - L_t) + (1 - \gamma)S_{t-s}$ | $S_t = \gamma \left(\frac{Y_t}{L_t} \right) + (1 - \gamma)S_{t-s}$ |
| Previsão | $F_{t+m} = (L_t + b_t m) + S_{t-s+m}$ | $F_{t+m} = (L_t + b_t m) S_{t-s+m}$ |

Quadro 2 - Equações comparativas entre o modelo aditivo e multiplicativo de Holt-Winters
 Fonte: Albuquerque e Serra (2006).

Sendo:

S – Comprimento da Sazonalidade;

L_t – Nível da Série;

b_t – Tendência;

S_t – Componente Sazonal;

F_{t+m} – Previsão para o período m;

Y_t – Valor Observado;

α , β e γ – São parâmetros exponenciais alisadores do nível, da tendência e da sazonalidade, respectivamente.

3.8 MODELO BOX-JENKINS

Segundo Maddala (2003), é uma das metodologias mais utilizadas para análise de dados em séries temporais.

A metodologia conhecida popularmente como Box-Jenkins e, tecnicamente, como ARIMA (*Autoregressive Integrated Moving Average*), parte do princípio de que cada valor da série temporal pode ser explicado por seus valores prévios, em função da utilização de uma estrutura de correlação temporal, que é algo que geralmente existe entre os valores da série (GUJARATI, 2000). São modelos matemáticos que visam assimilar o comportamento da correlação serial ou autocorrelação entre os valores da série temporal, cuja informação auxilia na determinação do modelo utilizado para realizar previsões futuras.

Para Mueller (1996) o modelo ARIMA, possui capacidade de manipular séries temporais de qualquer natureza, desde que contenham estrutura de dependência linear entre os dados. Modelos Autorregressivos e de Médias Móveis (ARMA) obtêm a previsão de algum valor futuro da série temporal pela combinação dos valores reais passados ou dos erros ocorridos, em algumas vezes utilizando ambos.

Esses modelos conseguem relatar os processos de geração de uma infinidade de séries temporais sem precisar das relações que as produzem (MONTGOMERY; JENNINGS; KULACHI, 2008).

3.8.1 Modelo Autorregressivo e Modelo de Média Móvel

Segundo Gujarati (2000) os modelos Autorregressivos (AR) e Médias Móveis (MA) se baseiam no pressuposto de que a série temporal seja gerada por meio de um sistema linear, e que contém um termo de erro aleatório não correlacionado, com média zero e variância constante, ou seja, um ruído branco. Para o caso de modelos AR, dada uma série de dados Z_t , esta será descrita por seus valores históricos Z_{t-1} , Z_{t-2} , e pelo ruído branco α_t , conforme mostra a Equação 5, citada por Morettin e Tolo (2006).

$$Z_t = \emptyset_1 Z_{t-1} + \emptyset_2 Z_{t-2} + \dots + \emptyset_p Z_{t-p} + \alpha_t \quad (5)$$

Na equação 5, p é a ordem do modelo autorregressivo, denotado por $AR(p)$. De outra maneira, o valor de Z no período t , depende do seu valor nos p períodos anteriores. Desta forma, $AR(p)$ é um processo autorregressivo de p -ésima ordem. Já o modelo MA, além de considerar o termo de erro (ruído branco), leva em conta o valor de uma constante mais uma média móvel dos termos de erro corrente e passado. Os modelos de médias móveis consistem em expressar os valores de determinada série como combinação linear do valor corrente e valores passados de erros (ou choques) aleatórios (BOX, JENKINS, REINSEL, 1994).

Assim, conforme Gujarati (2000), Z no período t é igual a uma constante mais uma média móvel e um processo de média móvel é simplesmente uma combinação linear dos termos de erro ruído branco, cuja ordem é representada por q . Portanto, um modelo $MA(q)$ conforme Morettin e Tolo (2006) pode ser expresso pela Equação 6.

$$Z_t = a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q} \quad (6)$$

Em que $MA(q)$ é um processo de média móvel de ordem q .

3.8.2 Modelo ARIMA

Segundo Bueno (2008), o modelo de Box-Jenkins tem como base o ajuste de modelos de tentativa chamados de ARIMA (autorregressivos integrados de médias móveis) às séries temporais de valores observados no qual a diferença entre os valores fornecidos pelos modelos e os observados resulte em séries de comportamento aleatório próximo de zero.

Diversos autores como Gujarati (2000), Morettin e Tolo (2006), Ediger e Akar (2007), afirmam que o modelo ARIMA teve origem a partir dos modelos de autorregressão (AR) e das médias móveis (MA) e da combinação entre AR e MA (modelo ARMA).

Para Gujarati (2000), várias séries temporais trabalhadas são não-estacionárias, de forma que as características dos processos estocásticos implícitos mudam com o decorrer do tempo. O processo observado deve ser necessariamente estacionário pelo fato de existir a possibilidade de fixar parâmetros válidos para conseguir prever o futuro a partir de dados passados (MORETTIN; TOLOI, 2006).

Uma série é considerada estacionária quando possui um equilíbrio estável por meio do seu desenvolvimento no tempo de forma aleatória ao redor de uma média constante (GUJARATI, 2000). Portanto, o primeiro passo para realizar essa modelagem é realizar procedimentos para remover a não-estacionariedade por meio da diferenciação da ordem d . O número de diferenças necessárias para transformar uma série não-estacionária em uma série estacionária é chamada de ordem de diferenciação (BOX, JENKINS, REINSEL, 1994).

Assim sendo, se for necessária para análise de uma série temporal a sua diferenciação d vezes para torná-la estacionária, diz-se que esta série temporal é ARIMA. Deste modo, será representada por ARIMA (p, d, q) , em que p indica o número de termos autorregressivos ou ordem autorregressiva, d o número de vezes que a série deve ser diferenciada para se tornar estacionária e, q indica o número de termos de média móvel ou ordem médias móveis (GUJARATI, 2000). O modelo da estrutura ARIMA pode ser expresso por meio da Equação 7.

$$\Delta^d Z_t = W_t = \phi_1 W_{t-1} + \phi_2 W_{t-2} + \dots + \phi_p W_{t-p} + \alpha_t - \theta_1 \alpha_{t-1} - \dots - \theta_q \alpha_{t-q} \quad (7)$$

Geralmente, a inclusão de termos autorregressivos e combinados com termos médias móveis resulta em modelos mais parcimoniosos em relação às formas puramente autorregressivas ou médias móveis.

3.8.3 Metodologia de Box-Jenkins para a Construção de Modelos ARIMA

Para Morettin e Tolo (2006), o método para a construção do modelo terá como base um ciclo iterativo, em que a escolha da estrutura do modelo se baseia nos próprios dados. As seguintes etapas são citadas pelo autor:

- I. Uma classe geral de modelos é considerada para análise (especificação);
- II. Há identificação de um modelo, com base na análise de autocorrelações, autocorrelações parciais e outros critérios;
- III. Estimação, na qual os parâmetros do modelo identificado são estimados;
- IV. E por fim, existe a verificação do modelo ajustado, por meio de uma análise de resíduos, para saber se este é adequado ou não.

Marchezan (2007) ilustra graficamente as etapas para elaborar um modelo ARIMA conforme mostra a Figura 3.

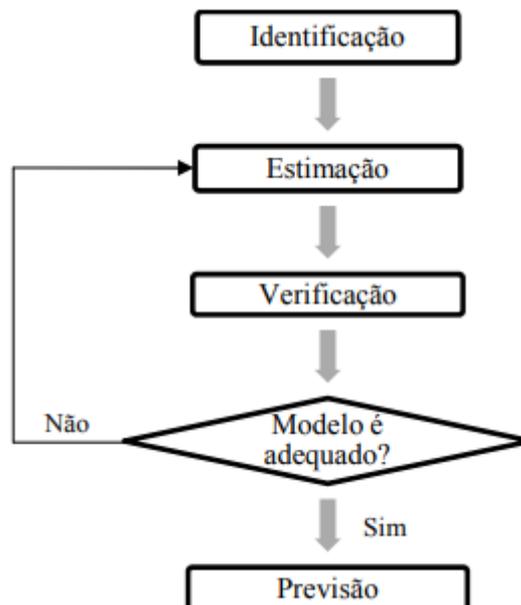


Figura 3 - Etapas para a construção de um modelo ARIMA
Fonte: Marchezan (2007)

Desta forma, sempre que o modelo se mostrar inadequado, as etapas devem ser repetidas. De outro modo, as etapas devem se repetir até que seja obtido um modelo satisfatório que descreva o processo gerador da série (MORETTIN; TOLOI, 2006). Por fim, quando um modelo satisfatório é obtido, passa-se para a última etapa da metodologia, ou seja, a realização das previsões.

4 PROCEDIMENTOS METODOLÓGICOS

4.1 CARACTERIZAÇÃO DA EMPRESA

A empresa em estudo está localizada na Região Oeste do Paraná, especializada no ramo de refrigeração automotiva, atuando no mercado há 45 anos.

No início a empresa trabalhava apenas com a manutenção e fabricação de radiadores, passando a trabalhar com condicionadores de ar e seus acessórios a partir de 2010, expandindo seus negócios também para o Paraguai no ano de 2016.

Localizada na cidade de Foz do Iguaçu, se tornou uma referência na região, uma vez que atende à demanda de toda a região da tríplice fronteira, possuindo clientes no Brasil, Paraguai e Argentina.

4.2 CLASSIFICAÇÃO DA PESQUISA

Segundo Prodanov e Freitas (2013), a pesquisa científica é a realização de um estudo planejado, sendo o método de abordagem do problema o que caracteriza o aspecto científico da investigação. Já Gil (2008), define pesquisa como o processo formal e sistemático de desenvolvimento do método científico. O objetivo fundamental da pesquisa é descobrir respostas para problemas mediante o emprego de procedimentos científicos.

Portanto, pesquisa é um conjunto de ações para encontrar a solução para um problema. Existem várias formas de classificar as pesquisas, a Figura 4 mostra esta classificação de acordo com requisitos como objetivo, natureza, objeto de estudo e técnicas utilizadas para coleta e análise.

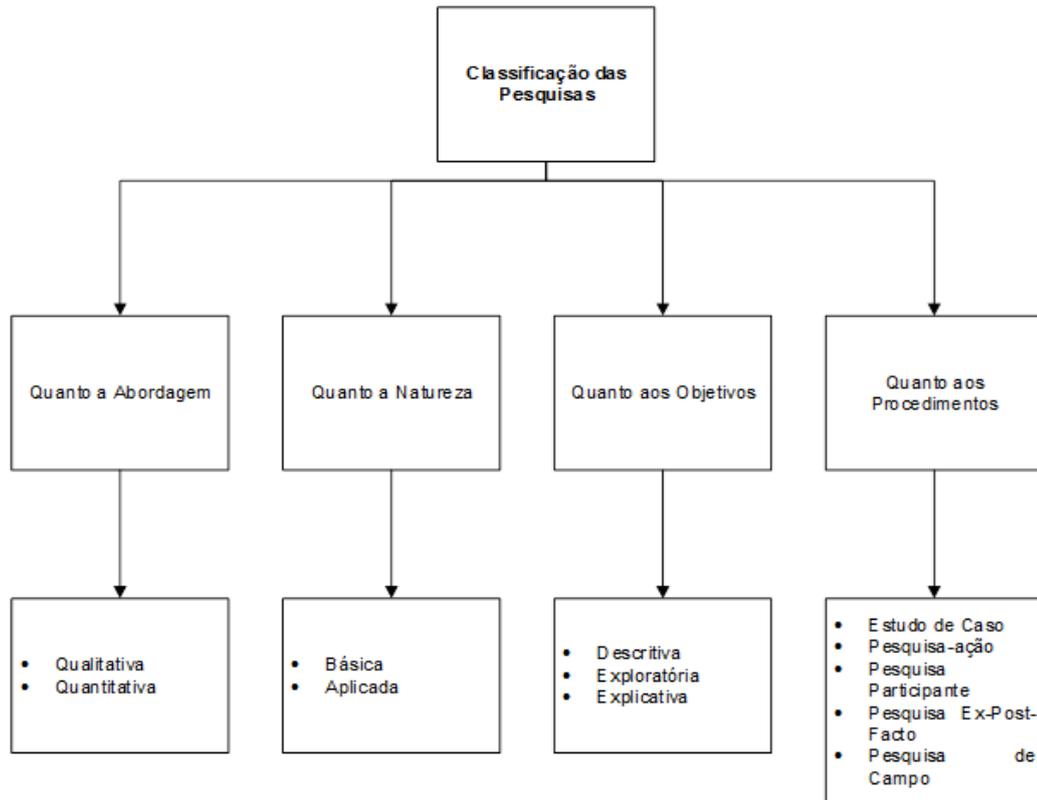


Figura 4 - Classificação das Pesquisas
 Fonte: Adaptado de Vianna (2013)

Quanto à abordagem, a pesquisa proposta é quantitativa. Kauark et al. (2010) consideram como pesquisa quantitativa o que pode ser quantificável, o que significa traduzir em números opiniões e informações para classificá-las e analisá-las. Os softwares computacionais *Microsoft Office Excel®* e *Eviews®* foram utilizados para realizar a organização e o tratamento dos dados brutos, os quais foram utilizados para a obtenção dos modelos propostos neste projeto.

A respeito da natureza da pesquisa é classificada como sendo aplicada, pois, segundo Prodanov e Freitas (2013), a pesquisa aplicada objetiva gerar conhecimentos para aplicação prática dirigida à solução de problemas específicos. A problemática da pesquisa pode ser caracterizada na escolha de um método de previsão que serviu para prever com precisão a demanda dos produtos automotivos na região Oeste do Paraná, tendo como base o menor erro RMSE no ajuste.

Já na classificação quanto aos objetivos, a pesquisa se enquadra como descritiva, que tem como objetivo primordial, segundo Gil (2008), a descrição das características de determinada população ou fenômeno ou o estabelecimento de relações entre variáveis.

Os procedimentos técnicos da pesquisa são caracterizados como estudo de caso, pois, de acordo com Prodanov e Freitas (2013), um estudo de caso consiste em coletar e analisar informações sobre determinado indivíduo, uma família, um grupo ou uma comunidade, a fim de estudar aspectos variados de sua vida, de acordo com o assunto da pesquisa.

4.3 ETAPAS DA PESQUISA

4.3.1 Visita técnica

A primeira etapa consistiu em uma visita à empresa estudada, com o intuito de identificar os problemas e possíveis melhorias no que diz respeito à demanda. Nesta etapa foi realizada uma conversa informal com o dono para entender melhor o negócio e possíveis características do processo que forneça subsídios para a escolha do melhor método e referências. Gil (2008), afirma que este tipo de entrevista tem como objetivo básico a coleta de dados, é considerada a menos estruturada, e limitada com uma simples conversação.

4.3.2 Revisão bibliográfica

Nesta etapa foi realizado um estudo da bibliografia dos métodos de previsão de demanda com o objetivo de identificar quais métodos poderiam ser utilizados, e posteriormente, com base nos dados obtidos, foi realizado um estudo de tendência e/ou sazonalidade, cálculo do erro e também uma análise qualitativa dos produtos vendidos, e posteriormente foram comparados e identificado o melhor método para o caso analisado.

4.3.3 Coleta de dados

Os dados foram fornecidos pela empresa por meio de planilhas. A coleta de dados se deu por meio do histórico de vendas da empresa, tendo como base todo o registro histórico, totalizando assim, um período de 4 anos. Foram selecionados os dois setores de maior importância dentro da empresa, sendo eles: setor de condicionadores de ar e radiadores. Após esta etapa, foram analisados os equipamentos que mais foram vendidos nestes dois setores, que juntos, são responsáveis pela maior parte das vendas, dentre eles: compressor, condensador e evaporador para o setor de condicionadores de ar e, radiador, aditivo e caixa plástica para o setor de radiadores. Estes produtos foram quantificados por vendas mensais.

Desta forma, com o auxílio dos *softwares Microsoft Office Excel®* e *Eviews®*, foram analisados, calculados e aplicados nos métodos de Médias Móveis, Holt-Winters, e ARIMA. Com isso, os erros foram calculados, e o método que possuiu o menor erro no ajuste foi considerado o modelo que melhor se ajustou na série de dados de cada produto.

4.3.4 Análise dos resultados

Por fim, foram verificadas as existências da sazonalidade, da tendência e do erro, e a partir disto foi realizada uma análise quantitativa dos resultados, identificado o método que teve o melhor ajuste para cada série estudada.

5 RESULTADOS E DISCUSSÃO

Durante a realização da pesquisa, constatou-se que nenhum método de previsão de demanda é utilizado pela empresa.

Este trabalho teve como foco duas áreas da empresa: condicionadores de ar e radiadores, que juntas, são responsáveis pela maior parte das vendas. Após análise dos dados, foram separados os três produtos mais vendidos de cada setor, dentre eles: compressor, condensador e evaporador para o setor de condicionadores de ar e, radiador, aditivo e caixa plástica para o setor de radiadores. Estes produtos foram quantificados por vendas mensais.

Sendo assim, por meio dos dados históricos, foi possível analisar o comportamento dos dados da empresa em estudo, observando-se principalmente as variáveis de nível, tendência e sazonalidade.

Os dados coletados compreendem março de 2015 à fevereiro de 2019 para os produtos do setor de condicionadores de ar e, março de 2015 à março de 2019 para os produtos do setor de radiadores, como pode-se observar nas Tabelas 1, 2, 3, 4, 5 e 6. Com isso, cada mês foi considerado como um período, totalizando 44 períodos para compressor, 47 períodos para condensador, 46 períodos para evaporador, 44 períodos para aditivo, 44 períodos para caixa plástica e 48 períodos para radiador, que foram utilizados nos cálculos das previsões. Os meses que não contabilizaram vendas, não foram considerados como período.

A Tabela 1 apresenta a venda de peças de compressores.

Tabela 1 - Vendas de Compressores por mês

| | 2015 | 2016 | 2017 | 2018 | 2019 |
|------------------|-------------|-------------|-------------|-------------|-------------|
| Janeiro | - | 24 | 19 | 18 | 33 |
| Fevereiro | - | 20 | 19 | 19 | 20 |
| Março | 0 | 15 | 36 | 20 | - |
| Abril | 0 | 16 | 6 | 14 | - |
| Mai | 0 | 8 | 15 | 11 | - |
| Junho | 0 | 6 | 11 | 8 | - |
| Julho | 0 | 2 | 11 | 17 | - |
| Agosto | 3 | 10 | 12 | 19 | - |
| Setembro | 12 | 10 | 18 | 14 | - |
| Outubro | 13 | 9 | 14 | 14 | - |
| Novembro | 16 | 13 | 10 | 17 | - |
| Dezembro | 14 | 12 | 16 | 21 | - |

Fonte: Autoria própria (2019)

A tabela 2 exibe a venda de peças de Condensadores.

Tabela 2 - Vendas de Condensadores por mês

| | 2015 | 2016 | 2017 | 2018 | 2019 |
|------------------|-------------|-------------|-------------|-------------|-------------|
| Janeiro | - | 17 | 16 | 25 | 32 |
| Fevereiro | - | 15 | 25 | 24 | 35 |
| Março | 1 | 13 | 50 | 22 | - |
| Abril | 0 | 12 | 21 | 16 | - |
| Mai | 3 | 16 | 30 | 14 | - |
| Junho | 0 | 14 | 21 | 11 | - |
| Julho | 6 | 15 | 17 | 17 | - |
| Agosto | 16 | 15 | 17 | 28 | - |
| Setembro | 15 | 15 | 25 | 25 | - |
| Outubro | 17 | 14 | 20 | 29 | - |
| Novembro | 11 | 20 | 30 | 33 | - |
| Dezembro | 13 | 18 | 28 | 25 | - |

Fonte: Autoria própria (2019)

Já na tabela 3, é apresentado o número de vendas de Evaporadores.

Tabela 3 - Vendas de Evaporadores por mês

| | 2015 | 2016 | 2017 | 2018 | 2019 |
|------------------|-------------|-------------|-------------|-------------|-------------|
| Janeiro | - | 6 | 11 | 8 | 26 |
| Fevereiro | - | 9 | 4 | 12 | 17 |
| Março | 0 | 14 | 18 | 9 | - |
| Abril | 0 | 9 | 1 | 11 | - |
| Mai | 0 | 2 | 4 | 7 | - |
| Junho | 0 | 4 | 6 | 5 | - |
| Julho | 1 | 1 | 7 | 9 | - |
| Agosto | 1 | 4 | 7 | 11 | - |
| Setembro | 5 | 9 | 6 | 8 | - |
| Outubro | 7 | 9 | 7 | 9 | - |
| Novembro | 7 | 4 | 7 | 15 | - |
| Dezembro | 4 | 8 | 16 | 12 | - |

Fonte: Autoria própria (2019)

As vendas de aditivo (cada unidade contém 1l), caixa plástica e radiadores estão quantificadas conforme tabelas 4, 5 e 6

Tabela 4 – Vendas de aditivo

| | 2015 | 2016 | 2017 | 2018 | 2019 |
|------------------|-------------|-------------|-------------|-------------|-------------|
| Janeiro | - | 70 | 55 | 105 | 67 |
| Fevereiro | - | 32 | 52 | 72 | 86 |
| Março | - | 51 | 147 | 43 | 32 |
| Abril | - | 47 | 61 | 58 | - |
| Mai | - | 38 | 64 | 73 | - |
| Junho | - | 41 | 30 | 60 | - |
| Julho | - | 21 | 147 | 191 | - |
| Agosto | 1 | 96 | 45 | 98 | - |
| Setembro | 6 | 58 | 55 | 78 | - |
| Outubro | 50 | 56 | 67 | 115 | - |
| Novembro | 93 | 96 | 69 | 65 | - |
| Dezembro | 20 | 24 | 63 | 53 | - |

Fonte: Autoria própria (2019)

Tabela 5 – Vendas de caixa plástica

| | 2015 | 2016 | 2017 | 2018 | 2019 |
|------------------|-------------|-------------|-------------|-------------|-------------|
| Janeiro | - | 10 | 132 | 176 | 131 |
| Fevereiro | - | 8 | 114 | 145 | 104 |
| Março | - | 24 | 327 | 142 | 93 |
| Abril | - | 5 | 139 | 174 | - |
| Mai | - | 4 | 123 | 206 | - |
| Junho | - | 12 | 118 | 110 | - |
| Julho | - | 22 | 114 | 125 | - |
| Agosto | 2 | 13 | 118 | 188 | - |
| Setembro | 2 | 34 | 131 | 251 | - |
| Outubro | 3 | 116 | 146 | 129 | - |
| Novembro | 4 | 165 | 166 | 128 | - |
| Dezembro | 10 | 141 | 143 | 85 | - |

Fonte: Autoria própria (2019)

Tabela 6 - Vendas de radiador

| | 2015 | 2016 | 2017 | 2018 | 2019 |
|------------------|-------------|-------------|-------------|-------------|-------------|
| Janeiro | - | 75 | 53 | 76 | 94 |
| Fevereiro | - | 84 | 82 | 59 | 104 |
| Março | - | 89 | 191 | 79 | 62 |
| Abril | 2 | 70 | 85 | 106 | - |
| Mai | 10 | 82 | 165 | 134 | - |
| Junho | 35 | 73 | 103 | 85 | - |
| Julho | 53 | 85 | 101 | 131 | - |
| Agosto | 68 | 78 | 108 | 162 | - |
| Setembro | 75 | 69 | 93 | 193 | - |
| Outubro | 92 | 84 | 85 | 106 | - |
| Novembro | 58 | 69 | 92 | 84 | - |
| Dezembro | 20 | 56 | 107 | 111 | - |

Fonte: Autoria própria (2019)

A partir disso, as plotagens dos gráficos que estão representados nas Figuras 5 e 6 podem ser feitas, os quais representam os dados históricos de venda dos períodos descritos anteriormente. Apesar dos gráficos das três séries temporais em análise apresentarem fraca tendência de crescimento, foi aplicado o teste de estacionariedade (Dickey-Fuller Aumentado) e o resultado mostrou que todas as séries são estacionárias na média, não sendo necessária a aplicação do operador diferenciação. Também foi constatado que a série temporal é estacionária, ainda, na variância. No geral, as séries apresentam um comportamento com baixa estrutura de dependência ou padrões temporais. Acredita-se que, com uma quantidade maior de

dados, é possível de se obter modelos que melhor representem a estrutura de dependência destes dados.

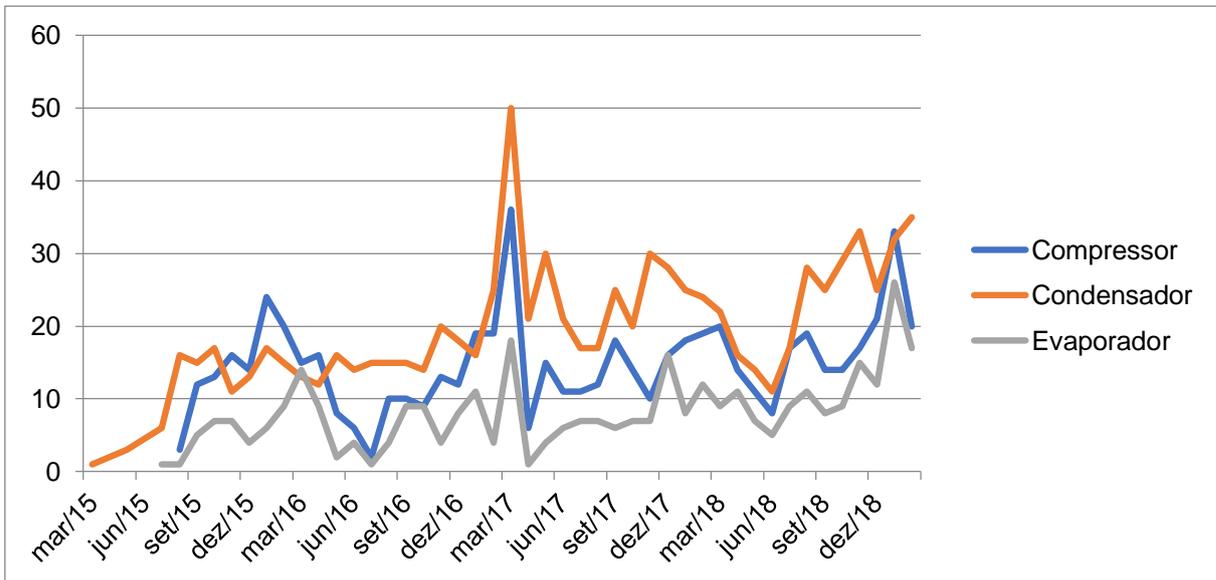


Figura 5 - Gráfico de linha das vendas no setor de condicionadores de ar
Fonte: Autoria própria (2019)

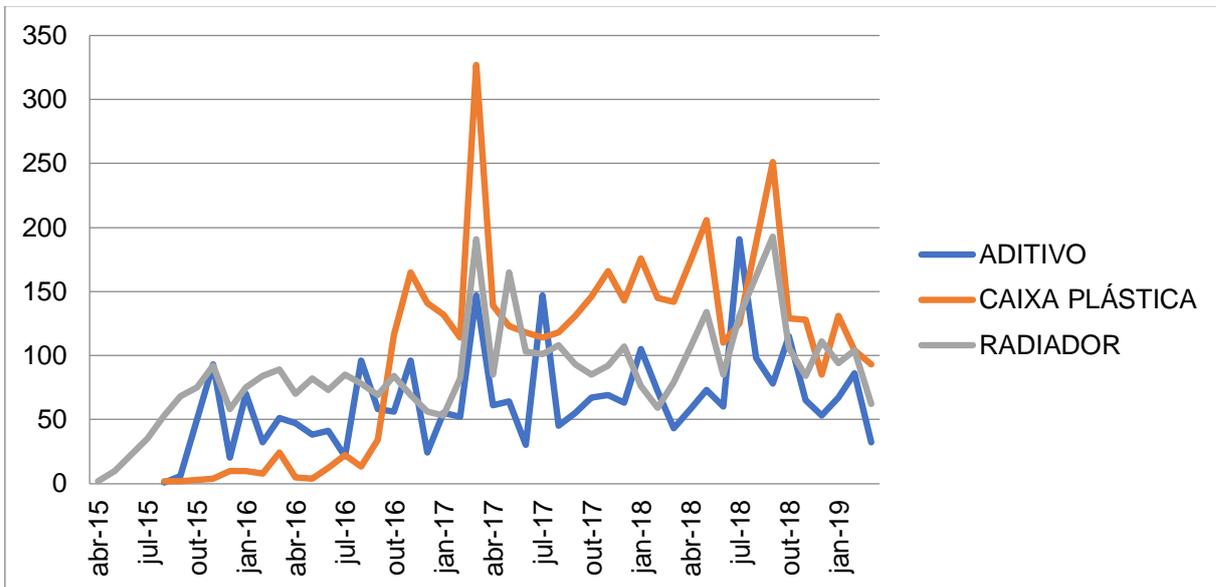


Figura 6 - Gráfico de linha das vendas no setor de radiadores
Fonte: Autoria própria (2019)

Após a coleta dos dados históricos, organização e tratamento dos dados, observação e análise do comportamento, foram testados alguns modelos e em seguida, feita uma comparação entre eles, para concluir qual modelo mais se ajustou para cada série de dados, ou seja, aquele com o menor erro no ajuste.

Como já citado, todas as previsões foram realizadas nos softwares Eviews® e Excel®, com o auxílio do software Excel® para a produção de tabelas e gráficos.

O primeiro método a ser utilizado foi o método de médias móveis simples, com o número de períodos anteriores inclusos na média igual a 2, cujo intervalo melhor se ajustou ao modelo. O segundo método escolhido para a análise foi o método holt-winters, que se ajusta melhor a um modelo com uma tendência linear e um componente de sazonalidade, e o terceiro modelo escolhido para a previsão de demanda foi o ARIMA sem diferenciação, ou ARMA, onde os modelos de autorregressão (AR) e das médias móveis (MA) combinados dão origem a este modelo. A justificativa da escolha do modelo ARMA em vez do ARIMA foi feita com base nos testes de estacionariedade (Dickey-Fuller Aumentado), uma vez que tais resultados sugeriram a não aplicação do operador de diferenciação para tornar os dados estacionários, pois os mesmos já apresentavam este comportamento.

O Quadro 3 resume os modelos que foram usados para o cálculo da previsão da demanda.

| | |
|-----------------|-----------------------|
| Primeiro modelo | Médias móveis simples |
| Segundo modelo | Holt-Winters |
| Terceiro modelo | ARMA |

Quadro 3 - Modelos usados para o cálculo de previsão da demanda

Fonte: Autoria própria (2019)

5.1 SETOR DE CONDICIONADORES DE AR

5.1.1 Modelos de Previsão da demanda de Compressores

A partir dos modelos apresentados, foram realizadas as previsões dos últimos seis períodos, que correspondem ao mês de setembro de 2018 a fevereiro de 2019, e seus respectivos resultados, juntos com a demanda real, estão apresentados na Tabela 7 e na Figura 7.

Tabela 7 - Demanda real e prevista

| Demanda real | Médias móveis | Holt-winters | Arma |
|--------------|---------------|--------------|------|
| 14 | 17 | 17 | 14 |
| 14 | 14 | 16 | 13 |
| 17 | 16 | 15 | 17 |
| 21 | 19 | 17 | 20 |
| 33 | 27 | 19 | 26 |
| 20 | 27 | 26 | 19 |

Fonte: Aatoria própria (2019)

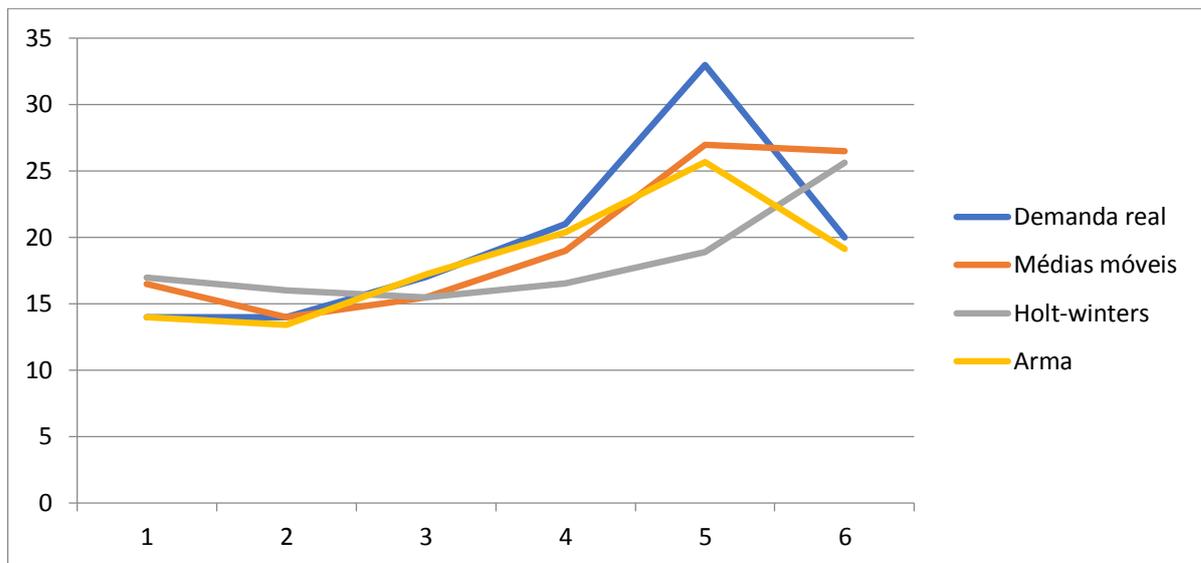


Figura 7 – Gráfico da demanda real e prevista para compressores

Fonte: Aatoria própria (2019)

A partir da demanda calculada, pode-se calcular a raiz do erro quadrático médio (RMSE), o erro percentual absoluto médio e erro médio absoluto (MAE), que estão apresentados no Quadro 4.

| | Médias móveis | Holt-winters | ARMA |
|-------------|---------------|--------------|----------|
| RMSE | 4,062019 | 6,645801 | 2,94392 |
| MAPE | 0,150028 | 0,231585 | 0,063528 |
| MAE | 3,166667 | 5,166667 | 1,666667 |

Quadro 4 - Erros calculados

Fonte: Aatoria própria (2019)

Para a análise do resultado dos erros, foi priorizado o RMSE, no qual tem como objetivo mostrar a dimensão do erro de uma determinada estimativa. Com isso, é possível observar que o menor valor do RMSE foi do método ARMA, onde comparado com o erro do modelo médias móveis, possuiu um valor 38% maior que

o ARMA, e quando comparado com o erro do modelo holt-winters, possuiu um valor 120% maior que o RMSE do modelo ARMA. Portanto, pode-se concluir que o modelo o qual se ajustou melhor os dados de demanda do compressor foi o modelo ARMA pelo método dos mínimos quadrados, que é um otimizador dos parâmetros(coeficientes) desse modelo.

A partir disso, as variáveis e seus respectivos coeficientes que foram calculadas a partir do Software computacional *Eviews®*, foram apresentadas na Tabela 8, com o objetivo de montar o modelo de previsão.

Tabela 8 - Variáveis e coeficientes do modelo ARMA

| Variável | Coefficiente |
|-----------------|---------------------|
| AR(2) | 0,237613 |
| AR(12) | 0,751444 |
| MA(2) | -0,448805 |
| MA(4) | 0,88489 |

Fonte: Autoria própria (2019)

Como indicado na Tabela 8, as variáveis apresentadas possuem uma grande significância para a construção do modelo. Ele foi montado conforme essas informações e está descrito na equação 8.

$$Z_t = 0,237613Z_{t-2} + 0,751444Z_{t-12} + a_t - 0,448805a_{t-2} + 0,884890a_{t-4} \quad (8)$$

Em que Z representa o valor da previsão, t representa o seu período, e o α representa o erro. Com isso, Z_t representa o valor futuro que se deseja prever, a_t é chamado de resíduo, Z_{t-1} , Z_{t-2} representa seus valores históricos e α_{t-1} , α_{t-2} representa seus erros históricos. Este modelo, representado na equação 8, descreve a equação do modelo que obteve o menor erro na modelagem.

5.1.2 Modelo de Previsão da demanda de Condensadores

Do mesmo modo que foi realizado para a demanda de Compressores, foi feito a previsão da demanda de condensadores, pelos métodos médias móveis, holt-winters e ARMA. O ARIMA sem diferenciação é chamado de ARMA, e neste caso

pelo método de máxima verossimilhança, que também é um otimizador dos parâmetros desse modelo.

As demandas foram calculadas e são mostradas na tabela 9 e na Figura 8.

Tabela 9 - Demanda real e prevista

| Demanda real | Médias móveis | Holt-winters | Arma |
|--------------|---------------|--------------|------|
| 25 | 27 | 23 | 30 |
| 29 | 27 | 25 | 33 |
| 33 | 31 | 28 | 32 |
| 25 | 29 | 31 | 34 |
| 32 | 29 | 29 | 28 |
| 35 | 34 | 31 | 30 |

Fonte: Autoria própria (2019)

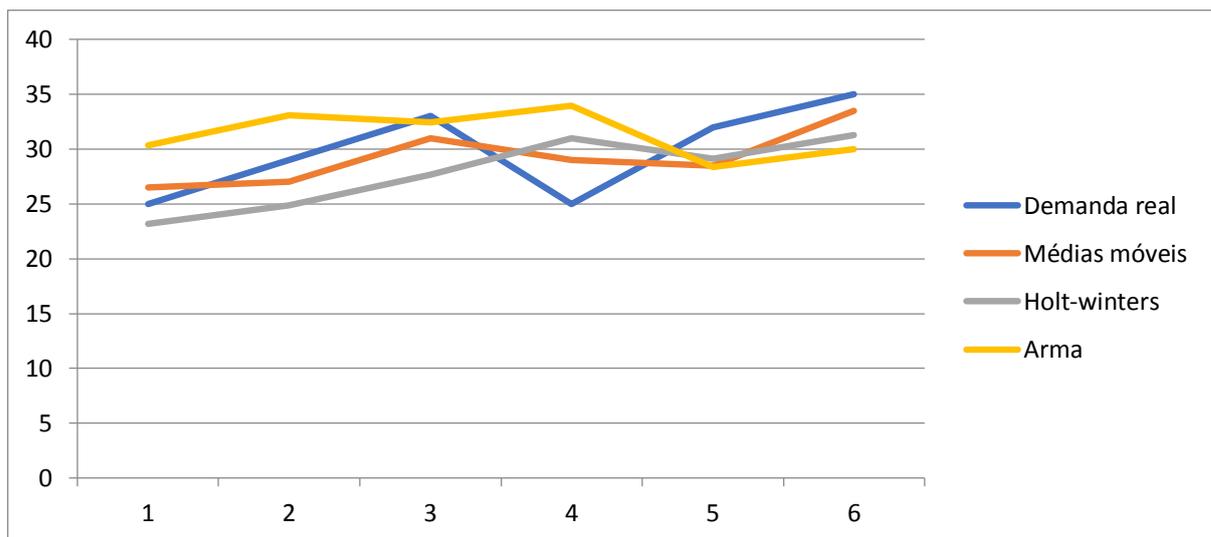


Figura 8 - Gráfico da demanda real e prevista para condensadores

Fonte: Autoria própria (2019)

A partir disso, pode ser feito o cálculo dos erros, que apresenta qual modelo se ajusta melhor a essa série de dados. Esses erros estão representados no Quadro 5.

| | Médias móveis | Holt-winters | ARMA |
|-------------|---------------|--------------|----------|
| RMSE | 2,516611 | 4,203173 | 5,228129 |
| MAPE | 0,081982 | 0,136247 | 0,166015 |
| MAE | 2,333333 | 4 | 4,666667 |

Quadro 5 - Erros calculados

Fonte: Autoria própria (2019)

Pela análise do Quadro 5, foi concluído que o modelo que mais se ajustou a série de dados de condensadores foi o de médias móveis. Para os valores do RMSE, quando comparados com o erro de médias móveis, podemos dizer que o erro do modelo holt-winters foi aproximadamente 67% maior, e o erro do modelo ARMA foi aproximadamente 102% maior que o do método médias móveis.

Já para os valores do MAPE, pode-se dizer que o erro do método holt-winters comparado com o erro do médias móveis, foi aproximadamente 66% maior, e o erro do ARMA foi 97% maior. Com os valores do MAE, temos que o erro do holt-winters foi aproximadamente 71% maior e também que o erro do ARMA foi aproximadamente 100% maior quando comparados com o erro do modelo médias móveis.

Desta forma, foi montado o modelo de médias móveis para o próximo período, que no caso da série de dados de condensadores, é o período número 48. Este modelo está apresentado na equação 9.

$$P_{48} = \frac{D_{47} + D_{46}}{2} \quad (9)$$

Em que P é a previsão, no caso dessa série, para o período 48, D é a demanda real, e o 2 representa o número de períodos anteriores para incluir na média móvel. No caso dessa série de dados, o $N=2$ foi o intervalo que obteve o melhor ajuste.

5.1.3 Modelo de Previsão da demanda de Evaporadores

Da mesma forma que os cálculos dos modelos médias móveis, holt-winters e o ARMA foram realizados para os equipamentos compressor e condensador, em seguida foram realizados para evaporadores, onde a demanda real e as demanda calculadas estão representas na Tabela 10 e na Figura 9.

Da mesma forma que no caso anterior, o terceiro modelo escolhido para a previsão do Evaporador é o ARIMA sem diferenciação, chamado de ARMA, pelo

método de máxima verossimilhança, que também é um otimizador dos parâmetros do modelo.

Tabela 10 - Demanda real e prevista

| Demanda real | Médias móveis | Holt-winters | Arma |
|--------------|---------------|--------------|------|
| 8 | 10 | 11 | 7 |
| 9 | 9 | 11 | 8 |
| 15 | 12 | 11 | 7 |
| 12 | 14 | 11 | 12 |
| 26 | 19 | 11 | 11 |
| 17 | 22 | 13 | 11 |

Fonte: Autoria própria (2019)

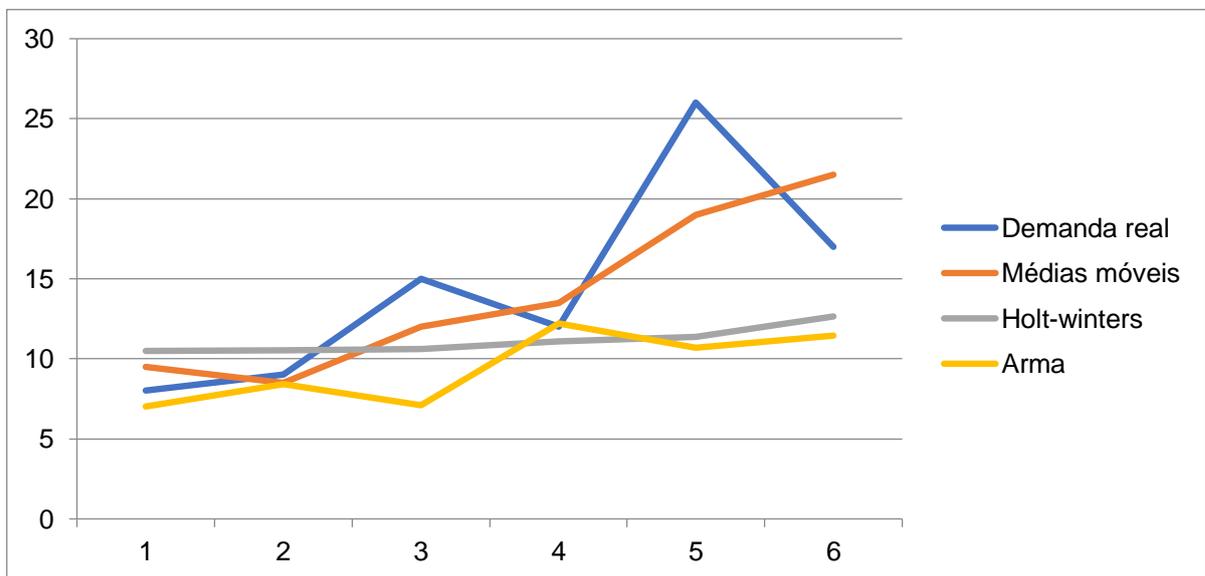


Figura 9 - Gráfico da demanda real e prevista para evaporadores

Fonte: Autoria própria (2019)

A partir da previsão calculada, foi possível realizar os cálculos dos erros desta modelagem, que estão apresentados no Quadro 6.

| | Médias móveis | Holt-winters | ARMA |
|-------------|---------------|--------------|----------|
| RMSE | 3,89444 | 6,720615 | 7,382412 |
| MAPE | 0,196669 | 0,29324 | 0,283218 |
| MAE | 3,166667 | 4,833333 | 5,166667 |

Quadro 6 - Cálculo dos erros

Fonte: Autoria própria (2019)

Analisando os dados, pode-se concluir que o modelo que teve o melhor ajuste para a série de dados de evaporadores foi o modelo média móvel.

Comparando os valores do RMSE, pode-se dizer que o erro do holt-winters foi 73% maior, e o erro do ARMA foi 89% maior que o erro do modelo médias móveis.

Já para os valores do MAPE, pode-se dizer que os erros dos métodos holt-winters e ARMA, foram aproximadamente 49% e 44% maiores que o erro do método médias móveis, respectivamente. Com os valores do MAE, temos que o erro do holt-winters foi aproximadamente 52% maior e também que o erro do ARMA foi aproximadamente 63% maior quando comparados com o erro do modelo médias móveis.

Desta forma, foi possível a executar modelo de média móvel do período 47, que seria o próximo período da previsão. Este modelo está apresentado na equação 10.

$$P_{47} = \frac{D_{46} + D_{45}}{2} \quad (10)$$

Em que P é a previsão, no caso dessa série, para o período 47, D é a demanda real, e o 2 representa o número de períodos anteriores para incluir na média móvel. No caso da série de dados de evaporadores, o $N=2$ foi o intervalo que obteve o melhor ajuste.

5.2 SETOR DE RADIADORES

Os períodos e os métodos de previsão de demanda utilizados para a área de radiadores, que compreende os produtos: aditivo, caixa plástica e radiador, foram os mesmos utilizados para o setor de condicionadores de ar. São eles: médias móveis, Holt-Winters e ARIMA sem diferenciação, conhecido como ARMA.

5.2.1 Modelos de Previsão da demanda de Aditivo

Para a previsão da demanda de aditivo, assim como no setor de condicionadores de ar, foram feitas as previsões dos últimos seis períodos, que correspondem aos meses de outubro de 2018 à março de 2019, e seus resultados são mostrados na Tabela 11 e na Figura 10.

Tabela 11 - Demanda real e prevista de aditivo

| Demanda real | Médias Móveis | Holt-Winters | ARMA |
|--------------|---------------|--------------|------|
| 115 | 97 | 87 | 122 |
| 65 | 90 | 89 | 95 |
| 53 | 59 | 90 | 89 |
| 67 | 60 | 92 | 77 |
| 86 | 77 | 94 | 61 |
| 32 | 59 | 95 | 68 |

Fonte: Autoria própria (2019)

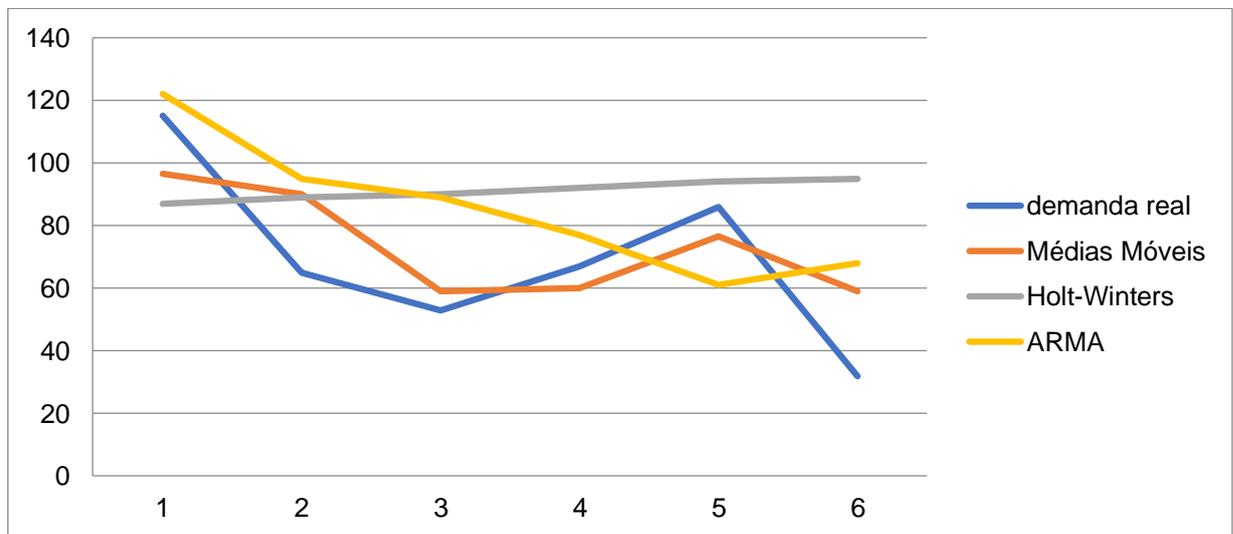


Figura 10 - Gráfico da demanda real e prevista para aditivo

Fonte: Autoria própria (2019)

Uma vez que, a previsão foi realizada, calculou-se os erros desta modelagem e estes são mostrados no Quadro 7.

| | Médias móveis | Holt-Winters | ARMA |
|-------------|---------------|--------------|----------|
| RMSE | 17,661163 | 35,08798 | 26,66458 |
| MAPE | 0,286231 | 0,624288 | 0,461101 |
| MAE | 15,5 | 30,83333 | 24 |

Quadro 7 - Cálculo dos erros das previsões da demanda de aditivo

Fonte: Autoria própria (2019)

De acordo com o Quadro 7, o modelo de melhor ajuste para a série de dados de aditivos foi o de médias móveis, uma vez que, os valores do RMSE se mostraram 98,67% maior para o modelo Holt-Winters e 50,98% maior para o modelo ARMA

Sendo assim, o modelo de médias móveis para o próximo período, que é o de número 45, pode ser descrito pela equação 11.

$$P_{45} = \frac{D_{44} + D_{43}}{2} \quad (11)$$

Em que P é a previsão para o próximo período, D é a demanda real, e o número 2 representa o número de períodos anteriores para incluir na média móvel. Para esta série de dados, $n=2$ foi o intervalo que obteve o melhor ajuste.

5.2.2 Modelos de Previsão da demanda de Caixa Plástica

Para os modelos de previsão de caixa plástica, também foram utilizados os últimos seis períodos, que correspondem aos meses de outubro de 2018 à março de 2019, e seus respectivos resultados podem ser visualizados na Tabela 12 e na Figura 11.

Tabela 12 – Demanda real e prevista para caixa plástica

| Demanda real | Médias Móveis | Holt-Winters | ARMA |
|--------------|---------------|--------------|------|
| 129 | 190 | 209 | 164 |
| 128 | 129 | 179 | 97 |
| 85 | 107 | 159 | 127 |
| 131 | 108 | 127 | 131 |
| 104 | 118 | 128 | 107 |
| 93 | 99 | 116 | 62 |

Fonte: Autoria própria (2019)

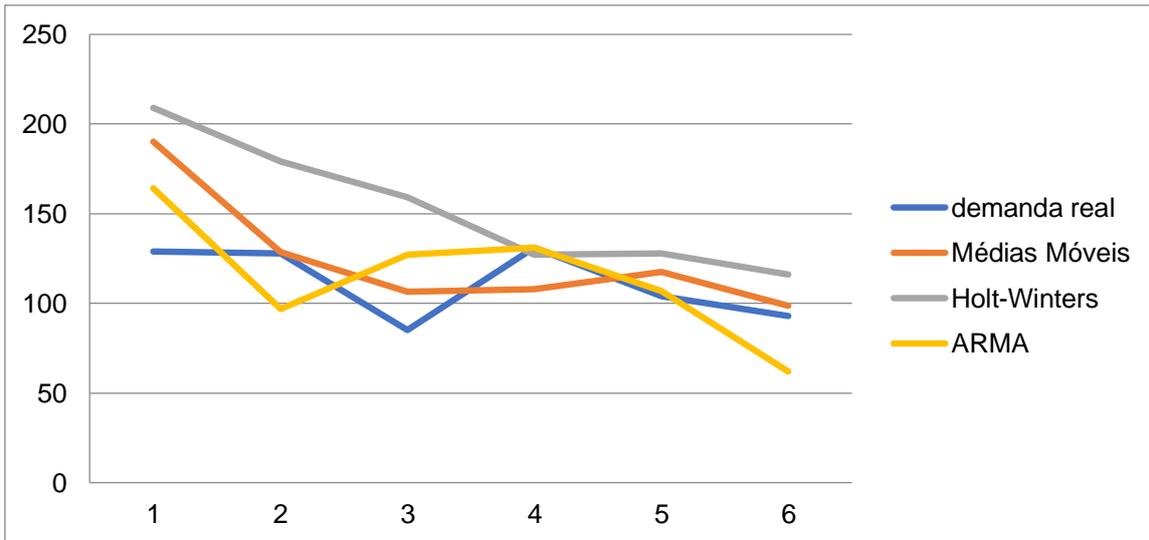


Figura 11 - Gráfico da demanda real e prevista para caixa plástica
Fonte: Autoria própria (2019)

Os erros calculados para estes modelos de previsão podem ser vistos no Quadro 8.

| | Médias móveis | Holt-winters | ARMA |
|-------------|---------------|--------------|----------|
| RMSE | 28,77209 | 50,986926 | 28,63564 |
| MAPE | 0,185701 | 0,399633 | 0,2283 |
| MAE | 21,16667 | 42,666667 | 23,66667 |

Quadro 8 - Cálculo dos erros das previsões da demanda de caixa plástica
Fonte: Autoria própria (2019)

O Quadro 8 mostra que o menor erro calculado para a série de dados de caixa plástica foi o do modelo ARMA, uma vez que, os valores do RMSE se mostraram 0,05% maior para o modelo de Médias móveis e 78,05% maior para o modelo Holt-Winters.

Com base nestes dados, as variáveis e seus respectivos coeficientes, obtidos a partir do Software computacional *Eviews®*, são apresentadas na Tabela 13.

Tabela 13 – Variáveis e coeficientes do modelo ARMA para caixa plástica

| Variável | Coefficiente |
|----------|--------------|
| AR(1) | 0.535546 |
| AR(4) | 0.417950 |
| AR(24) | -0.144636 |

Fonte: Autoria própria (2019)

Sendo assim, um modelo de previsão de demanda pode ser descrito pela equação 12.

$$Z_t = 0.535546Z_{t-1} + 0.417950 Z_{t-4} - 0.144636Z_{t-24} + a_t \quad (12)$$

Em que Z representa o valor da previsão, t representa o seu período e a_t é chamado de resíduo, o qual não é modelável, considera-se que ele tem comportamento totalmente aleatório (média zero e variância constante). Com isso, Z_t representa o valor futuro que se deseja prever, Z_{t-1} , Z_{t-4} , Z_{t-24} representam seus valores históricos e a_t representa o resíduo do modelo, com média zero e variância constante.

5.2.3 Modelos de Previsão da demanda de radiador

Assim como feito para as previsões da demanda de aditivo e caixa plástica, os modelos de previsão da demanda de radiador utilizaram os mesmos métodos e os mesmos períodos.

Os dados de demanda real e demanda prevista para este produto são demonstrados na Tabela 14 e na Figura 12.

Tabela 14 - Demanda real e prevista para radiador

| Demanda real | Médias Móveis | Holt-Winters | ARMA |
|---------------------|----------------------|---------------------|-------------|
| 106 | 150 | 96 | 124 |
| 84 | 95 | 96 | 98 |
| 111 | 98 | 96 | 108 |
| 94 | 103 | 96 | 96 |
| 104 | 99 | 97 | 88 |
| 62 | 83 | 97 | 89 |

Fonte: Autoria própria (2019)

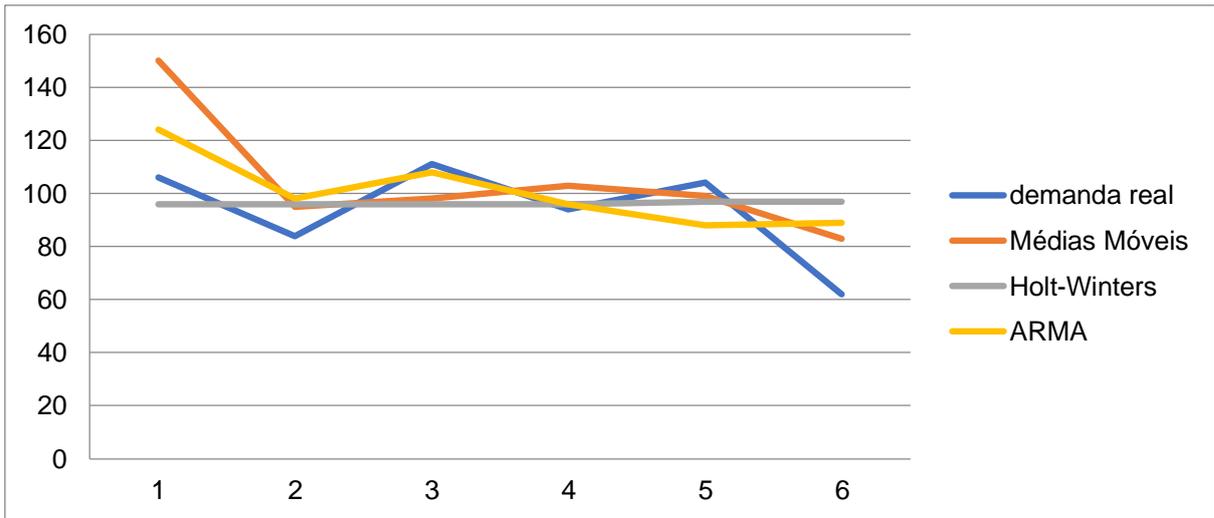


Figura 12 - Gráfico da demanda real e prevista para radiador
Fonte: Autoria própria (2019)

Com os modelos de previsão de demanda calculados, foi possível obter os erros desta modelagem, que estão apresentados no Quadro 9.

| | Médias móveis | Holt-winters | Arma |
|-------------|---------------|--------------|----------|
| RMSE | 21,49806 | 17,06361 | 15,90597 |
| MAPE | 0,169121 | 0,120649 | 0,119178 |
| MAE | 20,33333 | 15,16667 | 14,83333 |

Quadro 9 - Cálculo dos erros das previsões da demanda de radiador
Fonte: Autoria própria (2019)

De acordo com o Quadro 9, o modelo de melhor ajuste para a série de dados de aditivos foi o ARMA, já que, os valores do RMSE se mostraram 7,28% maior para o modelo Holt-Winters e 35,16% maior para o modelo de Médias móveis.

Sendo assim, um modelo ARMA para o próximo período pode ser descrito pela equação 13.

$$Z_t = 1,258137Z_{t-1} - 0,258169Z_{t-2} + a_t - 0,848367a_{t-1} \quad (13)$$

Em que Z representa o valor da previsão, t representa o seu período e a_t é chamado de resíduo, o qual não é modelável, considera-se que ele tem comportamento totalmente aleatório (média zero e variância constante). Com isso, Z_t representa o valor futuro que se deseja prever, Z_{t-1} , Z_{t-2} , representam seus

valores históricos, $\alpha_{t-1}, \alpha_{t-2}$ representam os erros históricos e a_t representa o resíduo do modelo, com média zero e variância constante.

6 CONSIDERAÇÕES FINAIS

Com a previsão de demanda, é possível ter uma estimativa do comportamento do mercado, o que influencia diretamente em todas as decisões estratégicas e de planejamento em uma cadeia de suprimentos. Para Fernandes e Filho (2010) as previsões têm papel fundamental no ambiente competitivo, guiando a empresa para o planejamento estratégico da produção, finanças e vendas.

Para o caso da empresa estudada, é necessário que haja uma reposição de estoque periodicamente e ter um estoque baixo é fundamental para a minimização de gastos, portanto, a previsão de demanda servirá como base.

Para a elaboração deste trabalho, a empresa foi dividida entre os setores de condicionadores de ar e de radiadores. A partir disto, foram selecionados os três produtos mais vendidos nos últimos quatro anos, foram então quantificados, resultando em 6 séries de dados. No geral, as séries apresentam um comportamento com baixa estrutura de dependência ou padrões temporais. Com isso, foi realizado um comparativo entre alguns métodos de previsão de demanda, sendo eles: Médias móveis, Holt-Winters e ARMA.

No geral, as seis séries temporais apresentaram um comportamento com baixa estrutura de dependência ou padrões temporais. Acredita-se que, com uma quantidade maior de dados, é possível de se obter modelos que melhor representem a estrutura de dependência destes dados.

A partir desta análise, foram obtidos e escolhidos os três modelos para cada produto, tendo como base o menor erro no ajuste (modelagem). O modelo com melhor ajuste para condensador, caixa plástica e radiador foi o ARMA, já para os demais equipamentos, sendo eles compressor, evaporador e aditivo, o modelo que mais se ajustou foi o Médias móveis.

Sendo assim, pode-se concluir que o baixo custo de utilização do modelo de previsão, a praticidade, seu uso e sua importância fazem com que o uso desta ferramenta tenha um alto custo/benefício. A possibilidade de se fazer previsões para cada mês de venda torna-se uma boa estratégia para a organização, podendo proporcionar melhorias na empresa e menores custos, obtendo uma vantagem competitiva em relação aos demais concorrentes.

REFERÊNCIAS

- ADOLFINO NETO. **A Gestão da Cadeia de Suprimentos (SCM) no Brasil**. 2016. Disponível em: <<https://adolfinoneto.com/2016/09/05/a-gestao-da-cadeia-de-suprimentos-scm-no-brasil/>>. Acesso em: 10 out. 2018.
- ALBUQUERQUE, J. S.; SERRA, C. M. V. **Utilização de modelos de holt-winters para a previsão de séries temporais de consumo de refrigerantes no Brasil**. In: Encontro Nacional De Engenharia De Produção ENEGEP, 24, 2006, Fortaleza. Anais. Fortaleza: Abepro, 2006. p. 1 - 5. Disponível em: <http://www.abepro.org.br/biblioteca/enegep2006_tr460317_7576.pdf>. Acesso em: 06 out. 2018.
- ANDRADE, M. G.; REIS, R. L. dos; SOARES, S.; SILVA FILHO, D. da. **Análise do erro de previsão de vazões mensais com diferentes horizontes de previsão**. Controle e Automação, Campinas, v. 23, n. 3, p. 294-305, 2012. São Paulo: Atlas, 2009.
- BALLOU, R. H. **Gerenciamento da cadeia de suprimentos/logística empresarial**. 5. ed. Porto Alegre: Bookman, 2006.
- BOX, G.E.P.; JENKINS, G.M.; REINSEL, G.C. **Time Series Analysis: Forecasting and Control**. 3. ed. Englewood Cliffs: Prentice Hall, 1994.
- BUENO, R. L. S. **Econometria de Séries Temporais**. São Paulo: Cengage Learning, 2008.
- CARVALHO, C. A. V. **Análise de Previsão de Itens de Demanda Intermitente Utilizando o Modelo SyntetosBoylanApproximation (SBA)**. XXXVI ENCONTRO DA ANPAD. Rio de Janeiro/RJ: 2012.
- CHATFIELD, C. **The Analysis of Time Series: An Introduction**. 5.ed., Washington: Chapman e Hall, 1996.
- CHOPRA, S.; MEINDL, P. **Gestão da cadeia de suprimentos: Estratégia, Planejamento e Operações**. 4.ed. São Paulo: Pearson Prentice Hall, 2011.
- CORREA, H. L.; CORREA, C. A.; **Administração de produção e operações: Manufatura e serviços: uma abordagem estratégica**. São Paulos: Atlas, 2012.
- DAVIS, M. M.; AQUILANO, N. J.; CHASE, R. B. **Fundamentos da administração da produção**. 3. ed. Porto Alegre: Bookman, 2001.
- EDIGER, V. Ş.; AKAR, S. **ARIMA forecasting of primary energy demand by fuel in Turkey**. Energy Policy, v. 35., Elsevier BV, 2007.
- FERNANDES, F. C. F.; GODINHO FILHO, M. **Planejamento e controle da produção: Dos fundamentos ao essencial**. 1. Ed. São Paulo: Atlas, 2010.

- GIL, A. C. **Métodos e técnicas de pesquisa social**. 6. ed. - São Paulo: Atlas, 2008.
- GOODWIN, P.; LAWTON, R. **On the asymmetry of the symmetric MAPE**. *International journal of forecasting*, v. 15, p. 405-408, 1999.
- GUJARATI, D. N.. **Econometria basica**. São Paulo: Makron Books, 2000.
- KAUARK, F; MANHÃES, F. C.; MEDEIROS, C. H.. **Metodologia da pesquisa: guia prático**. Bahia: Via Litterarum, 2010.
- KRAJEWSKI, L.; RITZMAN, L.; MALHOTRA, M. **Administração de produção e operações**. São Paulo: Person Prentice Hall, 2009.
- LUSTOSA, L. J.; MESQUITA, M.; QUELHAS, O. L. G.; OLIVEIRA, R. J. **.Planejamento e Controle da Produção**. Rio de Janeiro: Elsevier, 2008.
- MADDALA, G. S. **Introdução a econometria**. 3. ed. Rio de Janeiro: LTC, 2003.
- MARTINS, P. G.; LAUGENI, F. P. **Administração da produção**. São Paulo: Saraiva, 2005.
- MONTGOMERY, D. C.; JENNINGS, C. L.; KULACHI, M. **Introduction to Time Series Analysis and Forecasting**. Nova Jersey: John Wiley e Sons, 2008.
- MOREIRA, D. A. **Administração da Produção e Operações**. 2. ed. São Paulo: Cengage Learning, 2008.
- MORETTIN, P. A.; TOLOI, C. M. C. **Análise de Séries Temporais**. São Paulo. Edgar Blucher, 2006.
- MOURA, R. G.; HERDIES, D.L.; MENDES, D.; MENDES, M. C. D. **Avaliação do modelo regional ETA utilizando as análises do CPTEC e NCEP**. *Rev. bras. meteorol.* v.25, n.1, São Paulo: 2010.
- MUELLER, A. **Uma aplicação de redes neurais artificiais na previsão do mercado acionário**. Dissertação (Mestrado em Engenharia de Produção) – Programa de Pós-graduação em Engenharia de Produção, UFSC, Florianópolis, 1996.
- PACHECO, R. F.; SILVA, A. V. F. **Aplicação de modelos quantitativos de previsão em uma empresa de transporte ferroviário**. XXIII ENCONTRO NAC. DE ENG. DE PRODUÇÃO, Ouro Preto/MG: 2003.
- PEGELS, E. M. C. C. **An Approach for Selecting Times Series Forecasting Models**, *International Journal of Operations & Production Management*, v. 10, Iss 3, p. 50 – 60, 1990.
- PEINALDO, J.; GRAEML, A. R. **Administração da produção: operações industriais e de serviços**. 1. ed. Curitiba: Unicenp, 2007.

PELLEGRINI, F.R.; FOGLIATTO, F. **Estudo comparativo entre modelos de Winters e de Box- Jenkins para a previsão de demanda sazonal**. Revista Produto & Produção. Vol. 4, número especial, p.72-85. 2000.

PRODANOV, C. C.; FREITAS, E. C.. **Metodologia do trabalho científico: métodos e técnicas da pesquisa e do trabalho acadêmico**. 2. ed. Rio Grande do Sul Feevale, 2013.

RAGSDALE, C. T. **Modelagem e Análise de Decisão**. São Paulo: Cengage Learning, 2009.

SIMCHI-LEVI, D.; KAMINSKY, P.; SIMCHI-LEVI, E. **Cadeia de Suprimentos: projeto e gestão**. 3 ed. Porto alegre: Bookman, 2010.

SLACK, N.; CHAMBERS,S.; JOHNSTON, R. **Administração da Produção**. 3 ed. São Paulo: Atlas, 2009.

STEVENSON, W. J. **Administração das Operações de Produção**. 6. ed. Rio de Janeiro: LTC, 2001.

TUBINO, D. F. **Planejamento e Controle da Produção: teoria e prática**. 2. ed. São Paulo: Atlas, 2009.

VIANNA, C. T. **Classificação das Pesquisas Científicas: Notas para os alunos**. Florianópolis, 2013, 2p. Disponível em: <pt.slideshare.net >. Acesso em: 08 out. 2018.

VIVALDINI, M.; PIRES, S. R. I.; **Operadores logísticos: integrando operações em cadeias de suprimento**. São Paulo: Atlas, 2010.