

CENTRO ACADÊMICO DO AGRESTE  
NÚCLEO DE CIÊNCIA E TECNOLOGIA  
ENGENHARIA DE PRODUÇÃO

JOSÉ JAVAN NEVES SILVA

**UTILIZAÇÃO DA METODOLOGIA BOX-JENKINS OU *SEASONAL*  
*AUTOREGRESSIVE INTEGRATED MOVING AVERAGE* (SARIMA) PARA A  
PREVISÃO DE VENDAS DE ACUMULADORES EM UMA INDÚSTRIA DE  
ACUMULADORES DO INTERIOR DE PERNAMBUCO**

CARUARU

2018

JOSÉ JAVAN NEVES SILVA

**UTILIZAÇÃO DA METODOLOGIA BOX-JENKINS OU *SEASONAL*  
*AUTOREGRESSIVE INTEGRATED MOVING AVERAGE* (SARIMA) PARA A  
PREVISÃO DE VENDAS DE ACUMULADORES EM UMA INDÚSTRIA DE  
ACUMULADORES DO INTERIOR DE PERNAMBUCO**

Trabalho de Conclusão de Curso apresentado a(o) Coordenação/Núcleo do Curso de Engenharia de Produção do Centro Acadêmico do Agreste da Universidade Federal de Pernambuco, para obtenção parcial da graduação/licenciatura em Engenharia de Produção.

Orientador: Prof. Dr. Rodrigo Sampaio Lopes

CARUARU

2018

Catálogo na fonte:  
Bibliotecária – Simone Xavier - CRB/4 - 1242

S586u Silva, José Javan Neves.  
Utilização da metodologia box-jenkins ou seasonal autoregressive integrated moving average (sarima) para a previsão de vendas de acumuladores em uma indústria de acumuladores do interior de Pernambuco. / José Javan Neves Silva. - 2018.  
53f.; il.: 30 cm.

Orientador: Rodrigo Sampaio Lopes.  
Monografia (Trabalho de Conclusão de Curso) – Universidade Federal de Pernambuco, CAA, Engenharia de produção, 2018.  
Inclui Referências.

1. Demanda. 2. Logística. 3. Planejamento. 4. Previsão de vendas. I. Lopes, Rodrigo Sampaio (Orientador). II. Título.

658.5 CDD (23. ed.) UFPE (CAA 2018-071)

**JOSÉ JAVAN NEVES SILVA**

**UTILIZAÇÃO DA METODOLOGIA BOX-JENKINS OU *SEASONAL AUTOREGRESSIVE INTEGRATED MOVING AVERAGE* (SARIMA) PARA A PREVISÃO DE VENDAS DE ACUMULADORES EM UMA INDÚSTRIA DE ACUMULADORES DO INTERIOR DE PERNAMBUCO**

Trabalho de Conclusão de Curso  
apresentado à coordenação do Curso de  
Engenharia Produção do Centro Acadêmico  
do Agreste - CAA, da Universidade Federal  
de Pernambuco - UFPE, em cumprimento  
às exigências para obtenção do grau de  
Bacharel em Engenharia de Produção.

**Área de concentração: Logística**

**A banca examinadora, composta pelos professores abaixo, considera o candidato  
APROVADO com nota 9,5.**

**Caruaru, 09 de Julho de 2018**

**Banca examinadora:**

**Prof. Rodrigo Sampaio Lopes** \_\_\_\_\_

**Universidade Federal de Pernambuco – UFPE (Orientador)**

**Prof. Thales Vitelli Garcez** \_\_\_\_\_

**Universidade Federal de Pernambuco – UFPE (Avaliador)**

**Prof. Lucimário Gois** \_\_\_\_\_

**Universidade Federal de Pernambuco – UFPE (Avaliador)**

**Prof. Dr. Thalles Vitelli Garcez:** \_\_\_\_\_

**Universidade Federal de Pernambuco – UFPE (Coordenador da disciplina de TCC)**

## AGRADECIMENTOS

Agradeço a Deus por estar ao meu lado durante todas as fases de minha vida, agradeço a Ele pelo discernimento do que é certo e errado, pela determinação para enfrentar as dificuldades e pela felicidade que me foi proporcionada na superação de desafios.

Por este trabalho de conclusão, agradeço especialmente as pessoas que presentes durante a minha graduação acreditaram na minha capacidade de realização e nas quais foram essenciais para o desenvolvimento do trabalho apresentado.

Agradeço, portanto, a minha família pela base sólida e estrutura na qual obtive grande desenvolvimento pessoal, acadêmico e profissional e que pelo esforço a mim direcionado pude ascender socialmente.

Aos meus amigos que próximos ou distantes contribuíram para a construção de uma memória rica em experiência, aprendizado e afeto.

Agradeço também a minha namorada pela paciência e incentivo nas fases de construção deste trabalho e principalmente por torcer e vibrar com minhas conquistas.

À Ciclo Consultoria, empresa na qual obtive grande desenvolvimento e me tornei mais preparado para o mercado de trabalho.

Agradeço também ao meu professor orientador que além de orientador, foi guia e conselheiro em minhas tomadas de decisões.

Por fim agradeço à Universidade Federal de Pernambuco e à *National University of Ireland – Galway* por toda a qualidade e bagagem acadêmica que recebi e pude desenvolver durante esta fase de minha vida.

## RESUMO

Planejar é importante, levando a redução da incerteza dentro de uma cadeia de suprimentos, influencia o nível de serviço, os custos logísticos, custos operacionais, congelamento de capital, ou a margem de lucro de um simples ou até mesmo de um conjunto de produtos dentro de um setor produtivo. Um mau planejamento pode vir a gerar ociosidade ou até mesmo sobrecarga na produção, diminuição da colaboratividade entre departamentos, e tantos outros tantos resultados prejudiciais. Portanto, uma ótima resposta para uma tomada de decisão eficiente é o planejamento de curto, médio ou longo prazo. Seguindo este pensamento apresenta-se neste trabalho uma das ferramentas para o alcance de um planejamento eficiente: a previsão de demanda. A aplicação da previsão de demanda é desdobrada neste trabalho através da utilização do modelo SARIMA (Seasonal Autoregressive Integrated Moving Average) através da metodologia desenvolvida por Box-Jenkins. A metodologia é empregada em uma indústria de acumuladores elétricos no interior de Pernambuco com o objetivo de desenvolver, estudar e sugerir a aplicação do SARIMA como mais uma ferramenta no campo do planejamento das operações, buscando a melhoria contínua e o aumento da acurácia de previsões dentro das rotinas táticas e estratégicas dos departamentos envolvidos.

**Palavras-Chave:** Previsão de demanda, Logística, ARIMA, SARIMA, Box-Jenkins, Planejamento.

## **ABSTRACT**

The planning process is important, it leads a supply chain to reduce the uncertainty, influences the service level, logistics costs, operational costs, capital freeze, profit margin or even a set of products within a productive sector. Bad planning may lead to idleness or even overproduction, reduced collaboration among departments and many other damaging results. Therefore, a great response to an efficient decision making is short, medium, or long term planning. Following this thought, it is presented in this work one of the tools to reach an efficient planning: demand forecasting. The application of demand forecast is deployed in this work through the use of the SARIMA (Seasonal Autoregressive Integrated Moving Average) through a methodology developed by Box-Jenkins. This methodology is applied in an electric accumulator industry situated on the estate of Pernambuco has the aim to develop, study, suggest the application of SARIMA as another tool on the field of operations planning, searching for continuous improvement and higher levels of accuracy within the tactical and strategic routines of the departments involved.

**Key words:** Demand forecasting, logistics, ARIMA, SARIMA, Box-Jenkins, planning.

## LISTA DE FIGURAS

Figura 2.3.1.1 – Custo de Previsão x Custo de Inexatidão.....	18
Figura 3.1 Metodologia Simplificada da Pesquisa.....	32
Figura 4.1.2 - Custo de Previsão x Custo de Inexatidão para uma previsão de médio alcance.....	34
Figura 4.1.3 - Venda total de acumuladores elétricos por ano.....	34
Figura 4.1.5 - Função de Autocorrelação para a série temporal original.....	35
Figura 4.1.6 - Função de Autocorrelação para a série temporal original com 60 defasagens.....	37
Figura 4.1.7 - Série temporal original transformada através do logaritmo neperiano.....	37
Figura 4.1.8 - Série temporal original transformada através do logaritmo neperiano e da diferenciação de grau 1 ( $d=1$ ).....	37
Figura 4.1.9 - Função de Autocorrelação para a série temporal transformada.....	38
Figura 4.1.10 - Função de Autocorrelação para a série temporal transformada em $\ln(x)$ e $D(-1)$ com 60 defasagens.....	39
Figura 4.1.11- Função de Autocorrelação para a série temporal transformada.....	40
Figura 4.1.12 - Correlograma de autocorrelação parcial para a série temporal transformada em $\ln(x)$ e $D(-1)$ – 60 defasagens.....	40
Figura 4.1.13 - Correlograma da função de autocorrelação (FAC) para a série temporal transformada em $\ln(x)$ $d(-1)$ e $d(-12)$ com 60 defasagens.....	41
Figura 4.1.14 - Correlograma da função de autocorrelação (FACp) para a série temporal transformada em $\ln(x)$ $d(-1)$ e $d(-12)$ com 60 defasagens.....	42
Figura 4.2.4 - Função de Autocorrelação dos Resíduos para o modelo ARIMA SARIMA (1,1,0) (3,1,0) <sub>12</sub> .....	44
Figura 4.2.5 - Histograma da distribuição normal para os resíduos do modelo SARIMA (1,1,0) (3,1,0) <sub>12</sub> .....	44
Figura 4.2.6 - Distribuição normal para os resíduos do modelo SARIMA (1,1,0) (3,1,0) <sub>12</sub> .....	45
Figura 4.2.9 - Previsão de demanda para o modelo ARIMA (1,1,0)(3,1,0) <sub>12</sub> .....	46

## LISTA DE TABELAS

Tabela 2.3.1.2 Resumo das técnicas de previsão.....	20
Tabela 2.4.1.2.3.2 Padrões teóricos para FAC e FACP.....	29
Tabela 4.1.1 Venda de acumuladores para o período em estudo.....	33
Tabela 4.1.2 Parâmetros para o modelo SARIMA (4,1,0) (3,1,0) <sub>12</sub> .....	42
Tabela 4.1.3 Parâmetros para o modelo SARIMA (1,1,0) (3,1,0) <sub>12</sub> .....	43
Tabela 4.1.4 Previsão de venda de acumuladores elétricos para o período $t_{120} + 12$ .....	45
Tabela 4.2.1 – Acurácia para o modelo SARIMA (1,1,0) (3,1,0) <sub>12</sub> .....	47
Tabela 4.2.2 – Acurácia ajustada para o modelo SARIMA (1,1,0) (3,1,0) <sub>12</sub> .....	48

## SUMÁRIO

<b>1 INTRODUÇÃO</b> .....	<b>10</b>
1.1 OBJETIVOS .....	10
<b>2 REFERENCIAL TEÓRICO</b> .....	<b>12</b>
2.1 LOGÍSTICA .....	12
2.2 CADEIA DE SUPRIMENTOS .....	13
2.2.1 FASES DAS DECISÕES DENTRO DA CADEIA DE SUPRIMENTOS .....	15
2.2.1.1 Estratégia ou projeto da cadeia de suprimentos .....	15
2.2.1.2 Planejamento da cadeia de suprimentos .....	15
2.2.1.3 Operação da cadeia de suprimentos .....	15
2.3 PREVISÃO DE DEMANDA .....	16
2.3.1 MÉTODOS DE PREVISÃO .....	18
2.4 METODOLOGIA BOX-JENKINS OU AUTOREGRESSIVE INTEGRATED MOVING AVERAGE (ARIMA) .....	22
2.4.1 MODELOS ESTACIONÁRIOS .....	23
2.4.1.1 Modelos autorregressivos (AR) .....	24
2.4.1.2 Modelos de médias móveis (AM) .....	25
2.4.1.3 Modelos ARMA .....	25
2.4.1.4 Modelos não estacionários .....	26
2.4.1.4.1 Modelos ARIMA .....	26
2.4.1.4.2 Modelos Sazonais SARIMA .....	27
2.4.1.2.3 Etapas para a construção do modelo ARIMA. A metodologia Box-Jenkins .....	28
<b>3 METODOLOGIA</b> .....	<b>31</b>
<b>4 ESTUDO DE CASO</b> .....	<b>33</b>
4.1 APLICAÇÃO DA METODOLOGIA BOX-JENKINS .....	33
4.1.1 FASE DE IDENTIFICAÇÃO .....	34
4.1.2 FASE DE ESTIMAÇÃO .....	42
4.1.3 VERIFICAÇÃO DE DIAGNÓSTICO .....	43
4.1.4 PREVISÃO .....	45
4.2 ANÁLISE DE ERROS E ADAPTAÇÃO DO MODELO .....	46
4.3 IMPLICAÇÕES GERENCIAIS .....	48
<b>5 CONCLUSÃO</b> .....	<b>50</b>
<b>REFERÊNCIAS</b> .....	<b>52</b>

## 1 INTRODUÇÃO

Empresas modernas precisam lidar com novas tecnologias e uma competição em escala global diariamente. O ambiente na qual as empresas estão inseridas estão se tornando progressivamente mais dinâmicos, competitivos e com barreiras cada vez menores. Tais fatores tornam a tomada de decisão mais difícil e crítica dentro de uma empresa e conseqüentemente em toda uma cadeia logística (TSENG et al., 2002).

Gerentes, diretores, analistas, economistas ou empresários consideram quase que em todas as suas decisões alguma espécie de previsão. Hoje em dia, previsões de demanda, tendências e estudos de sazonalidade não são mais considerados itens de luxo, mas de necessidade. As previsões podem ajudar os executivos a tomarem decisões e quanto maior o entendimento sobre os princípios de previsão, tais como qual a melhor política de previsão de acordo com o horizonte de planejamento, necessidades de consumo, esforço necessário e eficiência requerida, melhor será o desempenho do tomador de decisão no ambiente corporativo (CHAMBERS et al., 1976).

Como já citado uma eficiente previsão de demanda é fundamental para o desenvolvimento e evolução do planejamento e das operações, assim como o entendimento das necessidades e demanda dos clientes. A análise das séries temporais é um dos métodos no qual se é possível utilizar a predição de demanda a favor das tomadas de decisão, portanto o estudo de uma série temporal sazonal (SARIMA) através da metodologia apresentada inicialmente por Box-Jenkins é sugerida e apresentada no decorrer deste trabalho, uma vez que tal metodologia vem sendo aplicados com sucesso em campos econômicos, de marketing, problemas sociais e industriais (BOX & JENKINS, 1976).

Com o entendimento dos conceitos de logística, previsão de demanda e os resultados obtidos com o modelo obtido sugere-se a aplicação da metodologia em futuras aplicações de planejamento e operações.

### 1.1 Objetivos

O objetivo geral deste trabalho é construir um modelo de previsão baseado na média móvel integrada ao autorregressivo a partir da metodologia desenvolvida por Box-Jenkins com o intuito de criar mais um parâmetro quantitativo para estudos de planejamento e de demanda relacionada à venda de acumuladores elétricos objetivando aumentar a qualidade de decisões tomadas a nível tático e estratégico e por conseqüência diminuir o efeito negativo de más decisões na cadeia de suprimentos como um todo.

Em linhas gerais foi utilizado o número de venda total de acumuladores elétricos para um determinado cliente com o intuito de verificar e analisar a capacidade da metodologia ARIMA em se adequar com a série temporal apresentada neste trabalho, e por consequência com outras series temporais derivadas e de mesma natureza que possam ser observadas e desenvolvidas.

Para este projeto, foi utilizada uma visão consolidada da venda de todas as baterias sem distinção de tipo, família, classe ou mercado de destino. É nossa intenção criar e validar um modelo base de caráter quantitativo que possa ser aperfeiçoado e expandido com o intuito de criar mecanismos alternativos que se somem as ferramentas atualmente utilizadas pelo departamento de planejamento da empresa em estudo.

Para o alcance dos objetivos citados anteriormente, são traçados os seguintes objetivos específicos:

- Definir a problemática a ser explorada e o alcance do modelo;
- Coletar dados para a aplicação da metodologia;
- Modelar o problema de acordo com o referencial teórico;
- Definir os parâmetros do modelo;
- Analisar a aderência do modelo testando a robustez dos resultados obtidos;
- Realizar previsões para os próximos períodos;
- Validar e sugerir a utilização do modelo para o departamento de planejamento e operações.

## 2 REFERENCIAL TEÓRICO

### 2.1 Logística

Ballou (2001) define a logística como todas as atividades de movimentação e armazenagem que tem por objetivo facilitar o fluxo de bens desde o ponto de aquisição da matéria prima até o ponto de consumo, além dos fluxos de informação necessários para se colocar os produtos em movimento, com a intenção de atender aos níveis de serviço adequados relacionados a clientes internos ou externos a um custo razoável.

A tipificação anterior identifica atividades primárias para o alcance dos objetivos logísticos de custo e nível de serviço, são elas:

- Transportes: estudo dos métodos para se movimentar produtos. Decisões ligadas normalmente a modais de transporte, rotas de distribuição e a utilização de suas capacidades.
- Manutenção de estoques: decisões relacionadas aos níveis de estoque e gerenciamento de provisões. Estoques agem como amortecedores entre a oferta e a demanda e agregam o valor de ‘tempo’ aos produtos da empresa, enquanto que o transporte agrega o valor de ‘lugar’.
- Processamento de pedidos: é um elemento altamente crítico em termos de tempo no que se diz respeito ao tempo necessário para se levar um produto a um cliente. O processamento de pedidos é também a atividade primária que dá início ao fluxo de pedidos, movimentando os produtos durante todo o processo logístico (BALLOU, 2001).

Tais atividades são consideradas primárias porque elas representam a maior parcela do custo total da logística ou são essenciais para o cumprimento das operações. Além das atividades primárias é necessário considerar também as atividades e operações adicionais que compõem as atividades primárias, são elas:

- Armazenagem;
- Manuseio de materiais;
- Embalagens;
- Programação de produtos;
- Manutenção da informação.

Ballou cita também que a Logística como objeto de estudo pode ser dividida em 4 fases de acordo com sua maturidade e evolução. São elas:

- I. Até 1950 - fase latente: Apenas as atividades primárias da logística como o transporte e alguns conceitos de controle de estoque eram utilizadas. Havia pouquíssimo ou nenhum elo entre outros participantes da cadeia logística e não existia nenhuma filosofia dominante para guiar as empresas.
- II. 1970 a 1990 – fase de semi-maturidade: Com a explosão da tecnologia da informação (TI) houve muito desenvolvimento da teoria e prática da logística acarretando em redução de custos e alguns sistemas integrados.
- III. Pós 1990: Primeiros conceitos sobre cadeia de suprimentos apareceram além da integração de processos desde os fornecedores primários aos consumidores finais.
- IV. Atualmente: Surgimento do conceito de cadeias de suprimentos cada vez mais fechadas, rápidas, com pouca variabilidade no número de participantes e com novas frentes, como serviços.

Com a evolução dos conceitos logísticos, diversos pontos foram sendo introduzidos nas metodologias. O aprimoramento e o estudo de diversos conceitos contribuíram positivamente para uma melhor eficiência logística e a confirmação de que uma boa administração é essencial para a perpetuação e sustentabilidade dos negócios empresariais.

Em resumo, a logística empresarial, através da administração de materiais e da distribuição física, busca garantir que os níveis de serviço desejados sejam alcançados, providenciando produtos ou serviços no lugar certo, no momento certo e na exata condição desejada ao menor custo possível (BALLOU, 2001). A era da logística empresarial já está em curso e o desenvolvimento das cadeias de suprimento ao lado das funções do marketing e produção é um fator cada vez mais importante.

## **2.2 Cadeia de suprimentos**

Uma cadeia de suprimentos consiste de todas as partes envolvidas diretamente ou indiretamente em atender as necessidades dos diversos clientes. Na cadeia de suprimentos não só estão incluídos fornecedores e fabricantes, mas também as empresas transportadoras de mercadoria, armazéns, centros de distribuição, revendedores e até os próprios clientes. Inclusive, dentro de cada um destes participantes da cadeia todas as atividades e operações logísticas citadas no tópico anterior estão presentes, assim como as funções de marketing,

operações, finanças e o atendimento ao consumidor (CHOPRA et al., 2013). A cadeia de suprimentos é então um fluxo constante de informações, produtos e capital entre diferentes estágios.

Em suma, o objetivo de cada cadeia de suprimentos deve ser maximizar as saídas e o seu valor global agregado, também conhecido como excedente da cadeia de suprimentos. Na cadeia de suprimentos este valor excedente será representado pela diferença entre o que é o valor final do produto para o consumidor e os custos associados no atendimento ao nível de serviço do cliente (CHOPRA et al., 2013).

$$\textit{Excedente da Cadeia de Suprimentos} = \textit{Receita Gerada Pelo Cliente} - \textit{Custo da Cadeia de Suprimentos}.$$

O valor percebido pelo cliente final poderá variar de cliente para cliente e pode ser estimado pelo preço máximo que um cliente está disposto a pagar por determinado produto. O restante do excedente da cadeia de suprimentos é a lucratividade da cadeia de suprimentos, ou seja, a diferença entre as receitas geradas pelo consumidor e os custos dentro da cadeia de suprimentos (CHOPRA et al., 2013).

O sucesso de uma cadeia de suprimentos deve ser medido em termos de rentabilidade da cadeia de suprimentos como um todo e não apenas como um indivíduo individual dentro da cadeia. Uma metodologia focada em aumentar a rentabilidade de toda a cadeia de suprimento fará com que os diversos participantes da cadeia de suprimentos busquem aumentar a sua participação média nos ganhos.

Tendo definido o sucesso de uma cadeia de suprimentos e sabendo que os membros da cadeia de suprimentos buscarão aumentar a fatia de seu lucro, é necessário olhar para o próximo passo, analisar, estudar e definir as origens dos valores agregados, vendas e custos dentro da cadeia. Sabendo que a única receita obtida dentro de uma cadeia de suprimentos vem do consumidor é necessário entender como todos os outros fluxos de informação, produtos e os próprios participantes da cadeia irão gerar os custos.

Portanto, a administração apropriada destes fluxos será a chave para o sucesso da cadeia de suprimento que por sua vez está ligada diretamente a um conjunto de decisões que devem ser tomadas em diversos níveis ao longo dela própria. As decisões por si só e seus impactos podem variar por uma diversidade de razões. Para que o impacto seja o mais positivo possível, as empresas vêm construindo e se consolidando no mercado através de decisões acerca do design, planejamento e operações dentro da cadeia de suprimentos, tais decisões são mais bem explicadas a seguir. (CHOPRA et al., 2013).

## 2.2.1 FASES DAS DECISÕES DENTRO DA CADEIA DE SUPRIMENTOS

### 2.2.1.1 *Estratégia ou projeto da cadeia de suprimentos.*

Nesta fase é definido como será a configuração da cadeia a partir de um horizonte de planejamento de longo prazo, decisões acerca de como recursos serão alocados e quais processos cada estágio deve realizar. Decisões estratégicas estão relacionadas à terceirização ou não de operações, localização, capacidade de operações das instalações relacionados a produção e armazenagem, quais tipos de produtos serão produzidos, modais de transporte utilizados para transporte interno ou externo e qual o tipo de sistema de informação utilizados são exemplos de decisões a serem tomadas. A empresa ao tomar tais decisões tem que garantir que o arranjo da cadeia suporte os objetivos estratégicos e aumente o excedente da cadeia (CHOPRA et al., 2013).

### 2.2.1.2 *Planejamento da cadeia de suprimentos*

Decisões tomadas nesta fase possuem geralmente um horizonte entre um trimestre a um ano, consistem em estabelecer restrições dentro dos quais o planejamento será feito com o objetivo de maximizar o excedente dadas as restrições da fase anterior. Decisões acerca do planejamento estão relacionadas a quais mercados locais serão abastecidos, subcontratação da manufatura, políticas de estoque, duração e tamanho das campanhas de marketing e decisões de preço (CHOPRA et al., 2013).

É necessário incluir neste ponto decisões relacionadas à demanda e suas incertezas, dado um período mais curto e em posse de melhores previsões do que na fase de projeto da cadeia é imprescindível a incorporação da flexibilidade embutida na cadeia e também a posse de dados confiáveis e estruturados para a tomada de decisão. Como resultado a empresa é capaz de fornecer e definir um conjunto de políticas operacionais que controlarão as operações (CHOPRA et al., 2013).

### 2.2.1.3 *Operação da cadeia de suprimentos*

Com decisões relacionadas a um horizonte de tempo semanal ou diário as empresas tomam decisões relacionadas aos pedidos individuais dos clientes. Neste nível operacional a

configuração da cadeia é considerada fixa e as políticas de planejamento já devem estar definidas. Nas decisões de operação o objetivo é garantir o nível de serviço adequado ao cliente, atendendo aos pedidos da melhor forma possível através de operações eficientes relacionadas ao estoque, produção de pedidos individuais, definição de prazo no qual o pedido será atendido, listas de separação e armazenagem, meio de transporte particular e prazos de entrega (CHOPRA et al., 2013).

Como notado, a maioria das decisões em uma cadeia de suprimentos é baseada em uma demanda futura, sendo assim necessário planejar e discutir sobre ferramentas que possam vim a ser uteis para que um gestor possa gerenciar a demanda e as ofertas e garantir que os lucros sejam maximizados. Ao longo do planejamento, independente do processo ser empurrado ou puxado, diversas metodologias podem ser usadas para prever a demanda com base em dados históricos ou não. Para um melhor entendimento sobre o tema vamos afunilar os conhecimentos sobre previsão de demanda.

### **2.3 Previsão de demanda**

As operações logísticas de planejamento e controle exigem estimativas condizentes com a realidade do volume de bens ou serviços manipulados dentro de uma cadeia de produção. Tais estimativas são realizadas basicamente através das previsões. O fornecimento dos níveis de demanda é tarefa vital, estas previsões serão entradas básicas e fundamentais para o planejamento de áreas funcionais, incluindo a própria logística, marketing, produção e finanças (BALLOU R. H, 2001).

A metodologia da previsão de demanda é fundamental para qualquer tipo de organização. Seus resultados servirão como ponto de partida para decisões e tarefas que serão distribuídas e executadas na empresa, dentre elas, planejamento do fluxo de caixa, planejamento da produção, planejamento de vendas, controle de estoques, gerenciamento de compras, estratégias e operações de marketing, previsão de tempos e respostas, decisões quanto a preços, custos, entre outras (Miranda, 2011).

Miranda et al (2011), também cita que quanto maior o erro na previsão de demanda, maiores serão as dificuldades da empresa em se planejar, afetando negativamente as decisões estratégicas nos níveis organizacionais, gerando perdas financeiras e redução da competitividade no mercado. Na medida em que a dependência de previsões aumenta, os gestores necessitam utilizar métodos cada vez mais estruturados para a previsão, tornando

imperativo o entendimento de como as previsões vinham sendo feitas anteriormente e, conseqüentemente, a evolução das metodologias utilizadas.

De acordo com Ballou (2011), a previsão logística diz respeito à natureza temporal, bem como espacial, a extensão de sua variabilidade e ao seu grau de aleatoriedade:

I. Demanda espacial *versus* demanda temporal.

A variação da demanda ao longo do tempo é resultado de uma tendência de crescimento ou regressão em taxas de vendas, sazonalidade ou flutuações derivadas de N fatores. A grande maioria de previsões de curto prazo lida com este tipo de variação temporal, frequentemente denominada serie temporal.

Uma vez que a logística possui ambas as dimensões (tempo e espaço), a localização espacial da demanda irá auxiliar o profissional da logística no planejamento da localização de armazéns, equilíbrio no nível de estoque e ações relacionadas aos serviços de transporte. As técnicas de previsão podem agregar as previsões de várias localizações ou desagregar uma demanda total prevista (BALLOU, 2011).

II. Demanda regular *versus* demanda irregular.

Profissionais da logística podem se deparar com padrões regulares ou irregulares ao estudar a demanda de uma organização. Quando a demanda é regular está estará descrita por padrões gerais que podem ser facilmente decompostos em elementos de tendência, sazonalidade e aleatórios. Sendo os elementos aleatórios uma pequena parcela na variação da previsão será possível a aplicação de procedimentos populares da previsão de demanda.

Sendo o comportamento de vendas de itens intermitente e variável, resultado, por exemplo, de um volume baixo e do alto grau de incerteza associada a demandam a série temporal poderá ser classificada como nebulosa ou irregular. Tal padrão é facilmente encontrado em produtos com baixa demanda, divididos em diversas localizações de estocagem. Tais padrões são mais difíceis de prever e serem analisados através das séries mais comuns, porém é importante o seu estudo, pois tais itens podem geralmente representam 50% dos produtos que uma empresa manuseia (BALLOU, 2011).

III. Demanda dependente *versus* demanda independente.

Quando uma demanda passa a ser resultado das exigências específicas de uma programação da produção está será denominada demanda dependente. Como por exemplo o número de botões de camisa a ser requisitado por um fornecedor é um múltiplo do número de camisas a ser produzido em um determinado período de tempo. Em outros casos, quando a demanda é gerada a partir de um número muito grande de clientes a maioria dos quais

comprarão uma pequena fração da produção total de determinado produto a demanda é denominada independente.

Sendo a demanda independente, os procedimentos estatísticos devem funcionar bem.

A maioria dos modelos de previsão de curto prazo é baseada em condições de independência e aleatoriedade na demanda. Em oposição, padrões de demanda dependentes são altamente inclinados e não aleatórios (BALLOU, 2011).

### 2.3.1 MÉTODOS DE PREVISÃO

Previsões assertivas iniciam com a colaboração de gerentes e analistas de previsões, no qual, em conjunto devem responder a basicamente os seguintes questionamentos:

1. Qual a finalidade da previsão? Busca compreender o motivo pelo qual determinada previsão será usada. Esta pergunta direciona os tomadores de decisão a definir a acuracidade requerida e o esforço necessário para tal. Decidir entrar em um mercado, por exemplo, requer mais dados mais brutos do tamanho do mercado, enquanto uma previsão orçamentária requer dados mais robustos.

As técnicas de previsão variam de acordo com o custo, o escopo e acuracidade. Gerentes devem fixar um valor de não acurácia que eles podem tolerar, em outras palavras é possível realizar um estudo de *trade off* de acordo com o custo e o alcance do método. Na Figura 2.3.1.1 é possível identificar o comportamento do custo *versus* acurácia.

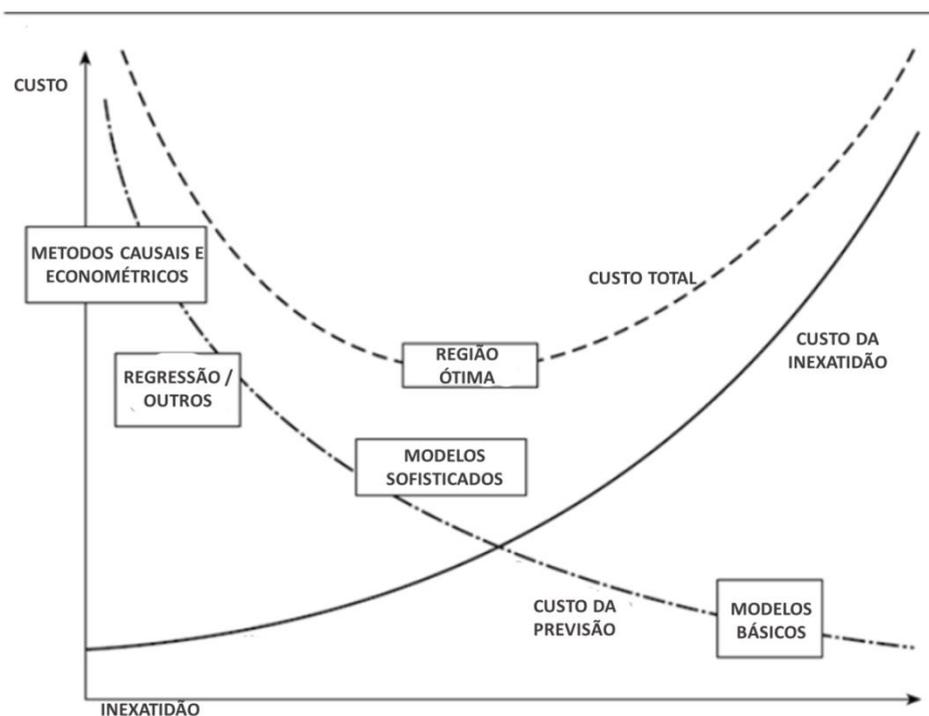


Figura 2.3.1.1. Custo de Previsão x Custo de Inexatidão para uma previsão de médio alcance.

Fonte: Adaptado de Chambers et. al. (1986).

2. Quais as dinâmicas e componentes do sistema no qual a previsão deve ser feita? Essa pergunta tem o objetivo de ajudar a identificar as relações de interação entre as variáveis. Quanto maior a quantidade de relações identificadas e utilizadas na previsão, mais sofisticado será método. É indicada a utilização de fluxogramas de processo com o intuito de compreender como variações nas vendas podem afetar os níveis de estoque, sistemas de produção e sistemas de distribuição.
3. Quão importante é o passado na estimativa do futuro? Significativas mudanças no sistema como a introdução de novos produtos, estratégias competitivas e assim por diante diminuirão a similaridade que o futuro terá com o passado. A curto prazo é improvável que mudanças recentes alterem o padrão geral da previsão, porém ao longo do tempo os efeitos de mudanças tendem a aumentar. Os tomadores de decisão devem discutir isso de forma estruturada.

Diversos métodos de previsão estão disponíveis na literatura, estes foram divididos basicamente em três grupos: qualitativo, quantitativo de projeção histórica e causal. Cada grupo difere em resumo de sua eficiência em prever o real da forma mais acurada possível a partir de sua sofisticação quantitativa, dados históricos, opiniões de especialistas pesquisas e horizonte de planejamento, curto, médio e longo prazo. Um resumo sobre as técnicas mais comuns apresentadas na literatura pode ser observada na Tabela 2.3.1.

Uma vez que o gerente ou analista de previsão tenha formulado o problema, é necessário escolher o método, que como citado acima são basicamente divididos em três categorias, qualitativas, quantitativas e causais (CHAMBERS et. al., 1986).

- I. Métodos qualitativos: uso de dados qualitativos, como a opinião de especialistas, e informações a respeito de eventos especiais que levem em consideração ou não o passado.
- II. Métodos quantitativos: método focado basicamente em padrões e em suas mudanças sendo totalmente dependente de dados históricos e considera que o futuro é uma repetição do passado.
- III. Métodos causais: Busca a causalidade a partir de uma correlação. Faz uso de informações específicas e refinadas. Assim como análise de séries o passado é importante e deve ser levado em consideração para este ramo de previsões.

Considera-se zero a três meses para horizontes de planejamento de curto prazo. Três meses a dois anos para horizontes de médio prazo e mais que dois anos para previsões de longo prazo.

**TABELA 2.3.1.2** Resumo das técnicas de previsão

Fonte: Adaptado de Ballou (2011); e Chambers et al. (1986).

<b>Método</b>	<b>Descrição</b>	<b>Horizonte de tempo / Característica</b>
<i>Análise do ciclo de vida</i>	<i>Análise e estudo das vendas de um novo produto baseado em curvas S. É estudado como o produto se comporta durante o seu ciclo de vida.</i>	<i>Médio-Longo / Causal</i>
<i>Análise espectral</i>	<i>Seu objetivo é quebrar uma série histórica em componentes fundamentais, denominados espectros. Os componentes são representados por curvas geométricas. Ao remontar os componentes é possível produzir uma expressão matemática para ser utilizada em previsões.</i>	<i>Curto-Médio / Quantitativo</i>
<i>Analogia histórica</i>	<i>Análise comparativa da introdução e crescimento das vendas de produtos novos com base na previsão de produtos similares.</i>	<i>Médio-Longo / Qualitativo</i>
<b>Box-Jenkins</b>	<b><i>Procedimento iterativo complexo, que produz um modelo de previsão baseado na média móvel integrado ao auto regressivo. É possível a utilização de ajustes sazonais e de tendência, estima parâmetros apropriados de ponderação, testa o modelo e caso necessário se repete o ciclo.</i></b>	<b><i>Curto-Médio / Quantitativo</i></b>
<i>Decomposição da serie de tempo</i>	<i>Decompõe uma série de tempo em componentes sazonais, de tendência e regular. É muito bom na identificação de pontos de inflexão, sendo esta uma excelente ferramenta para previsões de médio alcance.</i>	<i>Curto-Médio / Quantitativo</i>
<i>Delphi</i>	<i>Um grupo de especialistas é questionado a partir de uma sequência de questionários, onde as respostas para uma pergunta são utilizadas para produzir uma pergunta seguinte. Os conjuntos de questões são repassados para todos os especialistas terem acesso a previsão. Com esta técnica é possível evitar o efeito da influência majoritária.</i>	<i>Médio-Longo / Qualitativo</i>
<i>Estimativa da força de vendas</i>	<i>Previsões de vendas podem ser solicitadas aos vendedores. É importante neste caso que os vendedores sejam próximos do cliente.</i>	<i>Curto-Médio / Qualitativo</i>
<i>Filtro adaptativo</i>	<i>Um método derivativo de uma combinação ponderada das produções reais estimadas, sistematicamente alteradas para refletir padrões.</i>	<i>Curto-Médio / Causal</i>
<i>Intenções de compra e</i>	<i>Pesquisas de público geral determinam as intenções de compras</i>	<i>Médio / Causal</i>

<i>pesquisas de antecipação</i>	<i>para um determinado produto ou busca desenvolver um índice que meça o sentimento geral a respeito do presente e futuro e estimativas de como este sentimento afetará hábitos futuros. Estas previsões são mais úteis para seguir e advertir.</i>	
<i>Média móvel</i>	<i>Cada ponto de uma média móvel é uma média aritmética ou ponderada dos números do ponto consecutivo da série, onde o número de dados é escolhido para que efeitos de sazonalidade ou irregularidades sejam eliminados</i>	<i>Curto / Qualitativo</i>
<i>Modelo de entrada e saída</i>	<i>Um método de análise preocupado com o fluxo de produtos ou serviços interdepartamentais mostra que para que haja determinadas saída de produtos é necessário a entrada de outros fluxos. É necessário um esforço considerável para o uso deste modelo.</i>	<i>Médio / Causal</i>
<i>Modelo de regressão</i>	<i>Seu modelo é baseado no comportamento de determinada característica estudada com outros pontos, tais como, economia, competitividade e relacionamentos que causam ou explicam determinado nível. As variáveis são selecionadas no campo da significância estatística.</i>	<i>Curto-Médio / Causal</i>
<i>Modelo econométrico</i>	<i>Sistema de equações interdependentes de regressão com o objetivo de descrever algum setor de atividade econômica de vendas. Os parâmetros da regressões são estimados simultaneamente, na maioria dos casos.</i>	<i>Curto-Médio / Causal</i>
<i>Painel de consenso</i>	<i>Esta técnica se baseia na ideia de que diversos especialistas podem chegar a melhores previsões do que apenas um. As previsões neste caso são muitas vezes influenciadas por fatores sociais e podem não representar o consenso verdadeiro.</i>	<i>Médio-Longo / Qualitativo</i>
<i>Pesquisa de mercado</i>	<i>Procedimento formal e sistemático que envolve o teste de hipóteses a respeito do mercado.</i>	<i>Médio-Longo / Qualitativo</i>
<i>Ponderação exponencial</i>	<i>Técnica similar a média móvel, exceto que para os dados mais recentes são utilizados fatores de peso. Descritivamente, as novas previsões serão iguais as antigas mais uma parcela referente ao erro da previsão passada. Ponderações exponenciais duplas ou triplas são versões mais robustas que consideram a tendência e o fator sazonal na série de tempo.</i>	<i>Curto / Quantitativo</i>
<i>Previsão visionária</i>	<i>Em resumo é uma profecia que usa de discernimentos pessoais, julgamentos e, quando possível, fatos sobre diferentes cenários do futuro. Em geral são utilizados métodos não científicos.</i>	<i>Médio-Longo / Qualitativo</i>
<i>Previsões focadas</i>	<i>Testa um número de regras de decisão para identificar qual a mais acurada sobre o período de tempo de 3 meses vindouros. Geralmente se utiliza simulação por computador para testas</i>	<i>Médio / Quantitativo</i>

	<i>diversas estratégias.</i>	
<i>Projeção de tendências</i>	<i>Utiliza de uma linha de tendência através de uma equação matemática, projetando previsões através de curva descendente, equações polinomiais, logarítmicas e assim por diante.</i>	<i>Curto-Médio / Quantitativo</i>
<i>Redes neurais</i>	<i>Modelos matemáticos que são inspirados pelo funcionamento de neurônios biológicos. São caracterizados por aprender e evoluir ao passo que chegam novos dados no sistema. A acuracidade deste método parece ser maior do que outros métodos da série de tempo.</i>	<i>Curto / Causal</i>
<i>Resposta acurada</i>	<i>Processo de previsão que ocorre simultaneamente com o planejamento com a intenção de minimizar o impacto de previsões imprecisas. A resposta acurada é baseado no cálculo do que as previsões podem ou não podem predizer bem, fazendo com que gerentes possam postergar decisões no momento que esperam mais sinais do mercado.</i>	<i>Curto / Causal</i>
<i>Simulação dinâmica</i>	<i>Uso de computadores com a intenção de simular o efeito de vendas finais de produtos sobre exigências ao longo de uma cadeia de suprimentos e canais de distribuição. Algumas exigências são as políticas de estoque, programações de produção, entre outras.</i>	<i>Médio-Longo / Causal</i>

É importante ter consciência de que nenhuma técnica de previsão é perfeita, algumas delas podem chegar a apresentar resultados muito próximos do ótimo a depender do contexto utilizado. Porém, sempre haverá erros envolvidos no processo, pois há uma larga variedade de fatores que afetam o ambiente dos negócios. Neste contexto, uma estratégia é a do estabelecimento de uma prática de revisão contínua das previsões (CHASE et al., 2006).

Como proposta deste trabalho será utilizada uma metodologia quantitativa por intermédio da análise de séries temporais, mais especificamente a metodologia Box-Jenkins.

#### **2.4 Metodologia Box-Jenkins ou Autoregressive Integrated Moving Average (ARIMA)**

Morretin & Tolo (1987) citaram que uma série temporal é um conjunto qualquer de observações ordenadas no tempo, compostas por quatro elementos.

1. *Tendência*: verifica o sentido do deslocamento da série ao longo dos anos.
2. *Ciclo*: verifica se há um movimento ondulatório ao longo dos anos, que ao longo dos anos tende a ser periódico.

3. *Sazonalidade*: um movimento ondulatório de curta duração, normalmente associado a um período inferior a um ano, associada a fatores externos como variações climáticas.
4. *Ruído aleatório ou erro*: relacionado a uma variabilidade intrínseca dos dados, não pode ser eliminado.

É esperado que uma série temporal, tendo os dados coletados e ordenados sequencialmente ao longo do tempo, apresente correlação seriada no tempo. Os modelos de Box-Jenkins, conhecidos por ARIMA (*Auto Regressive Integrated Moving Averages*) ou em português por Auto Regressivos Integrados de Média Móvel, são modelos matemáticos que buscam captar o comportamento da correlação da série ou da autocorrelação entre os valores, e com base nestes comportamentos realizar uma previsão futura. Sendo a estrutura de correlação bem modelada, boas previsões serão fornecidas (WERNER, L. & RIBEIRO, J. L. D., 2003).

Já há algumas décadas muitos esforços veem sendo direcionados para o desenvolvimento e melhoria de metodologias a previsão e análise de séries temporais. Uma das mais importantes e mundialmente usadas e conhecidas é o modelo ARIMA – *autoregressive integrated moving average*. A popularidade do ARIMA é devida a suas propriedades estatísticas assim como a também conhecida metodologia de Box-Jenkins utilizada na construção do processo (Zhang, G. P. 2003).

Também de acordo com Zhang (2003) os modelos ARIMA são bastante flexíveis, uma vez que podem representar diferentes tipos de séries temporais, por exemplo, apenas a análise autorregressiva (AR), a média móvel pura (MA) ou uma combinação destas duas (ARMA) e aplicação do filtro de integração (I). Sua maior limitação é assumir previamente que o modelo possui uma função linear. Isto é, é assumido que há uma correlação linear entre os valores da série. Padrões não lineares não podem ser capturados pelo ARIMA. Os modelos da metodologia assim como sua construção serão apresentados a seguir.

#### 2.4.1 MODELOS ESTACIONÁRIOS

Uma série será dita estacionária quando ela estiver em equilíbrio, o que significa que média e variância serão constantes ao longo da série e a sua covariância é função da defasagem entre os instantes. Desta forma o primeiro passo para aplicação do método é identificar se há estacionariedade na série temporal. Caso a série seja não estacionária é necessário transformá-la de acordo. O filtro de integração refere-se ao processo de aplicação

de diferenças sucessivas (d) até o alcance do equilíbrio, desta forma será possível à identificação de padrões e comportamentos particulares (Ribeiro, 2009).

Há testes para a verificação de estacionariedade de uma série. Exemplos destes testes são o de Ljung-box e o de Box-Pierce, onde é verificado para o primeiro caso se os coeficientes de correlação amostral são estatisticamente iguais à zero, comprovando neste caso a estacionariedade da série; e para o segundo caso há a verificação dos coeficientes de autocorrelação amostral, sendo estes estatisticamente diferentes de zero, que sendo aceita provará que a série é não estacionária (MATOS, 2000).

Em caso da série em estudo apresentar tendência ou caso a não estacionariedade esteja comprovadamente associada a sua variância é necessário remover a tendência e realizar transformações na série original por intermédio do logaritmo neperiano respectivamente (FAVA, 2000).

#### 2.4.1.1 Modelos autorregressivos (AR)

A denotação deste modelo é dada por AR(p), sendo  $p$  o número de defasagens de  $y_t$ . O evento  $y$  no período  $t$  é resultado de uma média ponderada de eventos passados, aos quais  $p$  períodos anteriores são inclusos na série, além de uma perturbação ou erro corrente. Fava (2000) apresenta um modelo genérico autorregressivo como sendo representado na seguinte equação:

$$y_t = \phi_1 y_{t-1} + \phi_2 y_{t-2} + \phi_p y_{t-p} + \varepsilon_t \quad (\text{Eq. 1})$$

Onde:

$y_t$  – Valor da série temporal no instante  $t$ .

$\varepsilon$  – Resíduo ou erro aleatório, denominado ruído branco

$\phi$  – Parâmetro que descreve como  $y_t$  se relaciona com  $y_{t-p}$

Para descrever a série é sugerido por Fava (2000) a utilização do operador de defasagem  $B$ , sendo a equação 1 representada pelas equações 2 e 3:

$$y_t = \phi_1 B y_t + \phi_2 B^2 y_t + \phi_p B^p y_t + \varepsilon_t \quad (\text{Eq. 2})$$

$$\phi_1 B y_t = \varepsilon_t \quad (\text{Eq. 3})$$

Um modelo AR(p) refere-se ao grau de associação de valores que estejam distantes em  $p$  períodos. Para se determinar o número ótimo de defasagens necessárias pode-se analisar os valores através da função de autocorrelação parcial (FACP) (Matos, 2000). É necessário

cautela na utilização de parâmetros autorregressivos, com o intuito de se evitar a perda de informação.

Em um processo AR(p) autocorrelações parciais serão nulas para os lags maiores que p. Assim, em uma representação gráfica será possível identificar o grau do modelo AR(p).

#### 2.4.1.2 Modelos de médias móveis (AM)

Makridakis et al. (1998) cita que os modelos de médias móveis AM(q) irão expressar valores de determinada série como uma combinação linear do valor corrente e de valores dos erros passados ou de choques aleatórios. O número ótimo de defasagens poderá ser determinado com base nos valores da função de autocorrelação (FAC).

Os modelos da média móvel também tratam de uma soma ponderada de valores, porém os valores considerados são o valor corrente do erro aleatório e seus q valores passados, como pode ser visualizado na equação 4.

$$y_t = \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \theta_p \varepsilon_{t-p} \quad (\text{Eq. 4})$$

Onde:

$y_t$  – Valor da série temporal no instante t.

$\varepsilon_t$  – Resíduo ou erro aleatório no instante t

$\theta$  – Parâmetro da média móvel que descreve como  $y_t$  se relaciona com  $y_{t-p}$

Assim como no modelo auto regressivo utiliza-se também o operador de defasagem B, sendo a equação reescrita conforme a equação 5 e 6.

$$y_t = \varepsilon_t - \theta_1 B \varepsilon_t - \theta_2 B \varepsilon_t - \theta_p B \varepsilon_t \quad (\text{Eq. 5})$$

$$\theta(B) \varepsilon_t = y_t \quad (\text{Eq. 6})$$

De forma similar ao que acontece no modelo AR(p), a identificação adequada do valor de q passa pela análise dos coeficientes de autocorrelação (FAC) e autocorrelação parcial da série (FACP).

#### 2.4.1.3 Modelos ARMA

De acordo com Fava (2000), a equação de um modelo genérico ARMA irá utilizar um componente autorregressivo p e outro componente de médias móveis q. Makridakis (1998)

cita que o desempenho combinado destes dois modelos será melhor do que se for trabalhado o modelo AR(p) ou MA(q) de forma separada. De forma geral, a expressão para o modelo ARMA pode ser vista na equação 7, que nada mais é que a junção das equações 1 e 4.

$$y_t = \phi_1 B y_t + \phi_2 B^2 y_t + \phi_p B^p y_t + \varepsilon_t - \theta_1 B \varepsilon_t - \theta_2 B^2 \varepsilon_t - \theta_p B^p \varepsilon_t \quad (\text{Eq. 7})$$

Onde:

$y_t$  – Valor da série temporal no instante  $t$ .

$\phi$  – Paramêtro que descreve como  $y_t$  se relaciona com  $y_{t-p}$

$y_t$  – Valor da série temporal no instante  $t$ .

$\varepsilon_t$  – Resíduo ou erro aleatório no instante  $t$

$\theta$  – Paramêtro da média móvel que descreve como  $y_t$  se relaciona com  $y_{t-p}$

O operador de defasagem B também pode ser utilizado na equação, desta forma temos a equação resultante 8.

$$\Theta(B)\varepsilon_t = \phi_1 B y_t \quad (\text{Eq. 8})$$

É necessário ressaltar que para condições de estacionariedade e invertibilidade sejam satisfeitas em um modelo ARMA (p,q), requer-se, que todas as p raízes de  $\phi(B)$  e as q raízes de  $\theta(B)$  iguais a zero, estejam fora do círculo unitário.

#### 2.4.1.4 Modelos não estacionários

##### 2.4.1.4.1 Modelos ARIMA

Como citado no início do capítulo 2.4.1, é necessário que a serie em questão seja estacionária para a aplicação das metodologias AR(p), MA(q) ou ARMA(p,q). Caso as mesmas não apresentem características de estacionariedade, diferenças sucessivas deverão ser aplicadas na série para torna-la estacionária.

Em resumo, os modelos ARIMA(p,d,q) são modelos que se tornarão estacionários após a aplicação de  $d$  diferenças na serie original, a série que exibir este comportamento será denominada de não-estacionária homogênea. A ordem de integração  $d$  se refere ao número de diferenças necessárias para tornar uma série não estacionária em estacionária (FAVA, 2000).

O modelo ARIMA(p,d,q), após uma série de diferenciações  $d$  pode ser visualizado na equação 9, assim como o modelo reduzido devido ao operador de defasagem nas equações 10, 11 e 12.

$$w_t = \phi_1 w_{t-1} + \phi_2 w_{t-2} + \phi_p w_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \theta_p B \varepsilon_{t-2} \quad (\text{Eq. 9})$$

Onde:

$$\mathbf{w}_t = \Delta^d = \mathbf{y}_t$$

$$\mathbf{w}_t = \phi_1 \mathbf{w}_{t-1} + \phi_2 \mathbf{w}_{t-2} + \dots + \phi_p \mathbf{w}_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_p \mathbf{B} \varepsilon_{t-2} \quad (\text{Eq. 9})$$

$$(\mathbf{1} - \phi \mathbf{B} - \dots - \phi \mathbf{B}^p) \mathbf{w}_t = (\mathbf{1} - \phi \mathbf{B} - \dots - \theta_p \mathbf{B}^q) \varepsilon_t \quad (\text{Eq. 10})$$

$$\mathbf{w}_t = (\mathbf{1} - \mathbf{B})^d \mathbf{y}_t \quad (\text{Eq. 11})$$

$$(\mathbf{1} - \mathbf{B})^d \mathbf{y}_t \phi(\mathbf{B}) = \theta(\mathbf{B}) \varepsilon_t \quad (\text{Eq. 12})$$

Modelos ARIMA (p, d, q),  $(\mathbf{1} - \mathbf{B})^d \phi(\mathbf{B}) = \mathbf{0}$ , apresentam d raízes unitárias p fora do círculo unitário.

Se d=0, uma série é estacionária para ARMA (p,q). Importante notar que um processo ARIMA (p,0,0) significa um processo AR (p) puramente estacionário, um ARIMA (0,0,q) significa um processo MA(q) puramente estacionário. Dados os valores para p,d e q é possível dizer qual o processo esta sendo modelado.

#### 2.4.1.4.2 Modelos Sazonais SARIMA

O modelo SARIMA é o modelo ARIMA aplicado a séries com sazonalidade. Algumas outras versões do ARIMA são o CARISMA, *controlled autoregressive integrated segmented moving average*; KARINA, versão híbrida para o termo de previsão de tráfego; FARIMA, um método que usa o modelo *fuzzi* de regressão nos parâmetros do ARIMA; e o FSARIMA, modelo que combina as vantagens do SARIMA e do modelo de regressão de *fuzzi* (EDIGER et al., 2005).

O modelo sazonal para o ARIMA foi inicialmente proposto por Box-Jenkins e foi usado com sucesso em problemas de previsão. Enquanto que em outros modelos há vantagem na acurácia da previsão a partir de uma pequena amostra de dados, para o SARIMA é necessário 50 e preferencialmente 100 observações para que o modelo seja utilizado (TSENG et al., 2001).

Os modelos ARIMA como visto nós tópicos anteriores exploram a autocorrelação entre valores da série em instantes sucessivos. Porém, quando observados períodos inferiores a um ano é possível visualizar autocorrelação para uma estação de sazonalidade s. Os modelos SARIMA contem uma parte não sazonal, com os parâmetros (p,d,q) e uma parte sazonal, com parâmetros (P,D,Q)<sub>s</sub>. O modelo geral pode ser visualizado na equação 13.

$$\begin{aligned} & (\mathbf{1} - \phi_1 \mathbf{B} - \dots - \phi_p \mathbf{B}^p) (\mathbf{1} - \Phi_s \mathbf{B}^s - \dots - \Phi_P \mathbf{B}^{Ps}) (\mathbf{1} - \mathbf{B})^d (\mathbf{1} - \mathbf{B}^s)^D \mathbf{y}_t \\ & = (\mathbf{1} - \theta_1 \mathbf{B} - \dots - \theta_q \mathbf{B}^q) (\mathbf{1} - \Theta_1 \mathbf{B}^s - \dots - \Theta_Q \mathbf{B}^{Qs}) \varepsilon_t \quad (\text{Eq. 13}) \end{aligned}$$

Onde:

- $(1 - \phi_1 B - \dots - \phi_p B^p)$  – parte auto-regressiva não sazonal de ordem p;
- $(1 - \Phi_s B^s - \dots - \Phi_p B^{ps})$  – parte auto-regressiva sazonal de ordem p e estação sazonal s;
- $(1 - B)^D$  - parte da integração não sazonal de ordem d;
- $(1 - B^s)^D$  – parte da integração sazonal de ordem D e estação sazonal s;
- $(1 - \theta_1 B - \dots - \theta_q B^q)$  – parte das médias móveis não sazonal de ordem q;
- $(1 - \Theta_1 B^s - \dots - \Theta_q B^{qs})$  – parte sazonal das médias móveis de ordem Q estação sazonal S.

#### 2.4.1.2.3 Etapas para a construção do modelo ARIMA. A metodologia Box-Jenkins

Construir um modelo ARIMA é geralmente uma tarefa difícil para o usuário, pois requer um bom conhecimento em análise estatística, bom conhecimento sobre o campo de aplicação do modelo e a disponibilidade de um bom programa de computação.

A pergunta chave é: observando uma série temporal, como é possível identificar se a mesma segue um processo AR(p), AM(q), ARMA(p,q) ou um processo ARIMA (p,d,q) e quais são os valores para p, d e q?. A metodologia Box-Jenkins é muito útil para responder a esta questão.

Para uma série estacionária a metodologia de Box-Jenkins propõe as seguintes etapas iterativas para a construção do modelo (GUAJARATI et al., 2011).

**Etapa 1. Identificação.** O objetivo neste momento é selecionar o modelo ARMA (p,q) mais adequado e o que irá melhor descrever os padrões da série histórica. Nesta etapa serão analisados os dados históricos e comportamento da função através de funções de autocorrelação (FAC) e autocorrelação parcial (FACP). Com a análise é possível identificar quais serão os graus (p,q) do modelo.

**Etapa 2. Estimativas.** Depois da identificação de valores apropriados para (p,q) é necessário estimar parâmetros dos termos autorregressivos ( $\phi$ ) e dos termos da média móvel ( $\theta$ ) que estão inseridos no modelo. A partir da análise da função de autocorrelação e da função de autocorrelação parcial dos resíduos é possível avaliar se o modelo é adequado ou não. Para que o modelo seja considerado adequado as correlações devem ser insignificantes, caso o modelo não seja adequado o ciclo é repetido retornando-se à fase de identificação.

**Etapa 3. Verificação do diagnóstico.** Após a estimação de parâmetros é necessário confirmar a capacidade do modelo em simular fenômenos através das análises dos erros do modelo proposto. Em situações em que é verificado a inadequação do modelo é fundamental retornar para a Etapa 1 e recomeçar o processo, fazendo da metodologia de Box-Jenkins um processo iterativo.

**Etapa 4. Previsão.** Com o modelo validado é possível a sua utilização para previsões, especialmente para as de curto prazo. Uma das razões da popularidade do ARIMA é o seu sucesso em previsões, sendo estas mais confiáveis que as previsões obtidas através de métodos econométricos tradicionais.

#### 2.4.1.2.3.1 Identificação

Com a utilização das ferramentas (FAC), (FACP) e os seus correlogramas resultantes é possível identificar os valores (p,q). Gujarati (2011) apresenta uma tabela de verificação de padrões teóricos de FAC e FACP, obtidos através da observação do modelo empírico da série.

Na etapa de identificação há a necessidade de estabilização da série temporal, com o objetivo de se eliminar a possibilidade de resultados espúrios. Pellegrini (2000) cita o procedimento de diferenciação, que ira determinar o valor do coeficiente (d), para transformar uma série classificada inicialmente como não estacionária em estacionária, convertendo o processo em um modelo ARMA (p,q). Após a diferenciação é mensurado o grau de estacionariedade da série através dos coeficientes de autocorrelação e autocorrelação parcial.

**Tabela 2.4.1.2.3.2 Padrões teóricos para FAC E FACP**

Fonte: Adaptado de Gujarati (2011)

<b>Tipo de Modelo</b>	<b>Padrão Típico da FAC</b>	<b>Padrão Típico da FACP</b>
<i>AR(p)</i>	<i>Declina exponencialmente e/ou com padrão de onda senoidal amortecida.</i>	<i>Picos significativos até p defasagens.</i>
<i>AM(q)</i>	<i>Picos significativos até q defasagens.</i>	<i>Declina exponencialmente</i>
<i>ARMA(p,q)</i>	<i>Queda exponencial</i>	<i>Queda exponencial.</i>

Makridakis cita que a principal etapa da metodologia de Box-Jenkins é identificar o modelo ARMA (p,q), esta análise é basicamente dividida em 3 etapas:

1. Verificar se a série é estacionária ou não. Caso não seja, proceder com ajustes.
2. Avaliar os gráficos FAC e FACP para se identificar o modelo mais adequado.
3. Analisar as correlações para se definir o grau do modelo.

Com a diferenciação da série e a definição de sua estacionariedade será possível identificar componentes sazonais no conjunto de dados, observado quando se segue um padrão gráfico de picos periódicos.

#### **2.4.1.2.3.2 Estimação**

Obtido os valores  $p$ ,  $d$  e  $q$  é necessário estimar os parâmetros do modelo. Pacotes estatísticos trazem normalmente o algoritmo para a estimação dos valores. A estimação destes parâmetros pode ser alcançada através do método dos mínimos quadrados ou da máxima verossimilhança, porém é necessário admitir inicialmente que os ruídos brancos tenham distribuição normal, fator que deve ser comprovado na etapa de verificação do modelo (FAVA, 2000).

#### **2.4.1.2.3.3 Verificação do diagnóstico**

O objetivo desta etapa é verificar se o modelo de previsão obtido ajusta-se aos dados. Um diagnóstico simples para esta verificação é a análise dos resíduos que pode ser obtido através das funções de autocorrelação e correlação parcial dos resíduos. A função da autocorrelação e correlação parcial devem ser estatisticamente e individualmente não significativas. Em outras palavras, os correlogramas apresentados pelas funções FAC e FACP dos resíduos são puramente aleatórios, apresentado assim uma distribuição normal. Ao se comprovar este fator confirma-se também que não há necessidade de procurar por outro modelo (GUJARATI, 2011).

#### **2.4.1.2.3.4 Previsão**

Ao se obter um modelo satisfatório é possível prosseguir para a última etapa da metodologia Box-Jenkins, realizar as previsões. O detalhamento desta etapa será realizado na aplicação do estudo.

### 3 METODOLOGIA

Com o objetivo de se alcançar o conhecimento, se faz necessária a utilização de um conjunto de procedimentos técnicos e intelectuais definido como Método Científico (GIL, 2002). Gerhardt (2009) cita que a metodologia é o estudo do método, sendo o corpo de regras estabelecidas para a realização de uma pesquisa.

Com o intuito de garantir os resultados esperados, o presente estudo apresenta natureza aplicada, uma vez que possui a intenção de aplicar conceitos visando à solução do problema proposto. A abordagem quantitativa tem o objetivo de comparar os resultados reais com os resultados previstos para períodos anteriores a esta pesquisa, sugerindo também previsões para períodos futuros.

A indústria em estudo possui em sua rede de distribuição direta uma cartela de 84 clientes divididos ao longo de toda América do Sul, com a maior parte de sua operação nos estados brasileiros. Para o estudo foi sorteado aleatoriamente um entre estes 84 clientes que, por motivos éticos e de confidencialidade, não será indicado neste estudo.

Além dos 84 clientes, é sabido que há uma variedade considerável nos tipos de produtos comercializados pela empresa, tais produtos podem ser agrupados por famílias no mercado de consumo, por exemplo. Para o estudo em questão, serão consideradas as vendas totais de acumuladores, independente de seu modelo, subfamílias ou famílias, porém é sugerido para pesquisas futuras o afinamento do estudo.

Os dados de venda da empresa foram disponibilizados através do WMS (*Warehouse Management System*) no qual é integrado ao sistema ERP (*Enterprise Resource Planning*) empresarial. Para a série histórica foi considerada uma amostra com 120 pontos, compreendendo o período de vendas de 10 anos, 01/01/2008 a 31/12/2017.

Processos de previsão de demanda tiveram seu uso facilitado e disseminado em função do avanço das tecnologias e atualmente é possível a utilização de diversos softwares no mercado que realizam cálculos de forma automática, entretanto há ainda a necessidade de uma análise qualitativa da previsão de demanda para se atingir o seu objetivo. Para auxílio e desenvolvimento do presente estudo, fez-se uso do Software *Statistica Academic*®, versão 13.0.1 e também o Excel®, programa incluso no pacote Office, desenvolvido pela Microsoft®.

Através da pesquisa bibliográfica realizada e dos pontos debatidos ao longo deste trabalho é possível visualizar um resumo de como a metodologia é transcorrida através do fluxograma apresentado na figura 3.1.

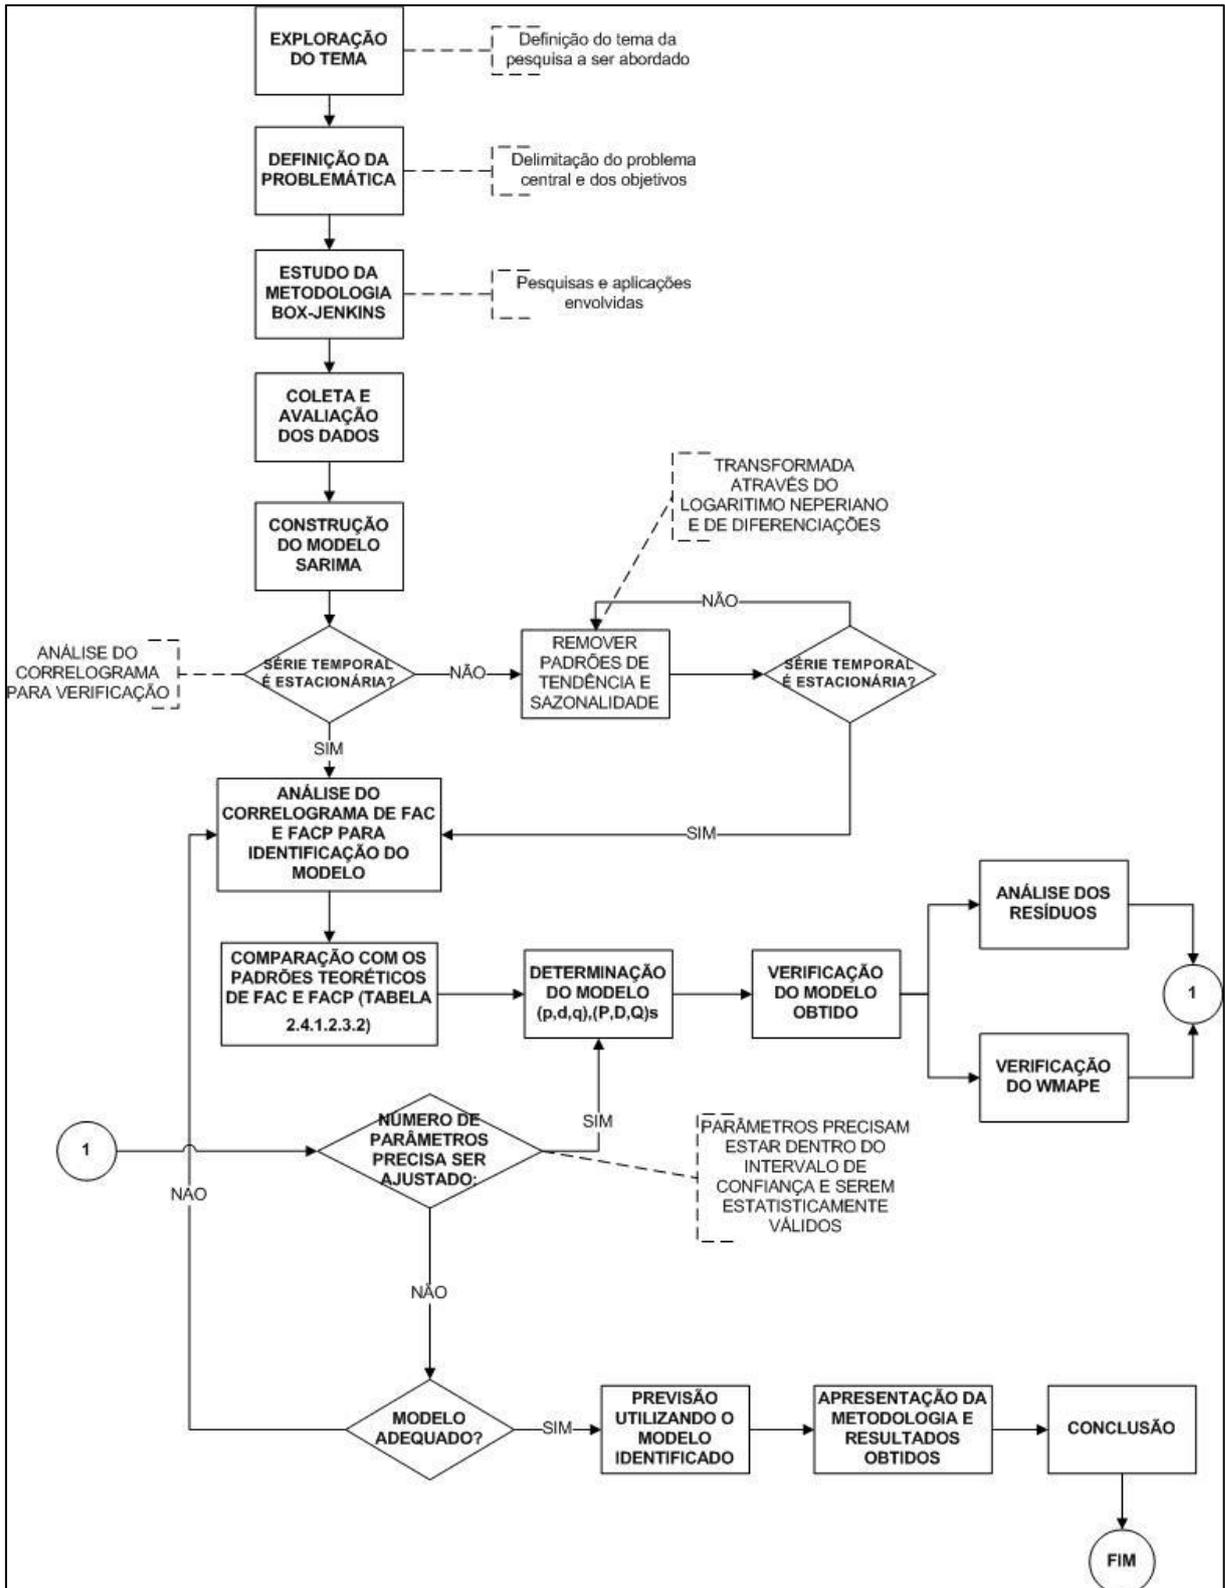


Figura 3.1 Metodologia Simplificada da Pesquisa  
Fonte: O Autor

## 4 ESTUDO DE CASO

### 4.1 Aplicação da metodologia Box-Jenkins

Como já citado, será analisado neste estudo o comportamento de uma série temporal associada à venda de acumuladores elétricos destinados a um cliente da indústria de acumuladores em questão. Os dados de venda ordenados no tempo podem ser visualizados na tabela 4.1.1.

**Tabela 4.1.1 Venda de acumuladores para o período em estudo**

Fonte: O autor

VENDA DE ACUMALADORES ELÉTRICOS										
	2008	2009	2010	2011	2012	2013	2014	2015	2016	2017
<b>JANEIRO</b>	4569	5952	7707	4888	6755	3759	11110	8950	9979	8944
<b>FEVEREIRO</b>	4353	4608	6096	6393	3591	8419	3672	5116	7796	15869
<b>MARÇO</b>	4344	5222	5263	6114	5750	6272	9571	8923	15242	10317
<b>ABRIL</b>	3944	4491	5202	3799	3198	6035	7685	6572	14073	3542
<b>MAIO</b>	4888	5318	5868	5629	9426	6384	8690	8823	5823	11988
<b>JUNHO</b>	4967	4877	6339	4711	7369	8384	768	10147	8379	8347
<b>JULHO</b>	4636	5750	2856	5837	3994	7940	1260	5526	15569	10299
<b>AGOSTO</b>	5841	5934	7094	5520	6858	8658	11399	11533	5845	12584
<b>SETEMBRO</b>	4530	5893	7989	5997	4045	10173	6369	12325	8820	8786
<b>OUTUBRO</b>	4929	6419	6196	6828	6565	8663	8570	11575	9159	12951
<b>NOVEMBRO</b>	4342	5188	4588	7430	4255	7476	11747	11344	9019	13481
<b>DEZEMBRO</b>	3746	6629	5291	6829	9671	7875	9940	10275	13508	13529
<b>TOTAL</b>	<b>55089</b>	<b>66281</b>	<b>70489</b>	<b>69975</b>	<b>71477</b>	<b>90038</b>	<b>90781</b>	<b>111109</b>	<b>123212</b>	<b>130637</b>

Para uma melhor visualização do comportamento da série, é possível visualizar as figuras 4.1.2 e 4.1.3 que correspondem respectivamente ao comportamento gráfico de vendas da série temporal ao longo do tempo.

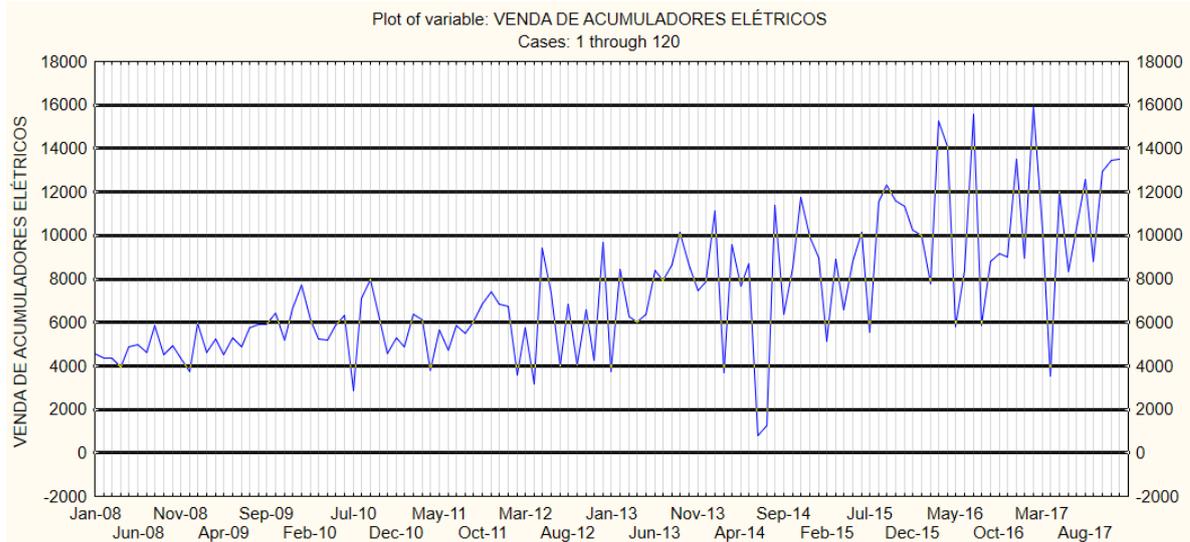


Figura 4.1.2 Venda de Acumuladores Elétricos  
Fonte: O Autor

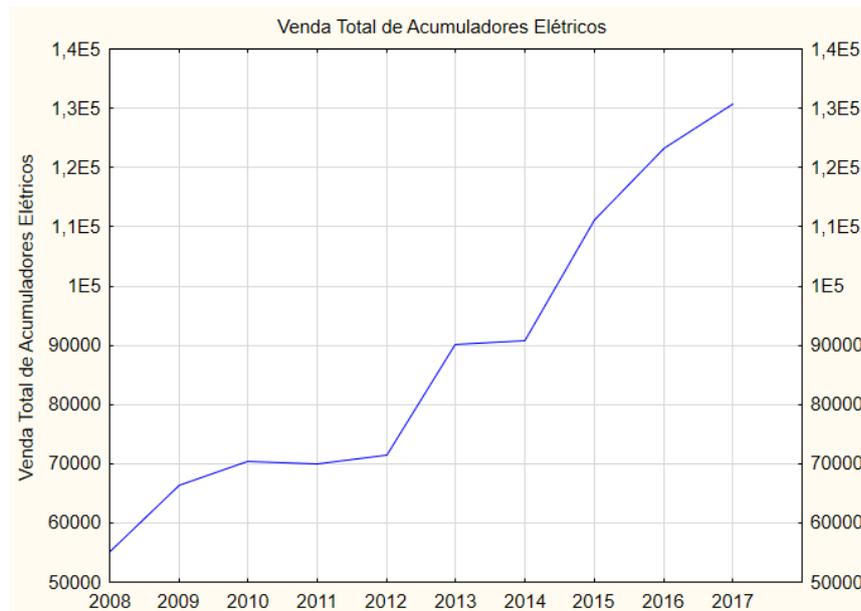


Figura 4.1.3 Venda total de acumuladores elétricos por ano  
Fonte: O Autor

#### 4.1.1 FASE DE IDENTIFICAÇÃO

É possível observar a partir da Figura 4.1.2 uma clara tendência de crescimento ao longo dos anos, com uma tendência de crescimento disruptiva a partir do ano de 2014. A partir da Figura 4.1.2 observamos picos de vendas ao longo dos meses, o que demonstra certo grau de sazonalidade ao longo da série temporal. De posse destas informações, conseguimos demonstrar que a série não possuía média ou variância constante ao longo do tempo. Sendo assim, classificada como não estacionária.

Como já citado anteriormente, outro método para checar a estacionariedade de uma série temporal é através da análise gráfica do correlograma da Função de Autocorrelação, para esta análise considere o resultado mostrado na Figura 4.1.5.

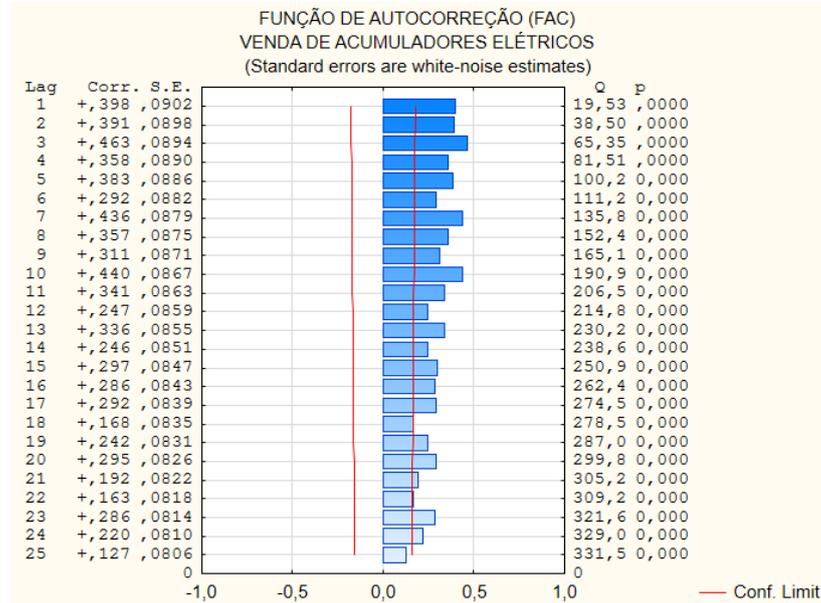


Figura 4.1.5 Função de Autocorreção para a série temporal original

Fonte: O Autor

Observando o correlograma da série temporal original é possível notar que os coeficientes de autocorrelação nas diversas defasagens são altos, apresentando uma queda muito lenta à medida que aumentamos o alcance da defasagem. De fato, se aumentarmos o alcance da defasagem é possível observar que na defasagem acima de 32 pontos há correlação quase nula dos números da série temporal, o que iria caracterizar a série como estacionária, porém há uma tendência de crescimento e variação da correlação após a defasagem de número 52 comprova que a série em estudo é realmente não estacionária, Figura 4.1.6.

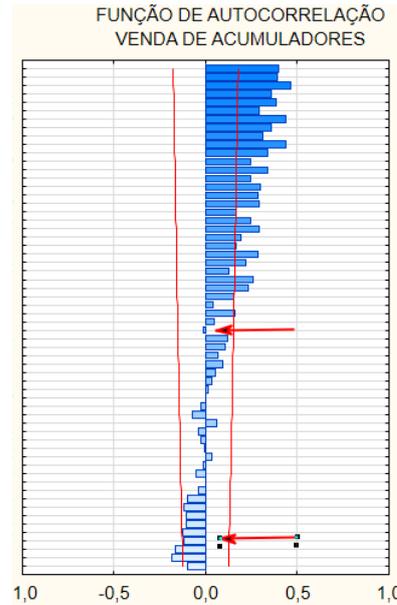


Figura 4.1.6 Função de Autocorrelação para a série temporal original com 60 defasagens.  
Fonte: O Autor

É importante também pontuar que os valores obtidos para o correlograma da autocorrelação são estatisticamente significativos, uma vez que o valor-p para todas as defasagens é menor que o nível de significância  $\alpha = 0,05$  previamente estabelecido.

Como comprovado que a série em questão apresenta características de tendência e sazonalidade, classificamos a mesma como não estacionária. Desta forma, para a correta utilização do modelo ARIMA, é necessário remover a tendência e sazonalidade associada a não estacionariedade, seguido dos estudos das funções de autocorrelação (FAC) e autocorrelação parcial (FACP).

Uma das formas de remover a tendência e identificar padrões sazonais na série é através de transformações na série original. Com o intuito de remover a tendência evidente na figura 4.1.2, aplicaremos uma transformada através do logaritmo neperiano. Com esta transformada, é possível observar uma menor variação na média e, consequentemente, na variância, Figura 4.1.7.

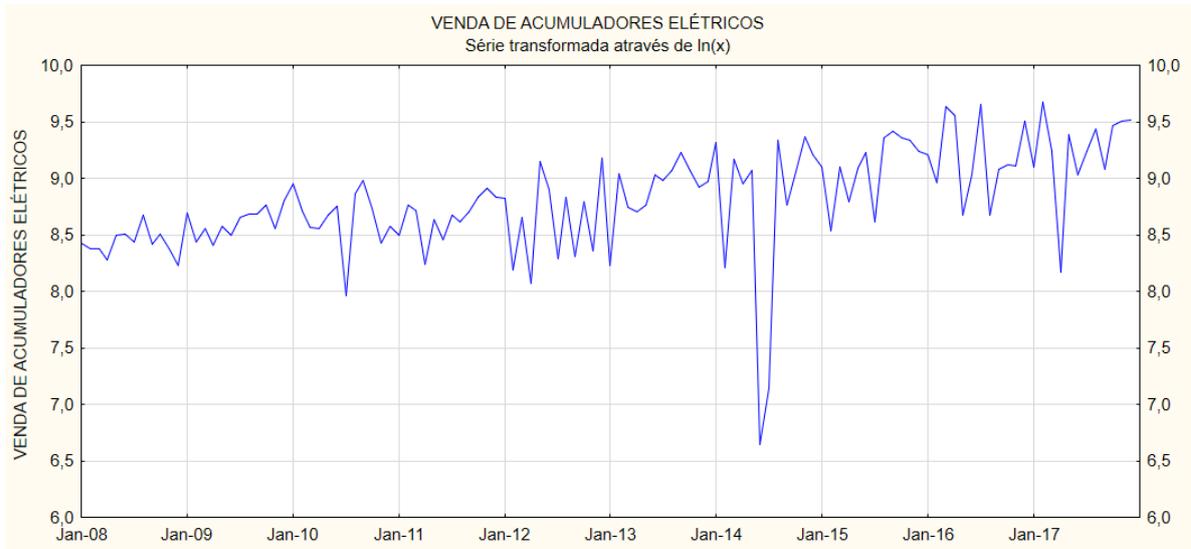


Figura 4.1.7 Série temporal original transformada através do logaritmo neperiano  
Fonte: O Autor

Com a transformação da série houve uma diminuição na amplitude das mudanças, sendo estas agora um pouco mais estáveis que antes, além do decréscimo do coeficiente de tendência. Porém, apenas esta transformada não é suficiente para tornar a série estacionária, sendo também necessária a transformada através do procedimento de diferenciação, determinando assim o valor do coeficiente ( $d$ ) e transformando o processo em um modelo ARMA ( $p, q$ ).

O grau de diferenciação da série para este momento será de 1 ( $d=1$ ) e o resultado da transformação pode ser visualizada na figura 4.1.8:

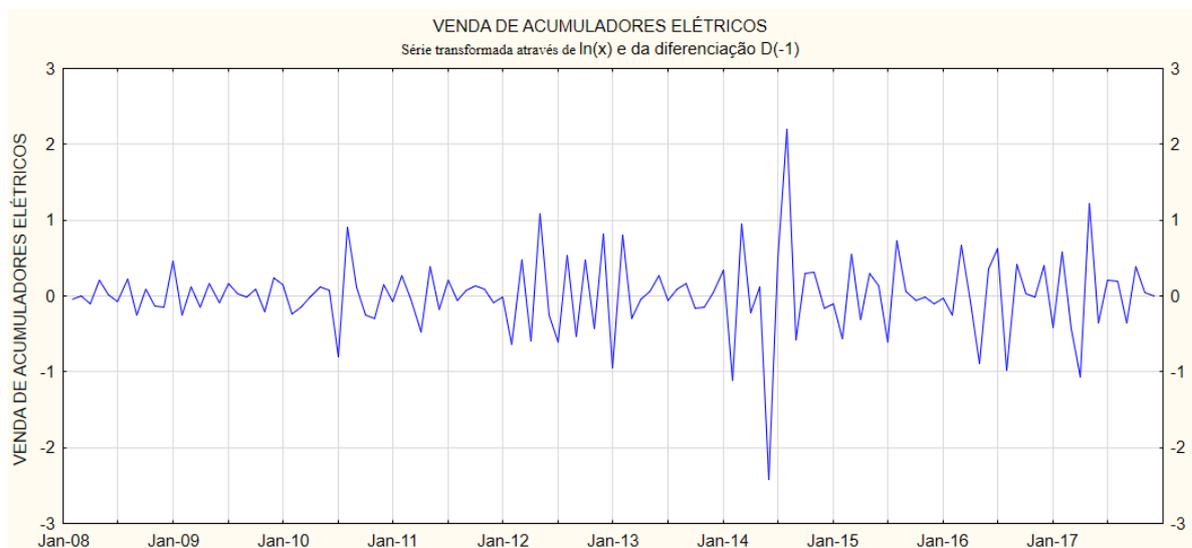


Figura 4.1.8 Série temporal original transformada através do logaritmo neperiano e da diferenciação de grau 1 ( $d=1$ )  
Fonte: O Autor 2018

Com isto, cada elemento da série original é representado pela diferença entre seu valor original e o valor de seu elemento adjacente. Mais uma vez é necessário utilizar a função de autocorrelação para verificar se a transformada é estaticamente válida e se há dependência associada aos valores da série transformada. É possível visualizar que a maioria das dependências seriais desapareceram, exceto pela defasagem 1 que não pode ser diferenciada por ser o primeiro elemento da serie, vide Figura 4.1.9, e que a série após a transformada passou a ser estacionária:

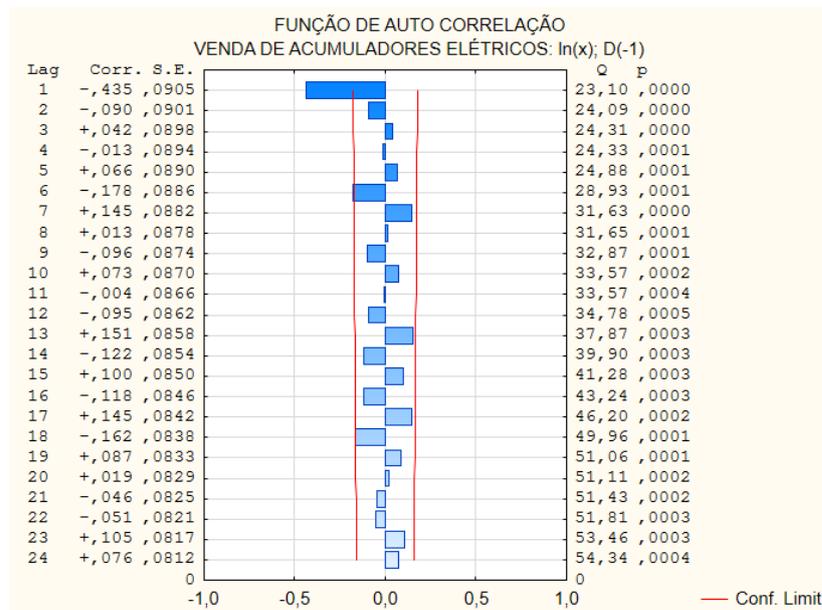


Figura 4.1.9 Função de Autocorrelação para a série temporal transformada em ln(x) e D(-1)  
Fonte: O Autor 2018

É possível também aumentar o número de defasagens na função de autocorrelação com o intuito de identificar o comportamento da série ao longo do tempo, aplicando uma defasagem de 60 meses observa-se que a venda de baterias dentro da série transformada revela um comportamento senoidal, padrão típico de processos autorregressivos AR(p), Figura 4.1.10.

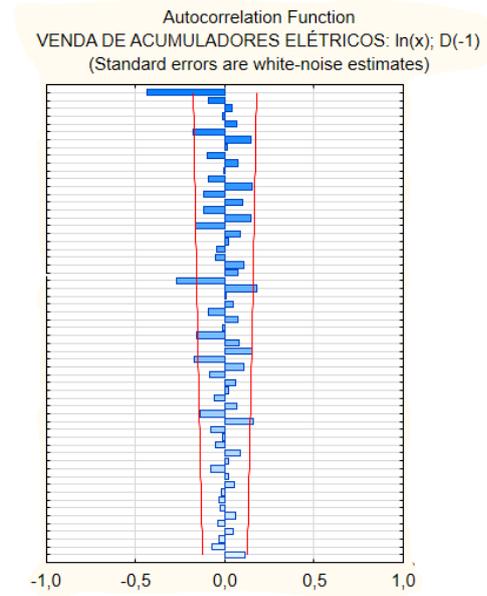


Figura 4.1.10 Função de Autocorrelação para a série temporal transformada em  $\ln(x)$  e  $D(-1)$  com 60 defasagens  
 Fonte: O Autor

Pontua-se também que os valores obtidos para o correlograma da autocorrelação são estatisticamente significativos, uma vez que o valor-p para todas as defasagens é menor que o nível de significância  $\alpha = 0,05$  previamente estabelecidos.

A partir do correlograma da função de autocorrelação observamos também que com a remoção de determinadas dependências a série ficou exposta a uma variação de maior ordem, indicando um padrão sazonal na série. Como estamos trabalhando com valores anuais é sugerida para este modelo uma dependência sazonal  $S=12$ , aprimorando assim o modelo ARIMA para o SARIMA.

O segundo correlograma a ser analisado é o da Função de autocorrelação parcial. É necessário que o mesmo também apresente características de estacionariedade onde os valores devem possuir uma tendência decrescente de correlação ao passo que se aumenta o número de defasagens. O correlograma da função de autocorrelação parcial (FACP) pode ser observado na Figura 4.1.11.

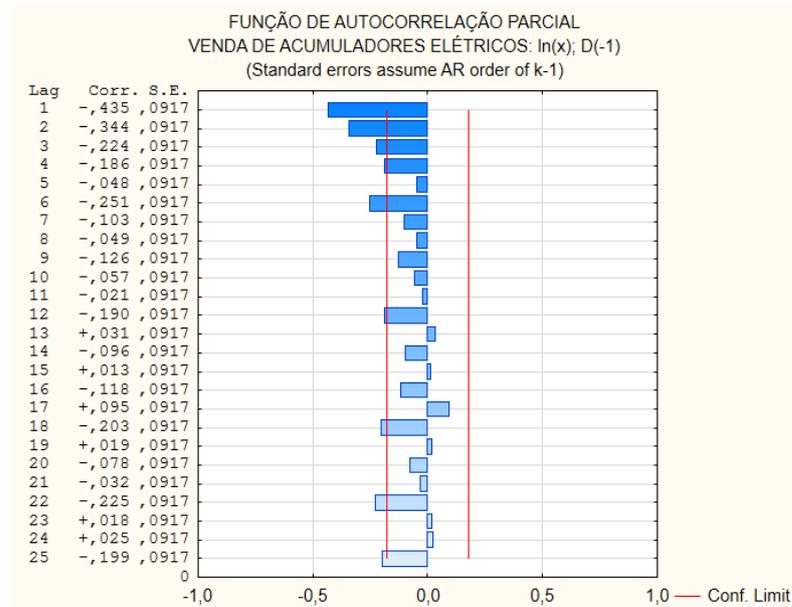


Figura 4.1.11 Função de Autocorrelação para a série temporal transformada em ln(x) e D(-1)  
Fonte: O Autor

Note que, apesar da quebra dos limites de confiança, observa-se à medida que se aumenta o número de defasagens para o correlograma da FACP picos significativos até a defasagem de número 32, caracterizando-o também como processo AR(p), observar Figura 4.1.10.

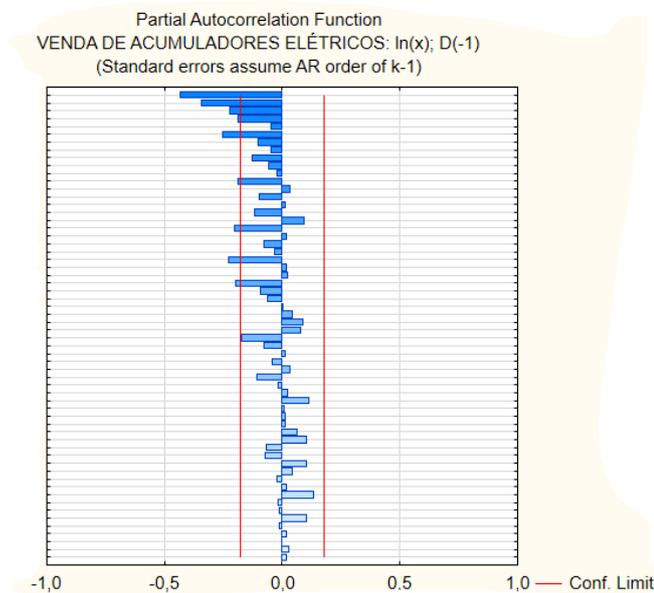


Figura 4.1.12 Correlograma de autocorrelação parcial para a série temporal transformada em ln(x) e D(-1) – 60 defasagens.  
Fonte: O Autor

Como evidenciado no tópico anterior, há um padrão sazonal na serie temporal, visualizado através da FACP. Por esta razão, definiremos a priori uma variação sazonal anual com um fator de diferenciação para a componente sazonal  $D=1, D(1)$ .

Nas figuras 4.1.13 e 4.1.14, é também possível visualizar que os correlogramas apresentam também um padrão senoidal no correlograma da FAC e de picos significativos para a FACP até a defasagem 25, indicando que para a parte sazonal da série temporal também possui características autorregressivas AR(P) apenas.

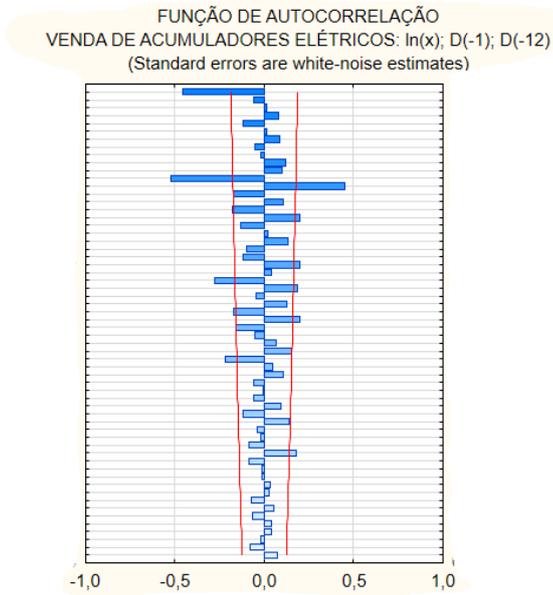


Figura 4.1.13 Correlograma da função de autocorrelação (FAC) para a série temporal transformada em  $\ln(x)$   $d(-1)$  e  $d(-12)$  com 60 defasagens.

Fonte: O Autor

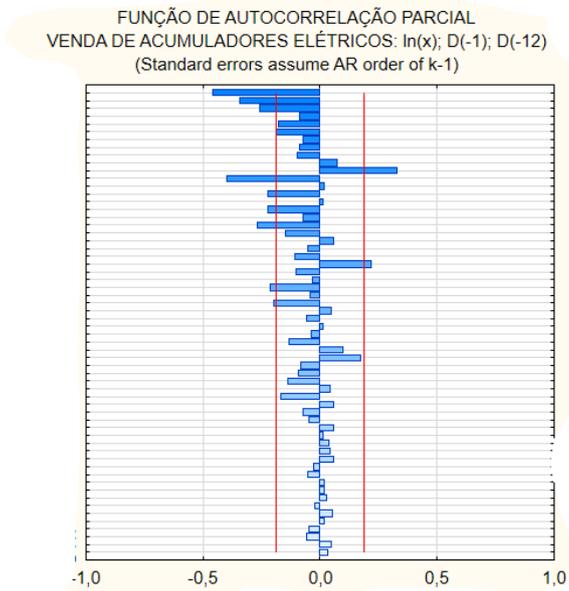


Figura 4.1.14 Correlograma da função de autocorrelação (FACP) para a série temporal transformada em  $\ln(x)$   $d(-1)$  e  $d(-12)$  com 60 defasagens.

Fonte: O Autor

É importante também pontuar que os valores obtidos para o correlograma da autocorrelação são estatisticamente significativos, uma vez que o valor-p para todas as defasagens é menor que o nível de significância  $\alpha = 0,05$  previamente estabelecidos.

Grandes partes das autocorrelações fortes desapareceram com as transformadas que foram efetuadas até o momento, desta forma assumimos que a série como estacionária e continuamos com o processo ARIMA. Mesmo que haja alguns valores com certo grau de autocorrelação é de se esperar que um não cancele o outro a partir de suas diferenças.

Com a série temporal transformada estimamos os valores não sazonais (p,q) e sazonais (P,Q). A estimativa dos valores se dará mais uma vez através dos correlogramas FAC e FACP. Como já observado até o momento para o modelo proposto não teremos valores AM(q) e AMs(Q), já para os valores iniciais para AR(p) e ARs(P) definiremos p=4 e P=3.

Desta forma temos como parâmetros iniciais nesta o seguinte modelo,

- **ARIMA (4,1,0) (3,1,0)**, com um padrão sazonal S=12.

Sendo,

Valores não sazonais, AR(p) = 4; d=1; AM(q)=0.

Valores sazonais, AR(P)=3; d=1; AM(Q)=0.

#### 4.1.2 FASE DE ESTIMAÇÃO

Uma vez identificado os valores para  $p$ ,  $d$ ,  $q$ ,  $P$ ,  $D$  e  $Q$ , o próximo estágio consiste em estimar os parâmetros do modelo SARIMA. Como citado anteriormente podemos realizar tais cálculos através dos mínimos quadrados simples ou até mesmo de estimação não linear. Para a estimativa dos valores do modelo proposto utilizaremos mais uma vez o software *Statistica*. Os resultados dos parâmetros do modelo SARIMA (4, 1, 0) (3, 1, 0) podem ser observados na TABELA 4.1.2,

**Tabela 4.1.2 Parâmetros para o modelo SARIMA (4,1,0) (3,1,0)<sub>12</sub>.**

VENDA DE ACUMULADORES ELÉTRICOS						
Transformations: ln(x),D(1),D(12)						
Model:(4,1,0)(3,1,0) Seasonal lag: 12 MS Residual= ,21260						
Parametros	Param.	Asympt. Std.Err.	Asympt. t( 100)	p	Lower 95% Conf	Upper 95% Conf
p(1)	-0,70165	0,103253	-6,79545	0,000000	-0,90650	-0,496801
p(2)	-0,64014	0,114462	-5,59262	0,000000	-0,86723	-0,413052
p(3)	-0,42428	0,114095	-3,71866	0,000331	-0,65064	-0,197920
p(4)	-0,21461	0,101377	-2,11693	0,036747	-0,41574	-0,013479
Ps(1)	-1,04403	0,108620	-9,61175	0,000000	-1,25953	-0,828530
Ps(2)	-0,90416	0,150620	-6,00289	0,000000	-1,20298	-0,605332
Ps(3)	-0,57390	0,153955	-3,72773	0,000320	-0,87934	-0,268460

O que podemos observar da tabela acima é que o parâmetro sazonal P(s) apresentou um parâmetro fora do intervalor [-1;1], o que poderá caracterizar o processo como não

estacionário, sendo assim necessário reavaliar a quantidade de parâmetros e também a variação sazonal do modelo.

Após um “n” número de calibrações no modelo originalmente proposto na fase de identificação é sugerido o seguinte modelo SARIMA pra o trabalho, é importante notar que há uma necessidade de se buscar o modelo que envolva o mínimo de parâmetros possíveis a ser estimado e que explique bem o comportamento da variável.

Com o modelo **SARIMA (1,1,0) (3,1,0)<sub>12</sub>**, com uma sazonalidade anual. Os parâmetros finais podem ser observados na TABELA 4.2.2,

**Tabela 4.1.3 Parâmetros para o modelo SARIMA (1,1,0) (3,1,0)<sub>12</sub>.**

VENDA DE ACUMULADORES ELÉTRICOS						
Transformations: ln(x),D(1),D(12)						
Model:(1,1,0)(3,1,0) Seasonal lag: 12 MS Residual= .27006						
Paramet.	Param.	Asympt. Std.Err.	Asympt. t( 103)	p	Lower 95% Conf	Upper 95% Conf
p(1)	-0,428925	0,095959	-4,46987	0,000020	-0,61924	-0,238613
Ps(1)	-0,973487	0,105442	-9,23248	0,000000	-1,18261	-0,764369
Ps(2)	-0,878478	0,152449	-5,76245	0,000000	-1,18082	-0,576132
Ps(3)	-0,658796	0,161542	-4,07816	0,000090	-0,97918	-0,338415

Note que os parâmetros são estatisticamente significantes para o modelo em questão

#### 4.1.3 VERIFICAÇÃO DE DIAGNÓSTICO

Como citado nos capítulos anteriores, o objetivo nesta etapa é conferir se o modelo proposto é adequado. Uma das metodologias para a validação do modelo é garantir que os resíduos são independentes entre si, fato que pode ser comprovado pela análise do correlograma da função de autocorrelação. Comprova-se a partir da FIGURA 4.2.4 que os resíduos são independentes e individualmente não significativos.

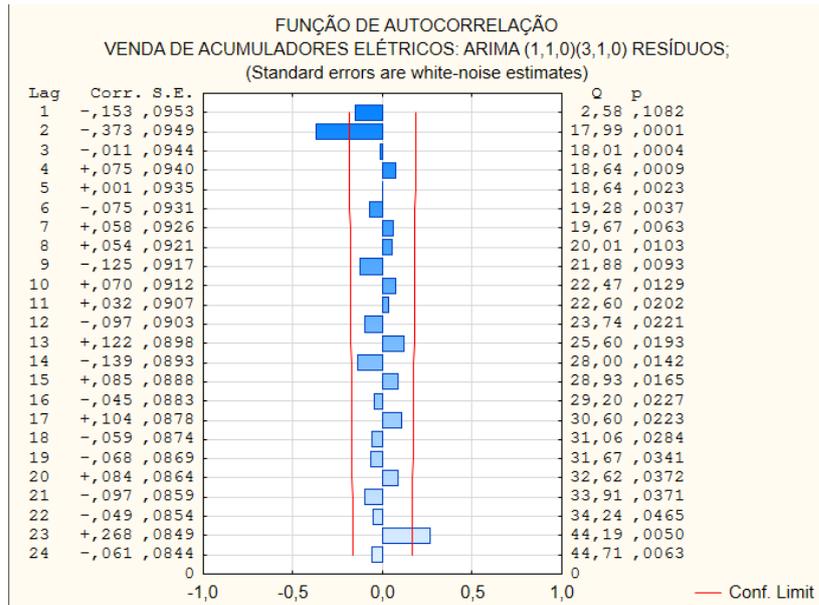


Figura 4.2.4 Função de Autocorrelação dos Resíduos para o modelo ARIMA SARIMA (1,1,0) (3,1,0)<sub>12</sub>  
 Fonte: O Autor

Sendo os resíduos estatisticamente independentes entre si eles se eles estarão distribuídos normalmente, FIGURA 4.2.5.

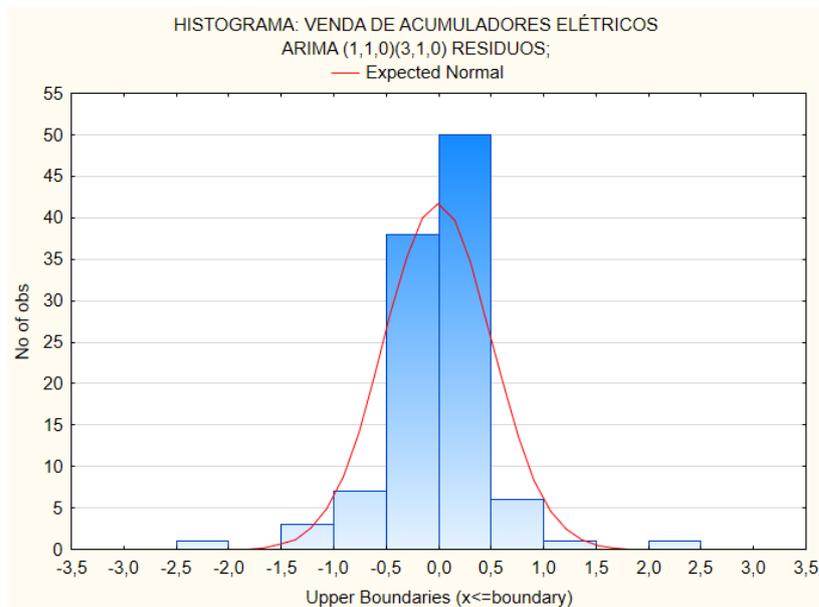


Figura 4.2.5 Histograma da distribuição normal para os resíduos do modelo SARIMA (1,1,0) (3,1,0)<sub>12</sub>  
 Fonte: O Autor

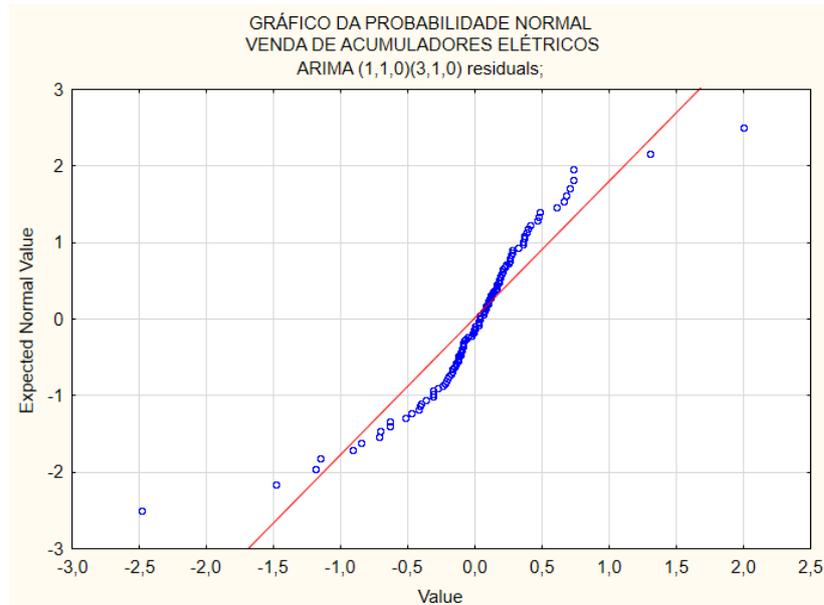


Figura 4.2.6 da distribuição normal para os resíduos do modelo SARIMA (1,1,0)(3,1,0)<sub>12</sub>  
 Fonte: O Autor 2018

Comprovada a adequação do modelo é possível seguir para a última fase, que corresponde a de previsão.

#### 4.1.4 PREVISÃO

De posse do modelo adequado podemos prever aproximadamente qual será o comportamento da série para os próximos períodos. Para o cálculo computacional no Software Statistica será utilizado o método aproximado de McLeod & Sales. Os resultados para o modelo após a convergência e as iterações podem ser visualizados na TABELA 4.2.8.

Com os parâmetros definidos a próxima etapa consiste em gerar as previsões para um período  $t+n$ , de acordo com a necessidade de previsão, os resultados para as previsões podem ser visualizado na tabela 4.1.4 e na figura 4.2.9. Apesar da previsão para todo o ano de 2018 é aconselhável um horizonte de planejamento com uma revisão trimestral uma vez que um longo horizonte de planejamento pode vir a comprometer a eficiência do modelo pelo fato de carregar os erros através de suas iterações.

**Tabela 4.1.4 Previsão de Venda de Acumuladores Elétricos para o período  $t_{120}+12$ .**

Fonte: O autor (2018)

Período	Previsão	Limite de Confiança Inferior	Limite de Confiança Superior
Janeiro 2018	16326,59	5824,895	45761,8
Fevereiro 2018	6911,46	2109,192	22647,7
Março 2018	15462,56	3740,327	63922,4

<b>Abril 2018</b>	12071,99	2483,786	58673,7
<b>Mai 2018</b>	13263,01	2322,755	75732,2
<b>Junho 2018</b>	2835,93	431,044	18658,2
<b>Julho 2018</b>	3667,25	487,475	27588,6
<b>Agosto 2018</b>	16848,36	1976,924	143590,4
<b>Setembro 2018</b>	12000,31	1251,029	115111,2
<b>Outubro 2018</b>	14593,25	1359,854	156607,2
<b>Novembro 2018</b>	17876,17	1496,426	213547,1
<b>Dezembro 2018</b>	16283,61	1230,025	215569,6

A tabela 4.1.4 pode ser representada pelo gráfico 4.4.13

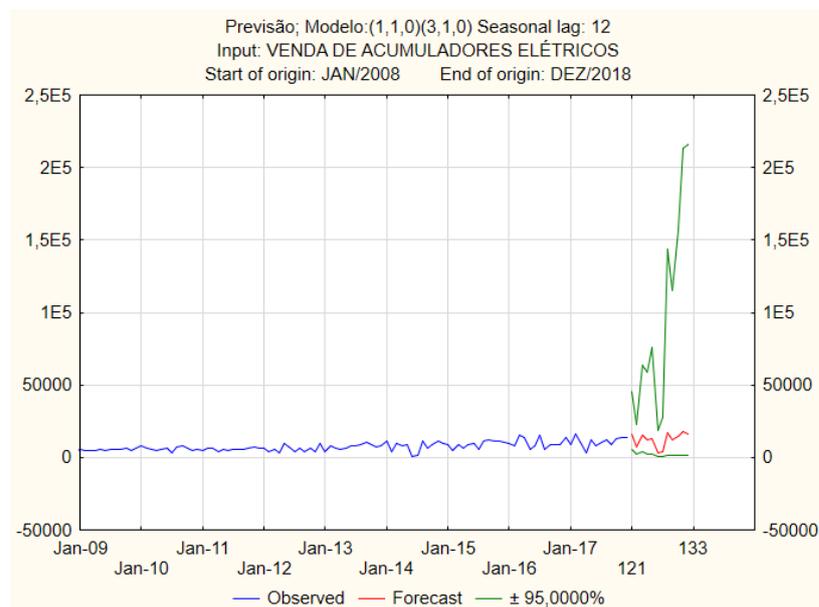


Figura 4.2.9 Previsão de demanda para o modelo ARIMA (1,1,0)(3,1,0)<sub>12</sub>

Fonte: O Autor

## 4.2 Análise de erros e adaptação do modelo

Um dos critérios para se validar um modelo proposto e o seu desempenho com relação a serie temporal analisada é a utilização de métricas para se medir a aderência dos planos a realidade. Uma destas métricas é o WMAPE – *Weighted Mean Absolute Percentage Error*, ou Erro Percentual Absoluto Médio Ponderado.

O WMAPE irá nos dizer em média o quanto a previsão foge do real no nível de agregação de cálculo, sem a compensação de erros de negativos e positivos.

O calculo do WMAPE considerando a média dos erros de todos os períodos ponderada pelo volume de vendas pode ser explicitado da seguinte forma,

O resultado do WMAPE indicara que em  $X\%$  dos dados haverá um erro de previsão, a acurácia por sua vez poderá ser medida subtraindo-se de 100% o resultado do MAPE (Eq. 15).

$$(Eq. 14) \text{ WMAPE} = 100\% - (100) \times \frac{\sum_{t=1}^n \frac{|A_t - Y_t| \times Y_t}{A_t}}{\sum_{t=1}^n |A_t|}$$

$$(Eq. 15) \text{ Acurácia} = 100\% - \text{WMAPE}$$

Onde:

$A_t$  = Volume de vendas no período.

$Y_t$  = Estimativa de vendas no período.

Para o modelo proposto neste trabalho e utilizando os 12 meses do ano de 2017 teriam o seguinte resultado:

**Tabela 4.2.1 Acurácia para o modelo SARIMA (1,1,0) (3,1,0)<sub>12</sub>**  
Fonte: O Autor

Período	Vendas	Estimativa	Erro Absoluto	Erro % Absoluto
Janeiro 2017	8944	8176,81	767,19	8,58%
Fevereiro 2017	15869	10031,47	5837,53	36,79%
Março 2017	10317	11057,51	740,51	7,18%
Abril 2017	3542	9914,05	6372,05	179,90%
Mai 2017	11988	10638,33	1349,67	11,26%
Junho 2017	8347	7638,10	708,90	8,49%
Julho 2017	10299	7886,07	2412,93	23,43%
Agosto 2017	12584	14150,36	1566,36	12,45%
Setembro 2017	8786	14088,83	5302,83	60,36%
Outubro 2017	12951	13460,30	509,30	3,93%
Novembro 2017	13481	13060,89	420,11	3,12%
Dezembro 2017	13529	13046,04	482,96	3,57%
			<b>WMAPE</b>	<b>20,26%</b>
			<b>ACURÁCIA</b>	<b>79,74%</b>

Considerando o ano de 2017 teríamos uma acurácia de aproximadamente 80%. Tal resultado pode ser considerado de bom para ótimo, porém se observamos na série de vendas há no mês de Abril de 2017 uma disrupção de vendas, onde por algum motivo o volume de vendas foi agressivamente abaixo do esperado para o período gerando um erro absoluto de 179%. Um exercício que podemos realizar é desconsiderar esta disrupção na série histórica, com este ajuste teríamos uma acurácia bem mais elevada (**Tabela 4.2.2**) do que vislumbrado anteriormente.

**Tabela 4.2.2 Acurácia ajustada para o modelo SARIMA (1,1,0) (3,1,0)<sub>12</sub>**  
Fonte: O Autor

Período	Venda	Estimativa	Erro Absoluto	Erro % Absoluto
Janeiro 2017	8944	8176,81	767,19	8,58%
Fevereiro 2017	15869	10031,47	5837,53	36,79%
Março 2017	10317	11057,51	740,51	7,18%
Mai 2017	11988	10638,33	1349,67	11,26%
Junho 2017	8347	7638,10	708,90	8,49%
Julho 2017	10299	7886,07	2412,93	23,43%
Agosto 2017	12584	14150,36	1566,36	12,45%
Setembro 2017	8786	14088,83	5302,83	60,36%
Outubro 2017	12951	13460,30	509,30	3,93%
Novembro 2017	13481	13060,89	420,11	3,12%
Dezembro 2017	13529	13046,04	482,96	3,57%
<b>WMAPE</b>				<b>15,81%</b>
<b>ACURÁCIA</b>				<b>84,19%</b>

Como pode ser observado ao passarmos a considerar o mês de Abril de 2017 como um outlier na série temporal conseguimos aumentar em aproximadamente 4,5% a medida de acurácia para o período em estudo.

Com esta análise é possível garantir e validar que o modelo SARIMA (1,1,0) (3,1,0)<sub>12</sub> proposto neste trabalho adequa-se ao objetivo de prever a venda total de acumuladores elétricos para o cliente em estudo e pode servir como input para uma melhor tomada de decisão no que se diz respeito ao planejamento das operações logísticas.

### 4.3 Implicações gerenciais

Abordando o campo gerencial da previsão de demanda e os efeitos das decisões tomadas também no nível estratégico, é possível compreender que uma gestão eficiente da demanda impacta de forma favorável o desempenho de uma cadeia de suprimento.

Quanto maior o nível de adesão no que se diz respeito ao planejamento e a estruturação das metodologias e ferramentas de previsão de demanda mais eficiente será a compreensão das necessidades do cliente e consequentemente melhor será o indicador do nível serviço, além de ganhos relacionados à redução de custo, aumento do giro de estoque e velocidade de atendimento entre os elos de uma cadeia.

O uso eficiente de ferramentas de previsão de demanda, aliada a outras metodologias de gestão, agrega valor a qualquer tipo de empresa. Uma vez que ela se torna capaz de entender as necessidades dos clientes internos ou externos e consegue suprir os desejos de consumo no que se refere à natureza temporal, espacial e grau de variabilidade e de

aleatoriedade da demanda, sem causar prejuízos dentro da cadeia de suprimentos, evitando uma disfunção dentro da rede.

Compreender a oscilação da demanda em diferentes períodos beneficia a tomada de decisão de curto prazo, facilitando, por exemplo, o gerenciamento dos níveis de inventário na medida em que se aumenta o giro do estoque dos produtos fornecidos ou necessários para o funcionamento de determinada rede de suprimentos, porém para que esse efeito seja alcançado é necessário o envolvimento e aprovação da alta gerência, com o objetivo de alinhar expectativas do que se deseja alcançar com as análises da demanda, e dos esforços necessários para se construir ou aprimorar um modelo que levará informação a outros participantes da cadeia.

Uma eficiente gestão de planejamento e previsão da demanda afeta diversos aspectos dentro de uma cadeia de suprimentos, tais como custos de aquisição de insumos, manutenção de estoques, custos de transporte, custos de movimentação e armazenagem além de agregar o nível de serviço ao cliente, retendo atuais consumidores e conquistando clientes de outras marcas, gerando para a empresa e toda a cadeia de suprimentos nela envolvida um aumento no excedente de capital.

Por este motivo, busca-se com os resultados apresentados no trabalho, validar o uso de ferramentas mais robustas e auxiliar no direcionamento do tomador de decisão. Auxiliando na garantia do cumprimento do nível de serviço, na diminuição dos níveis de estoque, redução de custos, e em uma maior responsividade na cadeia de suprimentos Particularidades que são mais facilmente alcançadas através da aplicação de metodologias quantitativas que agregam valor e dão uma maior solidez no campo do planejamento das operações.

## 5 CONCLUSÃO

Estudar, analisar e criticar séries temporais estruturadas deve ser uma atividade obrigatória e presente nas funções desempenhadas por departamentos de planejamento de operações, auxiliando na solução de problemas mais imediatos e fornecendo uma visão eficiente de como os clientes podem se comportar ao longo de um determinado período.

Trabalhar com dados tão bem estruturados como series temporais univariadas não é mais um diferencial competitivo e sim uma atitude imprescindível para o sucesso e sustentabilidade dos negócios empresariais, vindo a ditar a sobrevivência e sustentabilidade da organização. Por esta razão sugere-se a aplicação da metodologia desenvolvida por Box & Jenkins para a análise de séries temporais.

Por esta razão este trabalho utilizou a metodologia Box-Jenkins e analisou se a aplicação da metodologia agregaria valor as análises que são utilizadas atualmente na empresa em questão.

Foi avaliado neste trabalho se a aplicação do método SARIMA poderia vir a agregar valor ao processo de tomada de decisão no que se refere às tarefas de planejamento das operações. Com a aplicação da metodologia Box-Jenkins foi possível definir e validar um modelo SARIMA  $(1,1,0) (3,1,0)_{12}$  que alcança uma acurácia notável para os padrões definidos no estudo em questão, validando a ideia original de que a ferramenta em estudo pode ser aplicada nas atividades de planejamento.

O trabalho desenvolvido mostra-se eficiente quanto à qualidade dos resultados, porém é necessário pontuar que as soluções aqui apresentadas para as previsões não devem ser utilizadas como ponto único para a tomada de decisão, é necessário complementar que há uma necessidade da visão e de uma análise qualitativa do tomador de decisão e de sua equipe, pois o *know-how* é de suma importância em situações que envolvem o planejamento e a previsão.

Ressalta-se que o trabalho realizado serve como base para o desenvolvimento de novos modelos ARIMA ou SARIMA, tais trabalhos deverão abranger de forma mais eficiente e gradual toda a gama de clientes da empresa em estudo, dividindo a cartela de produtos em famílias, mercados de destino, mercados de origem ou qualquer outra classificação que melhor se aplique a temática em estudo. Um dos objetivos é desenvolver uma gestão do planejamento mais eficiente e compreender o comportamento do mercado, provendo informações com credibilidade e que possam dar suporte as tomadas de decisões.

Além de outras segmentações que a modelagem proposta por Box-Jenkins pode alcançar é importante notar que há uma gama de ferramentas que também podem ser utilizadas para uma melhor eficiência logística no que se diz respeito ao planejamento e

previsão de demanda como a utilização de Redes Neurais, *Big Data*, Simulações e tecnologias Blockchain.

## REFERÊNCIAS

- BALLOU, R. H. **Gerenciamento da cadeia de suprimentos – Planejamento, Organização e Logística empresarial**. - 4ª ed - São Paulo: Bookman, 2001
- BALLOU, R. H. **Logística empresarial: transportes, administração de materiais e distribuição física**. São Paulo: Atlas, 2001
- CHAMBERS, J. C., MULICK, S. K., SMITH, D. D.. **How to Choose the Right Forecasting Technique**. Harvard Business Review 64. (January –February 1986): 110-120.
- CHASE, R. B.. **Administração da produção para a vantagem competitiva**. Porto Alegre. Bookman, 2006.
- CHOPRA, S., MEINDL, P.. **Gestão da cadeia de suprimentos: estratégia, planejamento e operações**. 4ª Ed. Pearson, 2011.
- EDIGER, V. S., AKAR, S., UGURLU, B. **Forecasting production of fossil fuel sources in Turkey using a comparative regression and ARIMA model**. Elsevier. 2005
- G.P. BOX, G.M. JENKINS, **Time Series Analysis: Forecasting and Control**. Holden-Day, San Francisco, CA, 1976.
- GERHARDT, T.; SILVEIRA, D. **Métodos de Pesquisa**, 1 ed. Porto Alegre: UFRGS, 2009
- GIL, A. C. **Como elaborar projetos de pesquisa**. 4.ed. São Paulo: Atlas, 2002
- GUJARATI, D. N.. **Econometria básica**. 5 ed.. Porto Alegre. Bookman, 2011.
- MAKRIDAKIS, S.; WHEELWRIGHT, S.; HYNDMAN, R. J.. **Forecasting methods and applications**. 3. ed. New York: John Wiley & Sons, 1998.
- MATOS, O. C. **Econometria básica: teoria e aplicações**. São Paulo: Atlas, 2000
- MIRANDA, R. G.; GERBER, J. Z; BORNIA, A. C.; FREIRES, F. G. M. **Método estruturado para o processo de planejamento da demanda nas organizações**. In: Congresso Internacional de Administração, 2011. Anais eletrônicos... Ponta Grossa, 2011.
- MORRETIN, P. A.; TOLOI, C. M. C. **Previsão de séries temporais**. 2. ed. São Paulo: Atual Editora, 1987.
- RIBEIRO, A. R.. **Previsão de demanda: Estudo de Caso na Cadeia de Suprimentos**. Pontifícia Universidade Católica do Rio de Janeiro. PPG em Engenharia de Produção. 2009. Certificação Digital Nº 0621498/CA.
- TSENG, F., TZENG, G.. **A fuzzy seasonal ARIMA model for forecasting**. Elsevier. 2001.

WERNER, L. & RIBEIRO, J. L. D. **Previsão de demanda: uma aplicação dos modelos Box-Jenkins na área de assistência técnica de computadores pessoais.** Gestão & Produção, volume 10, no.1. São Carlos, 2003.

ZHANG, G.P., 2001. **Time series forecasting using a hybrid ARIMA and neural network model.** Neurocomputing. 50, 159–175.