

PAULA BUENO DE CASTRO

**DESENVOLVIMENTO DE MODELO AUTO REGRESSIVO PARA A
PREVISÃO DE DEMANDA DE PRODUTOS DE UMA INDÚSTRIA DO SETOR
DE COSMÉTICOS**

Guaratinguetá
2015

PAULA BUENO DE CASTRO

DESENVOLVIMENTO DE MODELO AUTO REGRESSIVO PARA A
PREVISÃO DE DEMANDA DE PRODUTOS DE UMA INDÚSTRIA DO SETOR
DE COSMÉTICOS

Trabalho de Graduação apresentado ao Conselho de Curso de Graduação em Engenharia de Produção Mecânica da Faculdade de Engenharia do Campus de Guaratinguetá, Universidade Estadual Paulista, como parte dos requisitos para obtenção do diploma de Graduação em Engenharia de Produção Mecânica.

Orientador : Dr - Aneirson Francisco da
Silva

Guaratinguetá
2015

| | |
|-------|--|
| C355d | <p>Castro, Paula Bueno de Desenvolvimento de modelo auto regressivo para a previsão de demanda de produtos de uma indústria do setor de cosméticos / Paula Bueno de Castro – Guaratinguetá, 2015. 45 f : il. Bibliografia: f. 41-42</p> <p>Trabalho de Graduação em Engenharia de Produção Mecânica – Universidade Estadual Paulista, Faculdade de Engenharia de Guaratinguetá, 2015. Orientador: Prof. Dr. Aneíson Francisco da Silva</p> <p>1. Previsão na administração 2 Cosméticos – Industria 3. Oferta e procura 4. Modelos matemáticos I. Título</p> <p style="text-align: right;">CDU 658</p> |
|-------|--|

PAULA BUENO DE CASTRO

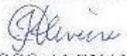
ESTE TRABALHO DE GRADUAÇÃO FOI JULGADO ADEQUADO COMO PARTE
DO REQUISITO PARA A OBTENÇÃO DO DIPLOMA DE "GRADUADO EM
ENGENHARIA DE PRODUÇÃO MECÂNICA"

APROVADO EM SUA FORMA FINAL PELO CONSELHO DE CURSO DE
GRADUAÇÃO EM ENGENHARIA MECÂNICA


Prof. Dr. ARMINDA EUGENIA MARQUES CAMPOS
Coordenador

BANCA EXAMINADORA:


Prof. Dr. ANEIRSON FRANCISCO DA SILVA
Orientador/UNESP-FEG


Prof. Dr. FRANCISCO ALEXANDRE DE OLIVEIRA
UNESP-FEG


Prof. Dr. JOSÉ ROBERTO DALE LUCHE
UNESP-FEG

Dezembro 2015

AGRADECIMENTOS

Agradeço a Deus em primeiro lugar por sempre ter guiado a minha vida e meu destino, pela família que me deu, pela minha saúde e das pessoas queridas próximas a mim, pelas oportunidades e por todos os momentos de aprendizado e felicidade.

Agradeço aos meus pais *Antônio Carlos de Castro* e *Flávia Carneiro Bueno de Castro* por sempre acreditarem em mim mesmo quando eu mesma não acreditava e por terem sido meu porto seguro em vários momentos da minha trajetória, proporcionando sempre amor incondicional, coragem, carinho e fé.

Às minhas irmãs *Marina Bueno de Castro* e *Camilla Bueno de Castro* por serem minhas companheiras e protetoras mesmo morando à distância já por muitos anos. À minha avó *Jeldeni Carneiro Pereira Bueno* por sempre ter sido um exemplo de respeito, força e companheirismo. À minha tia *Fernanda Bueno Guaraldo* pelas conversas filosóficas e mimos de madrinha. E todos os membros da minha família que de alguma forma contribuíram para o meu desenvolvimento.

Agradeço a todos os meus amigos que sempre estiveram comigo, sendo parceiros e representando minha segunda família, em especial à *Marcela Belotti da Silva* e *Sâmara Vilela Rodrigues* minhas eternas irmãs de coração, *Carolina Leite de Moraes*, *Nelise Acorinti* e *Laura Duarte Meirelles* minhas veteranas preferidas de faculdade e de vida, *Nathália Marques Guerreiro* e *Thaís Rodrigues Alves Lopes* companheiras em todos os momentos de felicidade e dificuldades que já passamos, *Bernardo Garcia* por todas as estendidas de mão e amizade em todos os momentos que precisei.

Agradeço também ao meu orientador, *Prof. Dr. Aneirson Francisco da Silva* por ser presente durante o desenvolvimento deste trabalho e por estar sempre disponível paciente e bem humorado para ajudar no que fosse preciso nessa última etapa da faculdade.

“Que a importância de uma coisa não se mede com fita métrica nem com balanças nem barômetros etc. Que a importância de uma coisa há que ser medida pelo encantamento que a coisa produza em nós.”

Manoel de Barros

CASTRO, P. B. **Desenvolvimento de modelo auto regressivo para a previsão de demanda de produtos de uma indústria do setor de cosméticos.** 2015. p. 45. Trabalho de Graduação (Graduação em Engenharia Mecânica) – Faculdade de Engenharia do Campus de Guaratinguetá, Universidade Estadual Paulista, Guaratinguetá, 2015.

RESUMO

A previsão de demanda na indústria de cuidados de beleza e cosméticos é complexa devido à existência de uma vasta gama de referências de produtos, que sofrem inovações continuamente, resultando ou em falta ou poucos dados históricos de vendas. Existe um número insuficiente de estudos da literatura para prever demandas sazonais na indústria de cuidados de beleza. O objetivo desse trabalho é construir um modelo matemático de apoio à decisão para previsões acuradas de demanda que possa ser replicada nesse tipo de indústria, e assim verificar a confiabilidade do modelo de previsão. Este estudo emprega o uso do método auto-regressivo SARIMA para modelar os dados, uma vez que serão tratadas séries temporais com sazonalidade.

Os dados utilizados se referem às vendas de um produto do setor de cosméticos ao longo dos anos de 2012 a 2015, coletados em períodos quinzenais em uma indústria multinacional de cosméticos e cuidados para a beleza localizada na cidade de São Paulo-SP. O estudo inclui a aplicação na vida real do modelo matemático proposto para a geração de valores de demanda do produto em questão.

Segundo Bertrand e Fransoo (2002), esta pesquisa é classificada com uma pesquisa aplicada, pois visa proporcionar melhorias para a literatura atual. A forma de abordar o problema é quantitativa sendo o método de pesquisa a modelagem.

PALAVRAS CHAVE: SARIMA. Indústria de cosméticos. Previsão. Demanda.

CASTRO, P. B. **Autoregressive development model for forecasting demand for products of the cosmetics industry sector.** 2015. p. 45. Graduate Work (Graduate in Industrial Engineering) – Faculdade de Engenharia do Campus de Guaratinguetá, Universidade Estadual Paulista, Guaratinguetá, 2015.

ABSTRACT

The demand forecast in beauty care and cosmetics industry is complex due to the existence of a wide range of products which suffers continuously innovation, resulting in a lack of or few historical sales data.

There are an insufficient number of studies in the literature to predict seasonal demand in the beauty care industry. The aim of this work is to build a mathematical model of decision support for accurate forecasts that can be replicated in this type of industry, and so check the reliability of the forecasting model. This study employs the use of autoregressive method SARIMA to model the data as they are temporal series.

The data refers to sales of a cosmetics industry's product over the years 2012 to 2015, collected every fifteen day in a multinational cosmetic enterprise located in the city of São Paulo-SP. This study includes a real-life application of the mathematical model proposed.

According to Bertrand and Fransoo (2002), this research is classified as an applied research because it aims to provide improvements to the current literature. The way to approach the problem is quantitative and the research method is modeling.

KEYWORDS: SARIMA. Cosmetics industry. Forecast. Demand.

LISTA DE FIGURAS

| | |
|---|--------------------------------------|
| Figura 1- Itens publicados por ano | |
| Figura 2- Citações por ano..... | Erro! Indicador não definido. |
| Figura 3- Representatividade dos países no mercado global de venda direta | 15 |
| Figura 4-Vendas globais por categorias na América do sul | Erro! Indicador não definido. |
| Figura 5-Fluxograma - método de pesquisa | 17 |
| Figura 6-Quadro Representativo dos Estágios do Ciclo Iterativo de Box-Jenkins | 18 |
| Figura 7-Ruído Branco | 25 |
| Figura 8-Autocorrelação/Estacionariedade | 30 |
| Figura 9-Teste Aumentado de Dickey-Fuller | 30 |
| Figura 10- Correlograma série original | 31 |
| Figura 11- Gráfico de sazonalidade | 32 |
| Figura 12- Correlograma | Erro! Indicador não definido. |
| Figura 13-Correlograma série derivada | 33 |
| Figura 14-Teste aumentado de Dickey- Fuller | 34 |
| Figura 15-Correlograma | 34 |
| Figura 16-Gráfico de Sazonalidade | 35 |
| Figura 17-Modelo gerado | 36 |
| Figura 18-Modelo SARIMA (0,1,1) x (1,0,1) | 37 |
| Figura 19-Gráfico comparativo entre demanda real e a primeira previsão | 38 |
| Figura 20 – Gráfico comparativo entre demanda real e segunda previsão..... | 38 |

LISTA DE TABELAS

| | |
|---|----|
| Tabela 1 - Série temporal do produto analisado | 43 |
| Tabela 2 - Previsão do Modelo com série derivada..... | 44 |
| Tabela 3-Previsão real do modelo com derivação..... | 44 |
| Tabela 4-Demanda real do produto | 44 |
| Tabela 5-Demanda estimada pela empresa | 45 |

LISTA DE ABREVIATURAS E SIGLAS

| | |
|--------|--|
| ABEVD | Associação Brasileira de Empresas de Vendas Diretas |
| AR | Auto-Regressivo |
| ARIMA | Auto-Regressivo Integrado de Médias Móveis |
| ARMA | Médias Móveis Auto Regressivas |
| DF | Dickey-Fuller |
| EQM | Erro Quadrático Médio |
| FAC | Funções de Auto correlações |
| FACP | Funções de Autocorrelações Parciais |
| MA | Médias Móveis |
| MAD | <i>Mean Absolute Deviation</i> |
| MAPE | <i>Mean Absolute Percentage Error</i> |
| PP | Phillips-Perron |
| SARIMA | Auto-regressivos Sazonais Integrados de Médias Móveis |
| WFDSA | <i>World Federation of Direct Selling Associations</i> |

SUMÁRIO

| | |
|--|----|
| 1 INTRODUÇÃO | 11 |
| 1.1 OBJETIVOS | 13 |
| 1.1.1 Objetivos específicos | 13 |
| 1.2 DELIMITAÇÃO E QUESTÕES DE PESQUISA | 13 |
| 1.3 JUSTIFICATIVA | 14 |
| 1.4 MATERIAL E MÉTODOS DE PESQUISA | 16 |
| 2 FUNDAMENTAÇÃO TEÓRICA | 19 |
| 2.1 SÉRIES TEMPORAIS | 19 |
| 2.1.3 Modelos auto-regressivos Lineares Não-Estacionários | 23 |
| 2.2 ERROS DE PREVISÃO | 27 |
| 2.2.1– Erro Absoluto Médio – MAD | 28 |
| 2.2.2– Erro Percentual Absoluto Médio – MAPE | 28 |
| 2.2.3– Erro Quadrático Médio – EQM | 28 |
| 3 DESCRIÇÃO DO PROBLEMA | 29 |
| 3.1 DESCRIÇÃO DO PROBLEMA | 29 |
| 3.2 METODOLOGIA BOX-JENKINS PARA O PRODUTO SOBRE SÉRIE ORIGINAL | 29 |
| 3.2.1 Identificação do modelo | 29 |
| 3.2.2 Estimação do modelo | 31 |
| 3.3 METODOLOGIA BOX-JENKINS PARA O PRODUTO SOBRE SÉRIE DERIVADA | 33 |
| 3.3.1 Identificação do modelo | 33 |
| 3.3.2 Estimação do modelo | 35 |
| 3.3.3 Verificação do modelo | 35 |
| 3.4 PREVISÕES GERADAS PELO MODELO ENCONTRADO | 36 |
| 4 CONCLUSÕES E RECOMENDAÇÕES PARA FUTURAS PESQUISAS | 39 |
| 4.1 VERIFICAÇÃO DOS OBJETIVOS | 39 |
| 4.2 RECOMENDAÇÕES PARA FUTURAS PESQUISAS | 40 |
| REFERÊNCIAS | 41 |
| APÊNDICE A | 43 |

1 INTRODUÇÃO

A Associação Brasileira de Empresas de Vendas Diretas (ABEVD) é uma entidade sem fins lucrativos fundada em 1980 que reúne mais de 65 empresas associadas que atuam nos mais diversos setores da economia, de cosméticos e produtos de limpeza a recipientes plásticos e suplementos nutricionais. A entidade visa promover e desenvolver a venda direta no Brasil e é membro do *World Federation of Direct Selling Associations* (WFDSA), organização que congrega todas as associações nacionais de vendas diretas existentes no mundo.

Segundo a ABEVD, o setor de venda direta no Brasil conta com mais de 4,5 milhões de empreendedores em sua força de vendas e gera cerca de 8 mil empregos diretos no país registrando R\$ 19,5 bilhões em volume de negócios no primeiro semestre de 2015, representando assim um crescimento de 0,7% em relação ao mesmo período do ano anterior.

No entanto, empresas que trabalham com a venda direta como pilar de suas estruturas econômicas enfrentam a necessidade de antecipar estoques e usufruir assim de vantagem competitiva ao mesmo tempo em que necessitam reduzir custos. O desafio é prever com a maior precisão possível qual a quantidade requerida de cada produto e o momento certo em que o mesmo será necessário. É nesse sentido que a Análise e Previsão de demanda se tornam uma ferramenta estratégica nas empresas.

Previsão refere-se em avaliar a probabilidade de valores futuros e a suposição da maioria dos métodos de previsão é que os padrões ou comportamentos passados continuarão nesse futuro (SUCKEY, 2012).

No mundo atual, todos os setores industriais precisam ser adaptáveis às mudanças no ambiente empresarial visando à competição de mercado global. Para tomar decisões relacionadas com a concepção e condução de toda a estrutura logística da empresa, os gerentes devem contar com sistemas de previsão eficientes e precisos. (SUN *et al.*, 2008)

Porém, apesar da importância da previsão de demanda, Huang (2009) expôs que métodos estatísticos frequentemente falham para capturar e gerenciar os componentes de variabilidade aleatória na demanda com precisão.

Para Liang (2011) uma das abordagens para a construção de um modelo de previsão de confiabilidade envolve análise de séries temporais. Métodos de séries temporais

visam reconhecer padrões recorrentes e relações lineares. Exemplos tradicionais são os modelos auto regressivos de média móvel (ARIMA) e o modelo ARIMA sazonal (SARIMA) desenvolvidos por Box e Jenkins (1976).

Este trabalho aplica um modelo avançado de previsão, conhecido por médias móveis sazonais integradas auto-regressivas- SARIMA em uma empresa multinacional de cosméticos e cuidados pessoais localizada no estado de São Paulo, na cidade de São Paulo. Para gerar a previsão foi utilizado o *software* de código aberto Gretl.

Neste contexto, Ritzman e Krajewski (2004), comentam que as previsões são essenciais para decisão, pois permitem analisar quais recursos são vitais, para então, programar com sensatez suas atividades ao longo do tempo.

Nesta pesquisa será investigado o número de pedidos de um produto da empresa de cosméticos utilizando uma série temporal quinzenal que contemplará dados reais dos anos de 2013 até o primeiro semestre de 2015, sendo os dados do segundo semestre de 2015 utilizados para a validação do modelo de previsão.

Na busca de um método que melhor poderia contribuir com esse trabalho encontraram-se os modelos auto-regressivos lineares (MORETTIN, 2006). Os modelos ainda se dividem em Auto-regressivos lineares estacionários:

- Modelo Auto-Regressivo (AR(p));
- Modelo Médias Móveis (MA (q));
- Modelo Médias Móveis Auto Regressivas (ARMA (p,q));

E auto-regressivos lineares não estacionários:

- Auto-regressivo Integrado de Médias Móveis (ARIMA(p,d,q));
- Auto-regressivos Sazonais Integrados de Médias Móveis (SARIMA (p,d,q)X(P,D,Q));

Sendo:

p , parâmetros auto-regressivos; q , parâmetros médias-móveis; d , o nível de diferenciação, a partir do qual a série se torna estacionária. P , parâmetros auto-regressivos sazonais; Q , parâmetros médias-móveis sazonais; D , operador diferença sazonal. A definição e explicação de cada modelo será tratada no Item 2

1.1 OBJETIVOS

Por meio de um estudo quantitativo este trabalho buscou gerar a previsão da demanda quinzenal de um produto de uma empresa multinacional do setor de cosméticos e cuidados pessoais que tem como base de vendas a estrutura de venda direta, por meio de métodos auto-regressivos a fim de evidenciar a utilização de séries temporais para estimar dados futuros. Pretende-se verificar a confiabilidade do estudo bem como o desempenho do método na análise das séries. Os dados coletados serão confrontados com os dados obtidos pelo método sensível a sazonalidade SARIMA.

Dessa forma, comprovando a eficácia do método o estudo poderá contribuir com a aplicação do método em outros segmentos, e o aperfeiçoamento da ferramenta, além de auxiliar as empresas na tomada de decisão.

1.1.1 Objetivos específicos

Utilizar um modelo Auto-Regressivo integrado de médias móveis sazonal-SARIMA na previsão quinzenal de um produto do segmento de maquiagem de uma empresa do setor de cosméticos e cuidados pessoais.

1.2 DELIMITAÇÃO E QUESTÕES DE PESQUISA

Neste trabalho não será estudado métodos de previsão para séries temporais não lineares. Além disso, os dados são referentes a produtos de cosméticos vendidos por meio da venda direta com características de demanda para esse tipo de setor e base de vendas.

Questão de pesquisa: O método SARIMA gerará uma previsão quinzenal confiável para a produção de produtos de uma empresa do setor de cosméticos e cuidados pessoais que tem como a estrutura de vendas a venda direta?

1.3 JUSTIFICATIVA

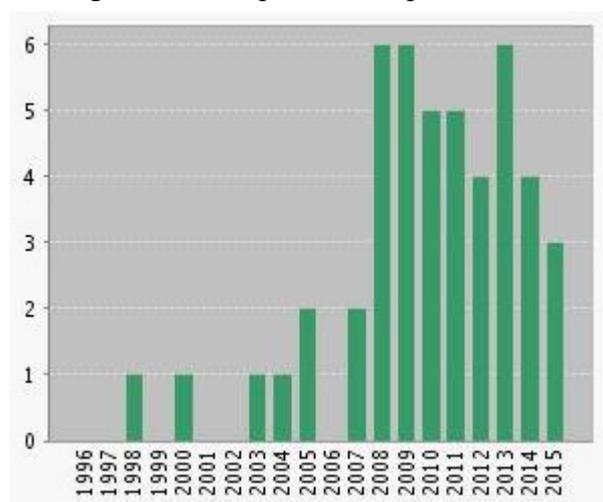
O Brasil é um dos países que mais movimentam dinheiro no mundo com o negócio de venda direta, representando 8% deste mercado no contexto global e se posicionando em quinto lugar no *ranking* de países que relataram um retorno de mais de US\$1 bilhão em vendas anuais no varejo de vendas diretas em 2014. O mercado brasileiro apresenta 4.495.153 de revendedores que atuam em diversos setores, sendo o principal o setor de cosméticos e cuidados pessoais, conforme Figura 4 (*Annual Report 2014 – World Federation of Direct Selling Associations*).

Porém, apesar da representatividade e impacto da venda direta no setor de cosméticos e cuidados pessoais, a previsão da demanda dos produtos que englobam esse setor se torna mais complexa para as indústrias devido à sazonalidade e tendências comerciais nem sempre identificadas, resultando em altas margens de erro e custos.

As empresas devem aprimorar as variáveis que possam diminuir as incertezas, dessa forma analisando uma dessas áreas encontra-se a previsão da demanda no suporte à tomada de decisão, e vê-se justificável o estudo de métodos auto-regressivos e sua contribuição para a análise de previsão (FAVARETTO, 2012).

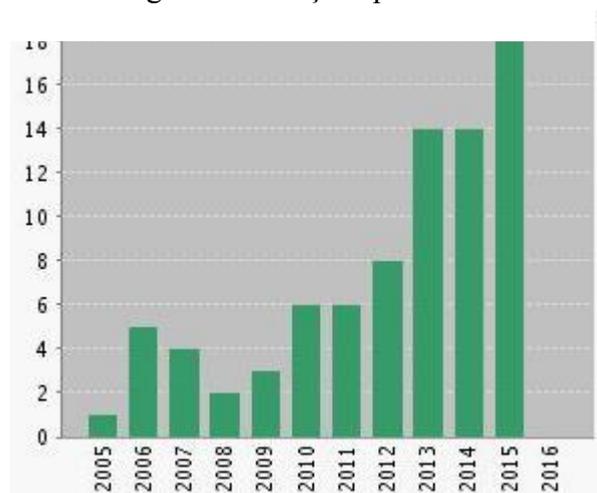
Ao se buscar na literatura estudos que relacione previsões com indústria de cosméticos, como exemplo no banco de dados da Web of Science, se observa poucos resultados relacionando os dois, conforme figura 1 e 2, mostrando assim oportunidades de mais estudos nessa área.

Figura 1- Itens publicados por ano



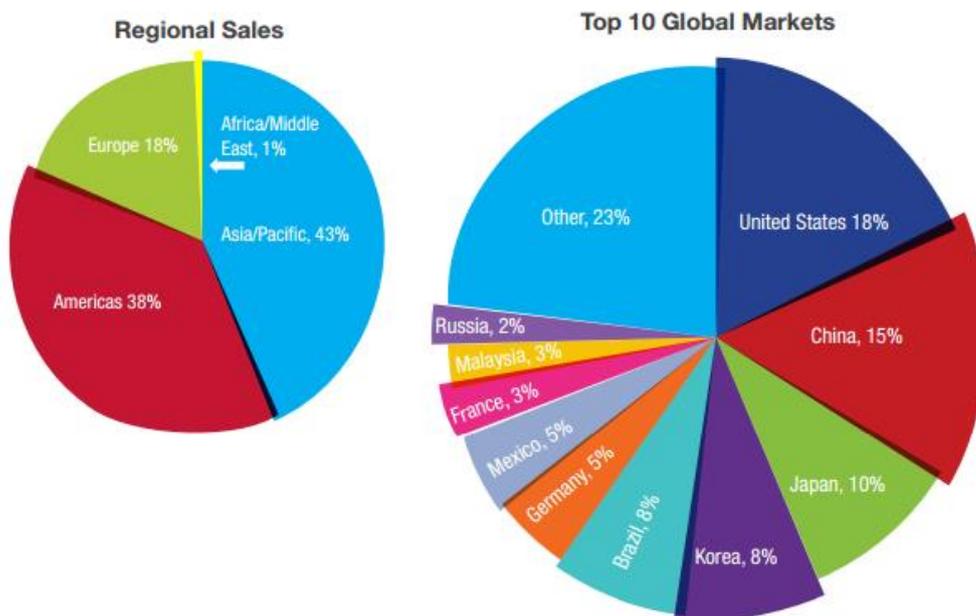
Fonte: Web of Science (2015)

Figura 2 - Citações por ano



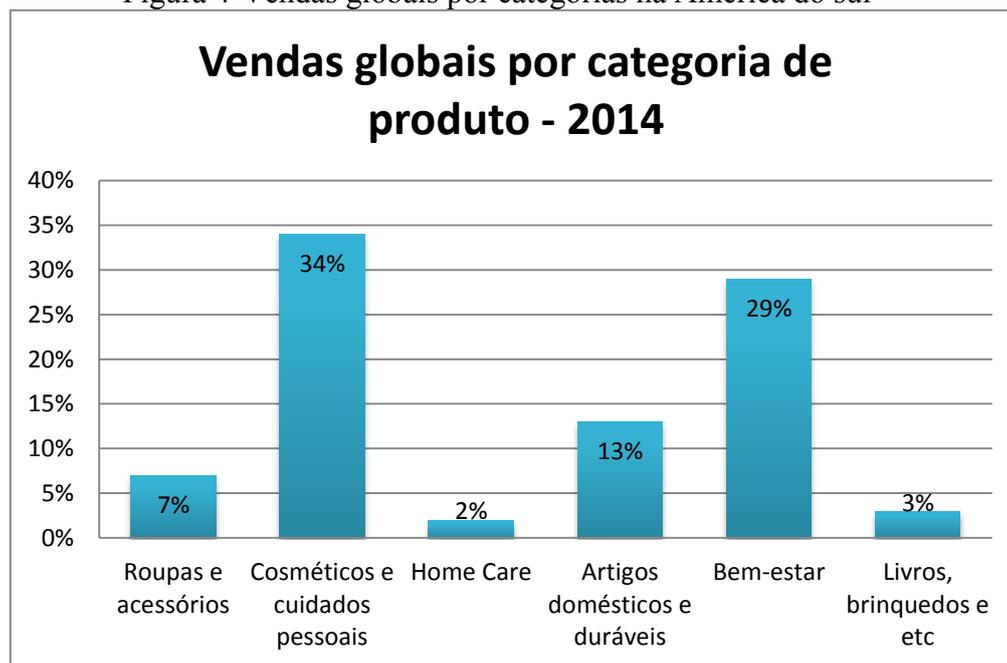
Fonte: Web of Science (2015)

Figura 3-Representatividade dos países no mercado global de venda direta



Fonte: Annual report WFDSA (2014)

Figura 4-Vendas globais por categorias na América do sul

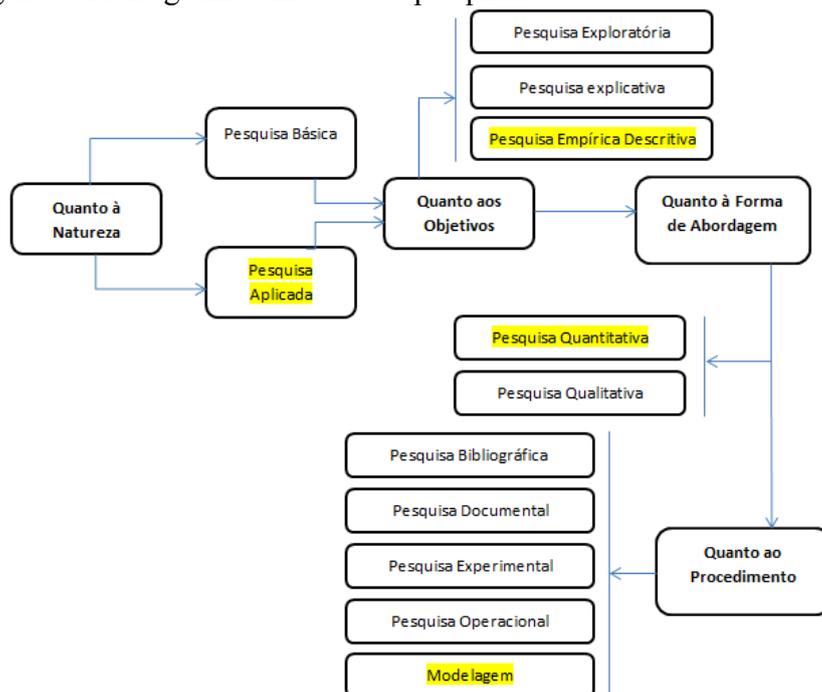


Fonte: Annual report WFDSA (2014)

1.4 MATERIAL E MÉTODOS DE PESQUISA

Segundo Bertrand e Fransoo (2002), esta pesquisa é classificada como uma pesquisa aplicada, pois visa proporcionar melhorias para a literatura atual. Os objetivos são empíricos descritivos, uma vez que se busca desenvolver um modelo que favoreça a compreensão das relações causais que existem em problemas reais. A forma de abordar o problema é quantitativo sendo o método de pesquisa a modelagem, pois a modelagem é o processo de criar e experimentar um sistema físico por intermédio de um modelo matemático computadorizado (CHUNG, 2004). A Figura 5 apresenta o fluxograma do método de pesquisa utilizado neste trabalho.

Figura 5- Fluxograma - método de pesquisa



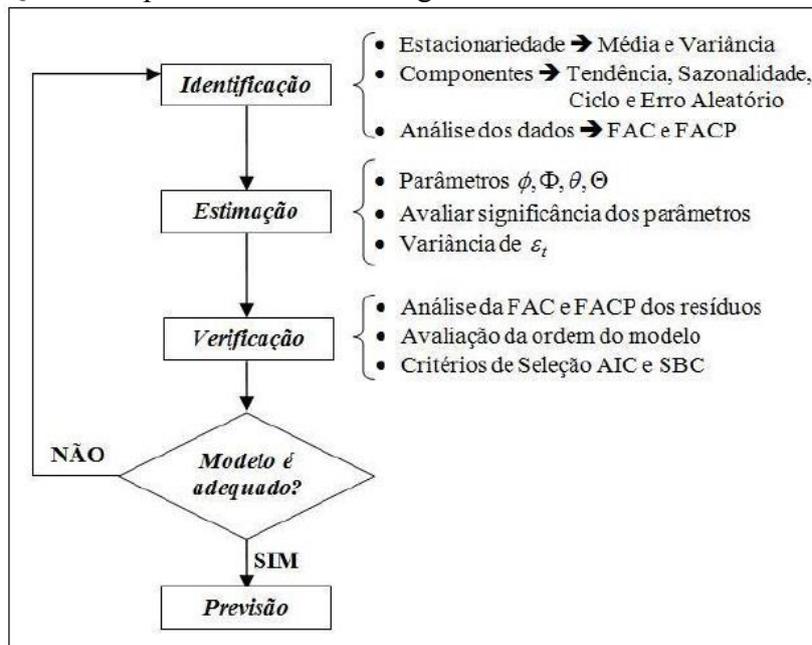
Fonte: (JUNG, 2003).

Sobre os materiais, essa pesquisa investigará modelos de previsão auto-regressivos para séries temporais lineares, como, por exemplo, os métodos ARIMA – Médias Móveis Integradas Auto-regressivas e o método SARIMA - Médias Móveis Integradas Sazonais Auto-regressivas.

Segundo Morretin e Tolo (2006), a construção do modelo Box & Jenkins é baseada em um ciclo iterativo, no qual a escolha do modelo é feita com os próprios dados. A metodologia de Box & Jenkins é composta de três etapas, conforme Figura 6. Estas etapas serão obedecidas para encontrar um modelo de previsão que descreva o comportamento da série de demanda de um produto de cosmético, máscara de cílios, possibilitando construir uma série com menor erro.

Coletou-se os dados do produto a partir de sistemas internos da empresa que armazenam e são atualizados constantemente com informações da demanda de todos os itens comercializados. A forma de escolha desse material orientou-se pela identificação do impacto em lucro que o produto tem no seu segmento. A série temporal enquadra-se entre os anos de 2013 e 2015 e utilizou-se os dados do segundo semestre de 2015 para validação. Em posse dos dados, o estudo seguiu com a aplicação dos métodos de previsão e em sequência concluiu-se com a análise e comparação com os dados do último semestre do último ano para validação.

Figura 6-Quadro Representativo dos Estágios do Ciclo Iterativo de Box-Jenkins



Fonte: Adaptado de Marchezan (2007)

2 FUNDAMENTAÇÃO TEÓRICA

2.1 SÉRIES TEMPORAIS

Na literatura, vários modelos de previsão diferentes têm sido propostos e utilizados para previsão de séries temporais. Há mais de três centenas de tipos diferentes de modelos de previsão nos tempos modernos que podem ser geralmente classificados em duas categorias principais: modelos qualitativos e modelos quantitativos (KHASHEI; BIJARI, 2014).

De acordo com Martins e Werner (2014), para a utilização de técnicas de previsão quantitativas é necessária existência de um registro de dados passados. Tais técnicas de previsão possuem diferentes propriedades, precisão e custos que devem ser considerados na escolha de um determinado método.

Já Efendigil, Önut e Kahraman (2009) afirmam que existem muitas técnicas de previsão e que estas podem ser classificadas na verdade em quatro grupos: (1) métodos qualitativos, que são essencialmente subjetivos por dependerem de julgamento humano e opiniões para fazer uma previsão (2) métodos de séries temporais que utilizam dados históricos para fazer uma previsão (3) métodos causais que envolvem assumir que a previsão de demanda é altamente correlacionada com certos fatores no ambiente, exemplo taxa de juros (4) métodos de simulação, que imitam as escolhas dos consumidores dando origem para demanda chegar a uma previsão.

Em modelos de séries temporais, observações históricas da mesma variável são recolhidas e analisadas para desenvolver um modelo que capta o processo de geração de dados subjacentes. Então o modelo é aplicado para prever o futuro (KHASHEI; BIJARI, 2014).

Uma série temporal é um conjunto de dados que contêm as medições repetidas de uma única variável ao longo do tempo. Uma das características mais importantes de uma série temporal é que os pontos de dados adjacentes são dependentes uns dos outros e essa dependência descreve a natureza e padrões de um conjunto de dados.

Para representar a série temporal é utilizada a notação Z , e no momento t será Z_t , em que $t = 1, 2, \dots, n$ indica o tamanho da série (MORETTIN, TOLOI, 2006).

Para Liang (2011) uma das abordagens para a construção de um modelo de previsão de confiabilidade envolve análise de séries temporais. Métodos de séries temporais visam reconhecer padrões recorrentes e relações lineares. Exemplos tradicionais que

usam séries temporais são os modelos auto regressivos de média móvel (ARIMA) e o modelo ARIMA sazonal (SARIMA).

As formas de previsão de séries temporais são baseadas na extrapolação de características transferidas entre seus relacionamentos, possibilitando assim previsões atiladas caso o comportamento futuro se assemelhe com o passado (GOOIJER, 2006).

Segundo Morettin e Tolo (2006), uma das suposições mais frequentes que se faz a respeito de uma série temporal é que ela seja estacionária, ou seja, desenvolve-se no tempo, aleatoriamente ao redor de uma média constante, refletindo alguma forma de equilíbrio estável. Entretanto, a maior parte das séries que é encontrado na prática apresenta alguma forma de não-estacionariedade, que geralmente é justificada devido a presença de quatro componentes:

- *Tendência*: verifica o deslocamento da série ao longo do tempo.
- *Sazonalidade*: movimento ondulatório de curta duração, em geral, inferior a um ano; geralmente associada à mudança climática.
- *Ciclo*: movimento ondulatório que ao longo de vários anos tende a ser periódico.
- *Ruído Aleatório*: compreende a variedade intrínseca aos dados e não pode ser modelado.

Para Dickey e Fuller (1979), considerando o modelo auto regressivo

$$Y_t = \rho Y_{t-1} + e_t, \quad t = 1, 2, \dots,$$

Onde $Y_0 = 0$, ρ é um número real e $\{e_t\}$ é uma sequência de variáveis aleatórias normais independentes com média zero e variância σ^2 . A série temporal Y_t converge ($t \rightarrow \infty$) para uma série temporal estacionária se $|\rho| < 1$. Se $|\rho| = 1$, a série temporal não é estacionária e a variância de Y_t é $t\sigma^2$. Se $|\rho| > 1$, a série temporal também não é estacionária e a variância da série temporal cresce exponencialmente com o crescimento de t .

A hipótese que $\rho = 1$ é de interesse em algumas aplicações porque corresponde à hipótese de que é apropriado transformar a série temporal através da diferenciação.

De acordo com Zivot (2015) em modelos ARMA, os dados devem ser transformados em estacionários antes da análise e o procedimento para isso é a primeira diferenciação.

O teste da raiz unitária pode ser usado para determinar se os dados devem passar pela primeira diferenciação ou pela regressão para se tornar um dado estacionário.

2.1.1 Teste da Raiz Unitária

Considerando a decomposição de um ciclo de tendência de uma série temporal y_t conforme equação 1, 2 e 3 :

$$y_t = TD_t + z_t \quad (1)$$

$$TD_t = \kappa + \delta t \quad (1)$$

$$z_t = \varphi z_{t-1} + \varepsilon_t, \varepsilon_t \sim \text{WN}(0, \sigma^2) \quad (3)$$

Onde, TD_t é uma tendência linear determinística e z_t é um processo AR(1). Se $|\varphi| < 1$ então y_t é I(0) em relação à tendência determinística TD_t . Se $\varphi = 1$, então $z_t = z_{t-1} + \varepsilon_t = z_0 + \sum_{j=1}^t \varepsilon_j$ é uma tendência estocástica e y_t é I(0) com deriva.

Testes de raiz unitária auto regressivo são baseados em testar duas hipóteses:

H_0 : $\varphi = 1$ ($\varphi(z) = 0$ tem uma raiz unitária – diferença estacionária)

H_1 : $|\varphi| < 1$ ($\varphi(z) = 0$ tem uma raiz fora do ciclo unitário – tendência estacionária)

Testes estacionários assumem a hipótese nula de que y_t é uma tendência estacionária. Se y_t é diferenciado pela primeira vez, então se torna

$$\Delta y_t = \delta + \Delta z_t \quad (5)$$

$$\Delta y_t = \varphi \Delta z_{t-1} + \varepsilon_t - \varepsilon_{t-1} \quad (6)$$

Os testes mais populares desse tipo são os testes de Dickey-Fuller (DF) e de Phillips-Perron (PP). O teste DF e o teste PP se diferem principalmente pela forma pela qual eles tratam a correlação das séries no teste de regressão.

Testes ADF usam uma estrutura paramétrica autogressiva para capturar a correlação da série, enquanto que testes PP usam correções não paramétricas baseadas na estimativa na variância de longo prazo Δy_t .

2.1.2 Modelos Lineares Estacionários

Modelos auto regressivos (AR) foram primeiramente introduzidos por Yule em 1926 e posteriormente completados por Slutsky em 1937, que apresentou o regime de média móvel (MA). No entanto, foi Wold em 1938 quem combinou ambos os regimes de AR e MA e mostrou que o processo ARMA podia ser usado para modelar uma grande classe de séries temporais estacionárias desde que os números de termos auto regressivos (ordem p) e números de termos de média móvel (q) fossem especificados (MAKRIDAKIS, 1997).

Auto regressivo (AR) é o processo de estimar valores de séries temporais baseando-se na média ponderada dos pontos de dados anteriores e Média Móvel (MA) é o processo de estimar valores de séries temporais com base na média ponderada dos resíduos de erro de estimativa de pontos de dados anteriores (ZHENG, 2014).

2.1.2.1 Modelo Auto-Regressivo (AR(p))

Morettin e Toloi (2006) definem modelos auto-regressivos de ordem p , conforme indicado na Equação 7.

$$Z_t = \varphi_1 Z_{t-1} + \varphi_2 Z_{t-2} + \dots + \varphi_p Z_{t-p} + \varepsilon_t \quad (7)$$

Os erros que não podem ser explicados pelo modelo são representados por ε_t e os termos $Z_{t-1}, Z_{t-2}, \dots, Z_{t-p}$ independem de ε_t . A série Z_t corresponde às observações históricas da série e possui valores que são combinações lineares dos p valores mais um termo ε_t , no qual incorpora coisas na série até o tempo t que não é explicado pelos valores passados.

2.1.2.2 Modelo Média Móvel (MA (q))

De acordo com Morettin e Toloi (2006), o processo de médias móveis de ordem q , MA(q), pode ser definido conforme indicado pela Equação 8.

$$Z_t = \mu + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q} + \varepsilon_t \quad (8)$$

Os erros que não podem ser explicados pelo modelo é representado por ε_t e a_t representa as ordens do modelo MA. Uma vez em que Z_t é obtido aplicando os pesos $1, -\theta_1, -\theta_2, \dots, -\theta_q$, às variáveis $a_t, a_{t-1}, a_{t-2}, \dots, a_{t-q}$, então, movendo-se os mesmos pesos 1 unidade do tempo a frente assim sendo aplicado a eles as somas $a_{t+1}, a_t, a_{t-1}, \dots, a_{t-q+1}$ para obter Z_{t+1} .

2.1.2.3 Modelo Média Móvel Auto Regressivo ARMA (p,q)

Hassan (2014) afirma que o modelo auto regressivo de média móvel para qualquer processo, como Z_t com ordens p, q denotadas como $ARMA(p, q)$, é a combinação de valores passados de Z_t e erros passados. A equação geral $ARMA(p, q)$ para uma série temporal pode ser escrita como na equação 9.

$$Z_t = \varphi_1 Z_{t-1} + \varphi_2 Z_{t-2} + \dots + \varphi_p Z_{t-p} + a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q} \quad (9)$$

Onde $\varphi_1, \varphi_2, \dots, \varphi_p$ e $\theta_1, \theta_2, \dots, \theta_q$ são respectivamente coeficientes auto regressivo e de média móvel desconhecidos e $a_t, a_{t-1}, \dots, a_{t-q}$ são choques aleatórios estatisticamente independentes que são assumidos para serem selecionados aleatoriamente a partir de uma distribuição normal com média zero e variância constante.

2.1.3 Modelos auto-regressivos Lineares Não-Estacionários

2.1.3.1 Modelo Auto-Regressivo Integrado Médias Móveis (ARIMA(p,d,q))

Box and Jenkins (1976, edição original 1970) popularizou o uso do modelo ARMA fornecendo orientações para transformar a série em estacionária tanto em sua média quanto na variância, sugerindo o uso de auto correlações e auto correlações parciais para determinar valores aproximados de p e q . Essa abordagem ficou conhecida como modelo ARIMA, onde a letra I entre AR e MA refere-se a “Integrado” e reflete a necessidade de diferenciar a série pra torna-la estacionária. (MAKRIDAKIS; HIBON, 1997).

Para as séries Z_t , com um número finito de diferenças, d , que se convertem em estacionárias, são chamadas não estacionárias homogêneas se obedecerem a Equação 10.

$$W_t = \Delta d Z_t \quad (10)$$

Representa-se W_t por um modelo ARMA(p,q) como na Equação 11.

$$\varphi(X) W_t = \theta(X) a_t. \quad (11)$$

Se W_t é uma diferença de Z_t , então Z_t é uma integral de W_t , portanto pode-se dizer que Z_t possui um modelo auto-regressivo-integrado-médias-móveis, ARIMA(p,d,q), apresentado na Equação 12, de ordem (p,d,q), se p e q são as ordens de $\varphi(X)$ e $\theta(X)$, respectivamente.

$$\varphi(X)\Delta d Z_t = \theta(X) a_t \quad (12)$$

No modelo, todas as raízes de $\varphi(X)$ estão fora do círculo unitário. Entretanto deve-se considerar a equivalência demonstrada na Equação 13,

$$\xi(X) Z_t = \theta(X) a_t \quad (13)$$

Donde $\xi(X)$ é um operador auto-regressivo não-estacionário, de ordem $p + d$, com d raízes iguais a 1 (sobre o círculo unitário) e as restantes p estão fora do círculo unitário, logo deve-se representar como na Equação 14.

$$\xi(X) = \varphi(X)\Delta d = \varphi(X)(1 - X)^d \quad (14)$$

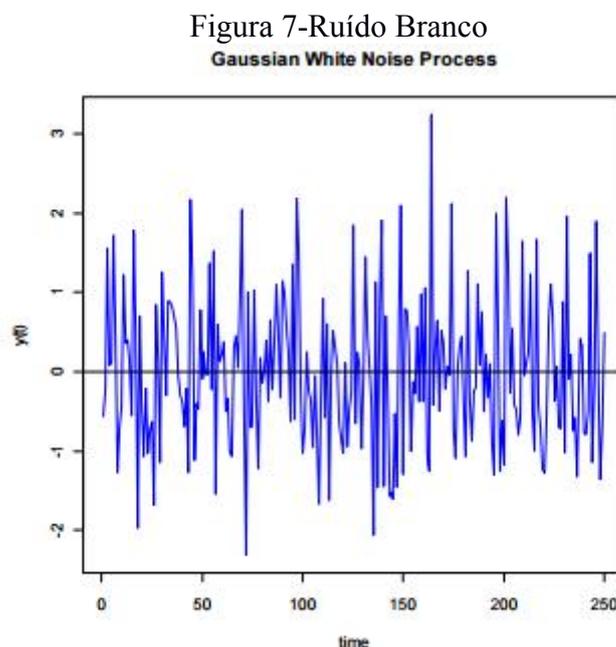
2.1.3.2 Modelo Médias Móveis Integradas Auto-regressivas Sazonais SARIMA(p,d,q) x (P,D,Q)

Para modelar a sazonalidade que aparece em muitas séries temporais, Box e Jenkins generalizaram o modelo ARIMA para incluir a sazonalidade na modelagem,

adicionando termos auto regressivos sazonais e termos de médias móveis sazonais, resultando no modelo SARIMA(p,d,q)(P,D,Q), onde P representa a ordem auto regressivo sazonal, Q representa o termo média móvel sazonal e D representa a ordem de diferenciação para transformação estacionária em nível de sazonalidade (ZHENG, 2014).

Modelos SARIMA assumem que valores futuros de uma série temporal têm relação linear com valores passados e atuais, assim como com o ruído branco (KHASHEI; BIJARI; HEJAZI, 2012).

A Figura 7 exibe um ruído branco, processos em que todas as suas variáveis aleatórias são expressas por meio de uma distribuição normal de média 0 com variância constante e covariância nula, que é estacionário.



Fonte: Zivot (2015)

O termo ρ_j é chamado j^{th} ordem de auto covariância. A ordem j^{th} de auto correlação é definido por

$$\rho_j = \frac{COV(Y_t, Y_{t-j})}{\sqrt{var(Y_t).var(Y_{t-j})}} = \frac{\gamma_j}{\sigma^2} \quad (15)$$

A autocovariância γ_j , mede o sentido de dependência linear entre Y_t e Y_{t-j} . A autocorrelação ρ_j , mede tanto a direção quanto a força da dependência linear entre Y_t e Y_{t-j} .

A auto covariância e auto correlação são medidas da dependência linear temporal em um processo estocástico estacionário (ZIVOT, 2015).

Khashei, Bijari e Hejazi (2012) afirmam que a ideia básica de identificação do modelo é que se uma série temporal é gerada a partir de um processo ARIMA, ele deveria apresentar algumas propriedades de auto correlação.

Liu e Li (2015) definiram o processo de modelagem da metodologia Box-Jenkins pela seguintes etapas:

- a) Pré-tratamento dos dados. Para estabelecer o modelo ARIMA é necessário que a série temporal seja um processo estacionário estocástico, sendo assim, os dados devem ser testados até atingir a estacionariedade.
- b) Estimar parâmetros desconhecidos. Após o diferenciação para transformar séries não-estacionárias em estacionárias, o passo chave é determinar a ordem do modelo ARIMA. Métodos como função de auto correlação (FAC) e Função de auto correlação parcial (FACP) são usados nesse momento.
- c) Testar o modelo. Após a determinação da ordem e estimativa de parâmetros, a aplicabilidade do modelo deve ser testada. Se o erro do modelo é o ruído branco então o modelo obtido é qualificado, caso contrário nova determinação de ordem e parâmetros de re-estimação são necessários.
- d) Previsão de resultados futuros com base nos dados conhecidos.

De acordo com Morettin e Tolloi (2006), quando $\{Z_t\}$ apresenta um comportamento sazonal determinístico com período 12, um modelo que pode ser útil é apresentado na Equação 16.

$$Z_t = \mu_t + N_t, \quad (16)$$

Sendo que μ_t é uma função determinística periódica, $(\mu_t - \mu_{t-12} = 0$, ou $(1 - B^{12})\mu_t = 0$) e N_t é um processo estacionário que pode ser modelado por um ARIMA (p,q) .

Dessa maneira, N_t satisfaz a Equação 17.

$$\phi(B)N_t = \theta(B)a_t, \quad (17)$$

Sendo a_t tem ruído branco e μ_t tem solução dada pela Equação 18.

$$\left[j \left| \cos \frac{(2\pi jt)}{12} + \beta_j \text{sen} \frac{(2\pi jt)}{12} \right| \right] \mu_t = \mu + \sum_{j=1}^6 \alpha_j \quad (18)$$

Com $\mu, \alpha_j, \beta_j, j=1, \dots, 6$, constantes desconhecidas.

Assim, para um modelo sazonal determinístico, aplicando a diferença sazonal $(1 - B^{12})$ à Equação (13), obteve-se a Equação 19.

$$(1 - B^{12})Z_t = (1 - B^{12})\mu_t + (1 - B^{12})N_t \quad (19)$$

E de acordo com (17), tem-se

$$(1 - B^{12})Z_t = (1 - B^{12})N_t. \quad (20)$$

Substituindo (19) em (20), obteve-se

$$\phi(B)(1 - B^{12})Z_t = \theta(B)(1 - B^{12})a_t, \quad (21)$$

$$\phi(B)W_t = \theta(B)(1 - B^{12})a_t \quad (22)$$

Sendo $W_t = (1 - B^{12})Z_t$.

2.2 ERROS DE PREVISÃO

2.2.1– Erro Absoluto Médio – MAD

O erro absoluto médio MAD (*mean absolute deviation*) é a soma dos desvios absolutos dos períodos dividida pelo número de períodos, conforme equação 23.

$$MAD = \frac{\sum_{i=1}^n |X_i - \widehat{X}_i|}{n} \quad (23)$$

Se MAD for pequeno, os dados reais seguem estreitamente as previsões da variável dependente e o modelo de previsão fornece previsões acuradas.

2.2.2– Erro Percentual Absoluto Médio – MAPE

O erro percentual absoluto médio MAPE (*mean absolute percentage error*) representa a média percentual da divisão entre erro de previsão e o valor real.

$$MAPE = \frac{\sum_{i=1}^n \left| \frac{X_i - \widehat{X}_i}{X_i} \right| (100)}{n} \quad (24)$$

Quanto menor o valor do MAPE melhor a precisão nos dados previstos.

2.2.3– Erro Quadrático Médio – EQM

O erro quadrático médio é dado pela expressão:

$$EQM = \frac{\sum_{i=1}^n (X_i - \widehat{X}_i)^2}{n} \quad (25)$$

De uma forma geral, quando os valores do e forem pequenos, os dados reais seguem estreitamente as previsões da variável dependente e o modelo de previsão fornece previsões acuradas.

3 DESCRIÇÃO DO PROBLEMA

3.1 DESCRIÇÃO DO PROBLEMA

O departamento de Planejamento de Demanda da indústria de cosmético estudada forneceu os dados de um produto do segmento de maquiagem para os olhos. A escolha desse produto baseou-se na dificuldade em atingir uma exatidão pelos meios tradicionais de estimar a previsão e pelo impacto em margem de lucro que o produto representa dentro do seu segmento.

Entre as dificuldades que existem para estimar a demanda do produto está a influência aleatória que a série temporal sofre, como o preço do produto que varia quinzenalmente podendo ser vendido no preço regular ou em preços promocionais.

Após análise da série verificou-se que as observações históricas do produto vendido ao seu preço regular estavam distorcendo a previsão gerada pelo modelo. Sendo assim, todas as observações com essa característica foram retiradas, resultando em total de 47 observações.

O produto em questão se refere à máscara de cílios e a série temporal se iniciou em maio de 2012 até maio de 2015, conforme contemplado pelo apêndice A.

Seguindo a metodologia Box-Jenkins (1970), primeiramente foi identificado o modelo, em seguida estimou-se e por fim verificou-se, com os dados reais de três meses após o último dado coletado para estudos, se a previsão gerada era coerente.

Utilizando a previsão gerada pelo método auto regressivo, confrontou-se os valores encontrados com os dados reais, contemplados na tabela 3 em anexo A e os dados previstos pela empresa, conforme apresentado na tabela 4 em anexo A. Dessa forma, conseguiu-se identificar que o método estudado neste trabalho alcançou o objetivo de prever a demanda do ano de 2015.

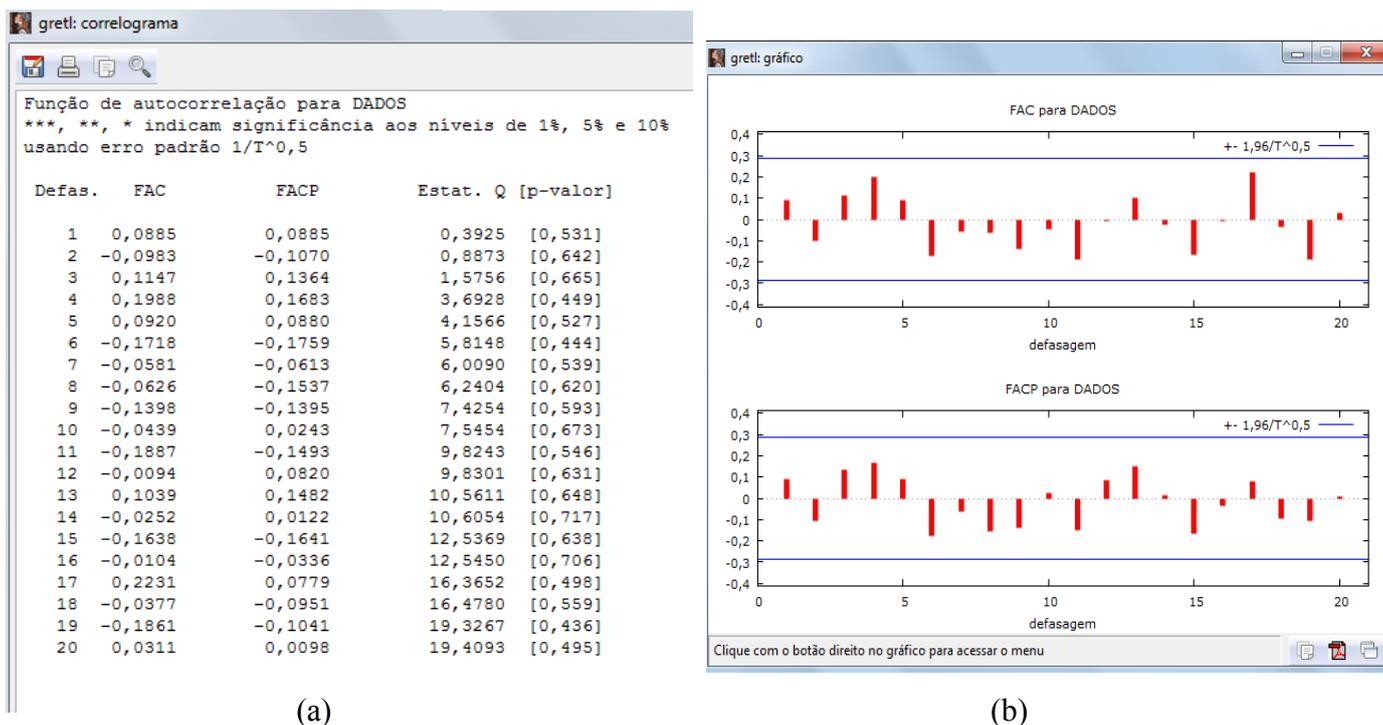
3.2 METODOLOGIA BOX-JENKINS PARA O PRODUTO SOBRE SÉRIE ORIGINAL

3.2.1 Identificação do modelo

As Figuras 8a e 8b apresentam os dados gerados pelo correlograma do software Gretl sobre a série original.

Conforme Figura 8, observou-se que os valores de p-valor estão acima de 0,05, fato que evidencia a não estacionariedade do modelo, considerando nível de significância de 5%. Para confirmar, utilizou-se o teste aumentado de Dickey-Fuller, para valores acima de 5% de significância se aceita a hipótese de não estacionariedade. Conforme indicado na Figura 9, p-valor é maior que 0,05, logo se trata de uma série não estacionária.

Figura 8-Autocorrelação/Estacionariedade

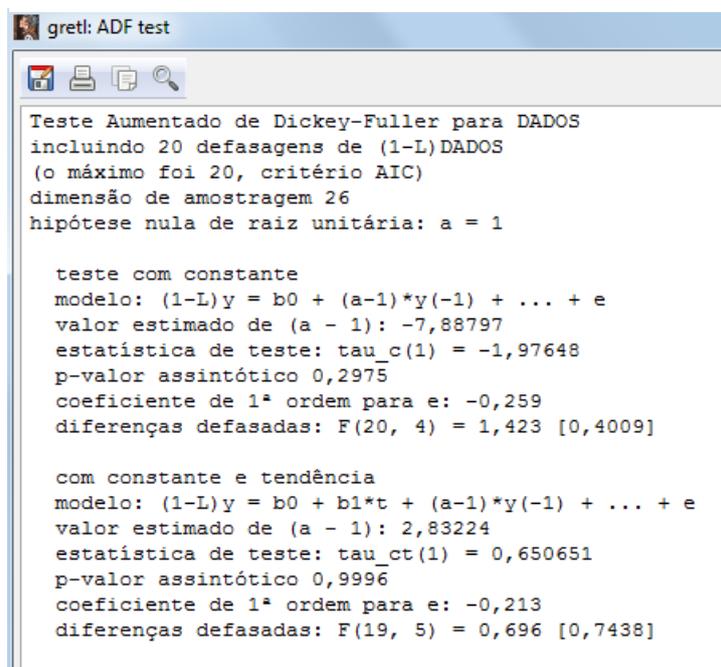


(a)

(b)

Fonte: O próprio autor

Figura 9-Teste Aumentado de Dickey-Fuller



Fonte: O próprio autor

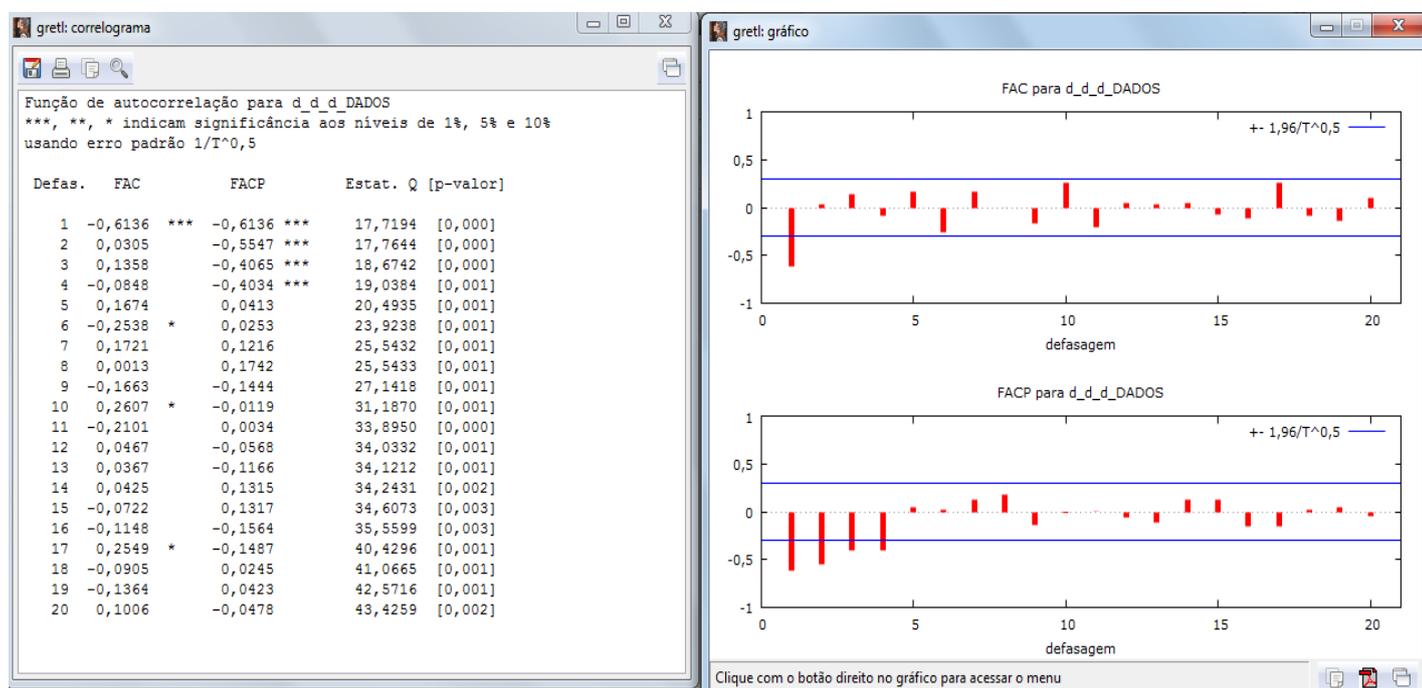
3.2.2 Estimação do modelo

Foram feitas três diferenciações para se chegar a um valor satisfatório de p-valor, com isso $d=3$. A Figura 10 mostra os valores encontrados após a diferenciação. Os valores p e q são encontrados a partir do ponto de inferência encontrado a partir da Equação 26. Foram analisados 47 dados, e como foram feitas três diferenciações n passa a ser 44, fornecendo assim um ponto de inferência igual a 0,3015.

$$\pm \frac{2}{\sqrt{n}} = \pm \frac{2}{\sqrt{44}} = 0,3015 \quad (26)$$

Analisando FACP, encontrou-se que o último maior número que o ponto de inferência é 0,4034, sendo assim $p = 4$. Para encontrar q deve-se analisar a coluna FAC e encontrar o primeiro valor menor que o ponto de inferência, neste caso $q = 2$.

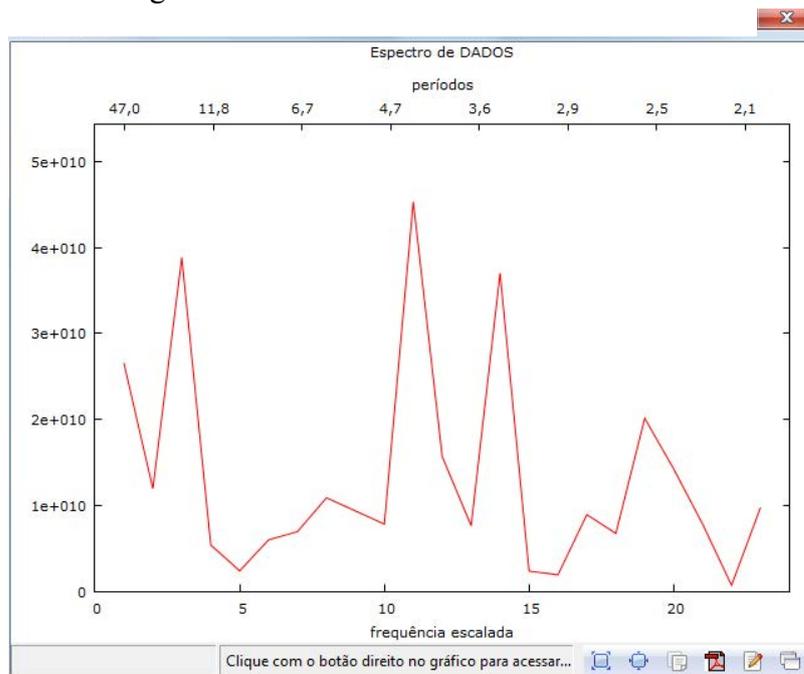
Figura 10- Correlograma série original



Fonte: o próprio autor

Por meio do periodograma foi possível verificar se existe sazonalidade. O que caracteriza gráfico sazonais é a presença de picos e vales acentuados. A Figura 11 apresenta um gráfico com essas características, confirmando assim que se trata de um processo sazonal. Sendo assim, buscou-se identificar os filtros P, Q e D do modelo SARIMA (p, d, q) X (P, D e Q).

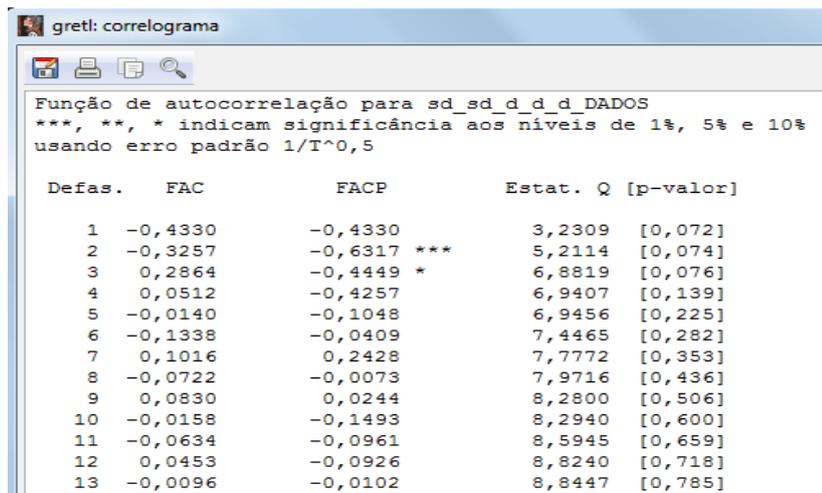
Figura 11- Gráfico de sazonalidade



Fonte: o próprio autor

Por meio da análise do correlograma indicado na Figura 12 se observa que mesmo após fazer três diferenciações sazonais ainda não se alcança a estacionariedade da série. Sendo assim, utilizou-se então a derivação aplicando o logaritmo neperiano na série original, como descrito no item 3.3 a seguir.

Figura 12- Correlograma



Fonte: o próprio autor

3.3 METODOLOGIA BOX-JENKINS PARA O PRODUTO SOBRE SÉRIE DERIVADA

3.3.1 Identificação do modelo

A Figura 13 apresenta a auto correlação da série original derivada, e como os valores de p-valor estão acima de 0,05 fica indicado a tendência de não estacionariedade da série. Porém, o teste aumentado de Dickey-Fuller indica valor de p-valor menor que 0,05 e assim rejeita a hipótese de não –estacionariedade, conforme indicado pela Figura 14.

Figura 13-Correlograma série derivada

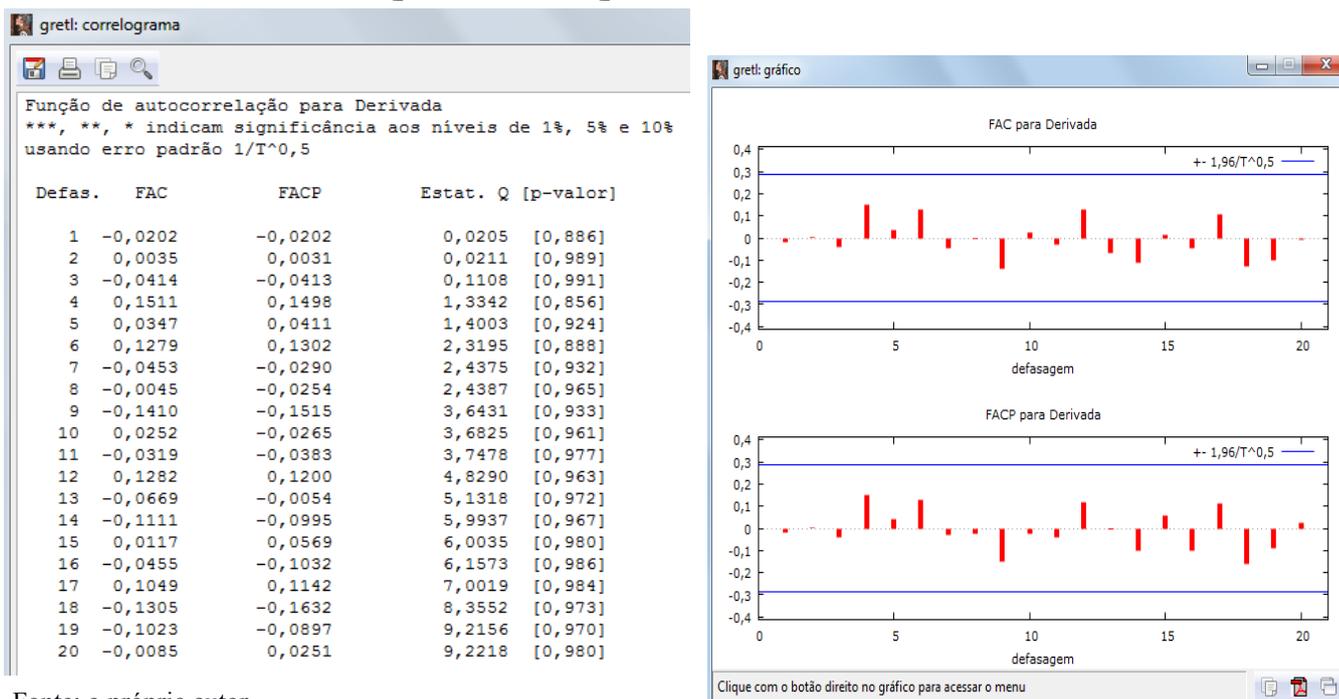
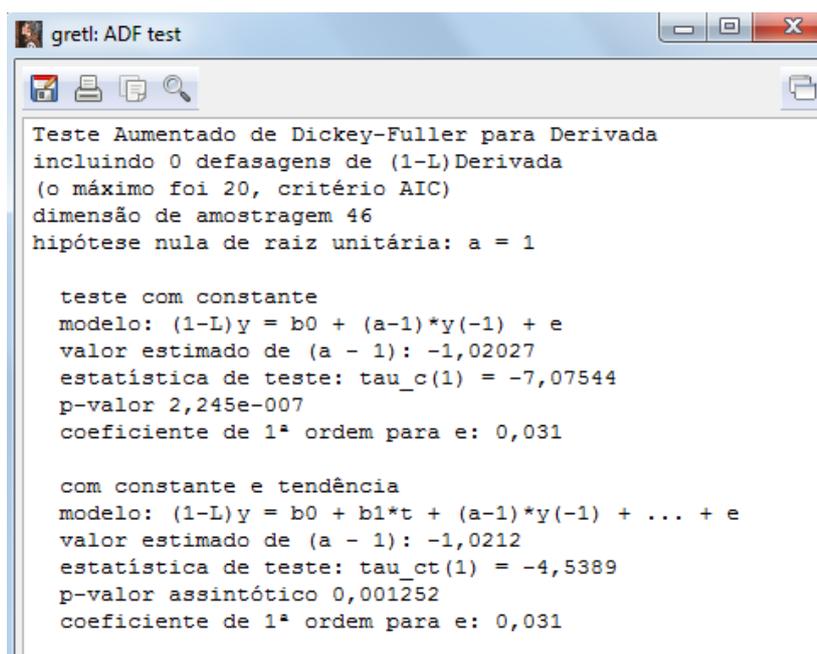


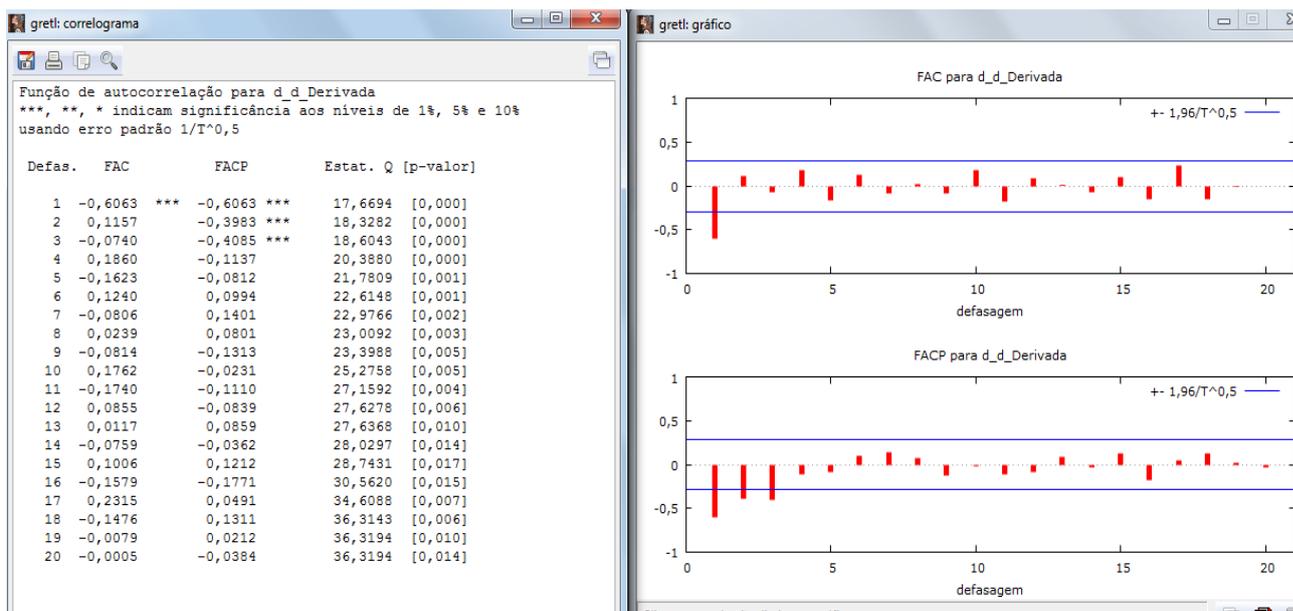
Figura 14-Teste aumentado de Dickev- Fuller



Fonte: o próprio autor

A fim de garantir a estacionariedade da série foi feita uma diferenciação, conforme Figura 15. Observa-se que os valores de p-valores neste caso se apresentaram abaixo de 0,05, indicando a estacionariedade da série e se confirmando assim com o teste aumentado de Dickey-Fuller.

Figura 15-Correlograma



(a)

(b)

Fonte: o próprio autor

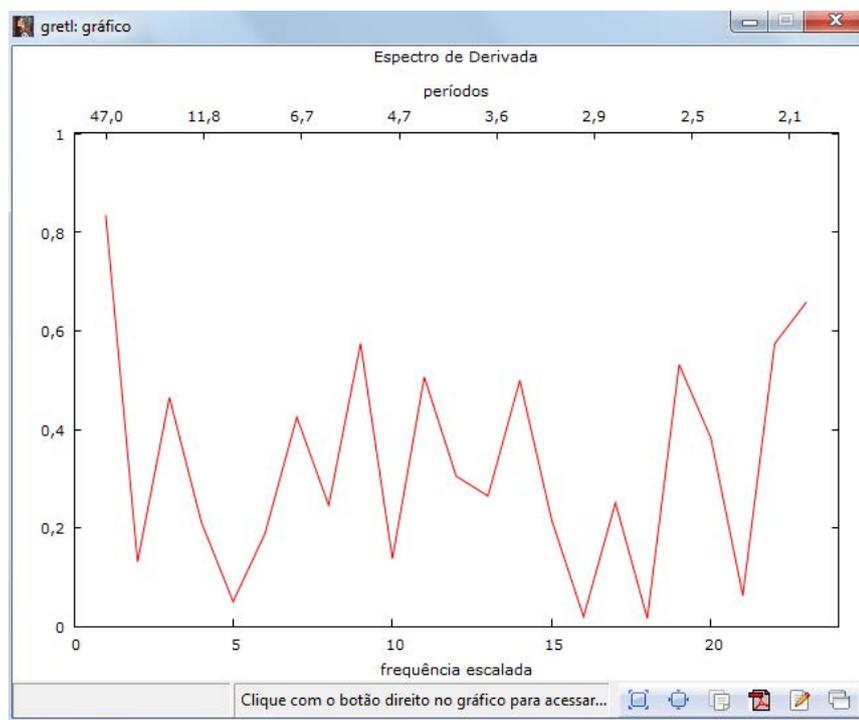
3.3.2 Estimação do modelo

Após uma diferenciação se chega a valores satisfatórios para p-valor, com isso $d = 1$. Para encontrar o valor de p e q é necessário encontrar o ponto de inferência, de acordo com a Equação 26. Como foi feito uma diferenciação n passa a ser 46, o que fornece um ponto de inferência igual a 0,2948.

Analisando FACP da Figura 15, encontrou-se o último maior número que o ponto de inferência, sendo assim $p=3$. Analisando a coluna FAC encontra-se o primeiro valor menor que o ponto de inferência, para esse caso $q=2$. A Figura 15b mostra o ruído próximo de zero após uma diferenciação.

Pela análise do periodograma verificou-se a não sazonalidade, pois os picos seguem uma tendência, conforme Figura 16.

Figura 16-Gráfico de Sazonalidade



Fonte: o próprio autor

Como não há sazonalidade na série derivada, não há necessidade de diferenciação, sendo assim $D = 0$ e se assume valores de P e Q iguais a 1 para se obter um modelo inicial SARIMA.

3.3.3 Verificação do modelo

Verificou-se por meio de tentativa e erro que o modelo provável encontrado SARIMA (3,1,2) x (1,0,1) necessitava de ajustes por meio de tentativa e erro. Observando os valores de p-valor presentes no modelo gerado, encontrou-se o melhor modelo SARIMA (0,1,1) x (1,0,1) conforme mostra Figura 17.

Figura 17-Modelo gerado

| | coeficiente | erro padrão | z | p-valor | |
|------------------------|-------------|-------------|-----------------------|-----------|-----|
| Phi_1 | -0,788426 | 0,161617 | -4,878 | 1,07e-06 | *** |
| theta_1 | -0,911492 | 0,0753692 | -12,09 | 1,14e-033 | *** |
| Theta_1 | 0,996490 | 0,224107 | 4,447 | 8,73e-06 | *** |
| Média var. dependente | 0,059778 | | D.P. var. dependente | 2,030537 | |
| Média de inovações | 0,101336 | | D.P. das inovações | 1,387812 | |
| Log da verossimilhança | -83,44776 | | Critério de Akaike | 174,8955 | |
| Critério de Schwarz | 182,2101 | | Critério Hannan-Quinn | 177,6356 | |

| | Real | Imaginária | Módulo | Frequência |
|--------------|---------|------------|--------|------------|
| AR (sazonal) | | | | |
| Raiz 1 | -1,2684 | 0,0000 | 1,2684 | 0,5000 |
| MA | | | | |
| Raiz 1 | 1,0971 | 0,0000 | 1,0971 | 0,0000 |
| MA (sazonal) | | | | |
| Raiz 1 | -1,0035 | 0,0000 | 1,0035 | 0,5000 |

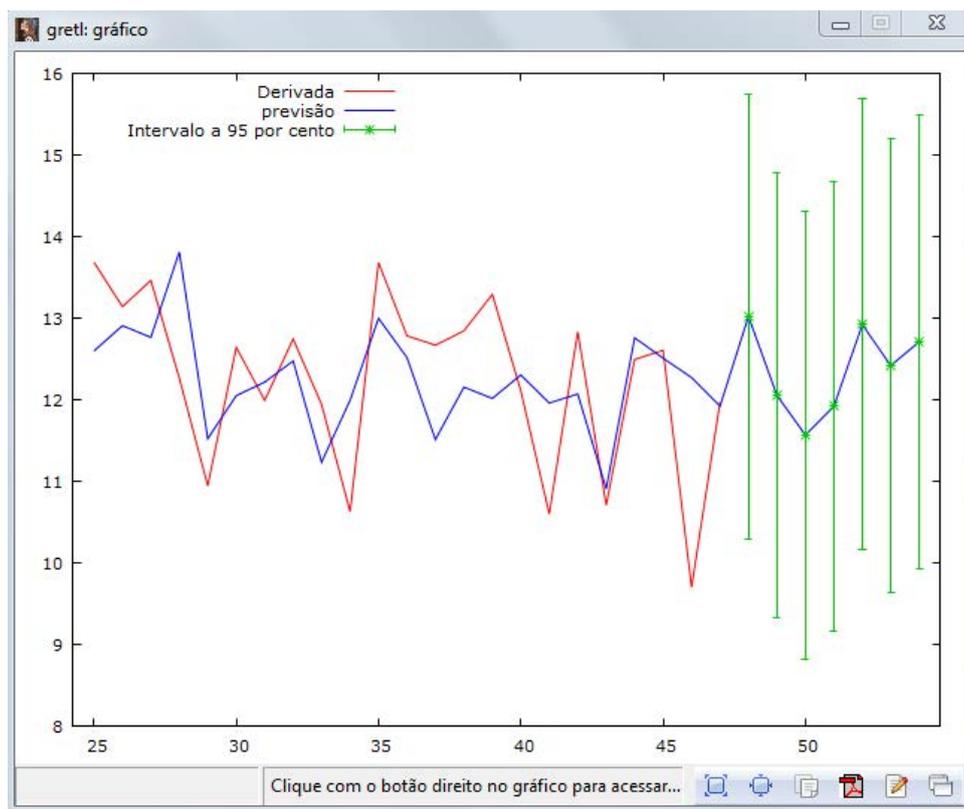
Fonte: o próprio autor

3.4 PREVISÕES GERADAS PELO MODELO ENCONTRADO

Os dados mostrados na Tabela 2 em Apêndice A foram obtidos utilizando o modelo SARIMA (0,1,1) x (1,0,1). Ao se aplicar a função exponencial nos dados da previsão, se obtém os valores reais gerados pelo modelo para a previsão, conforme Tabela 3 em apêndice A.

Na Tabela 4 há a demanda real do produto fornecido pela empresa. Levando em consideração o intervalo de confiança de 95%, a Figura 18 representa visualmente a aderência do modelo sobre a série temporal do produto. Observa-se que a previsão do modelo se encontra entre o intervalo de confiança.

Figura 18-Modelo SARIMA (0,1,1) x (1,0,1)

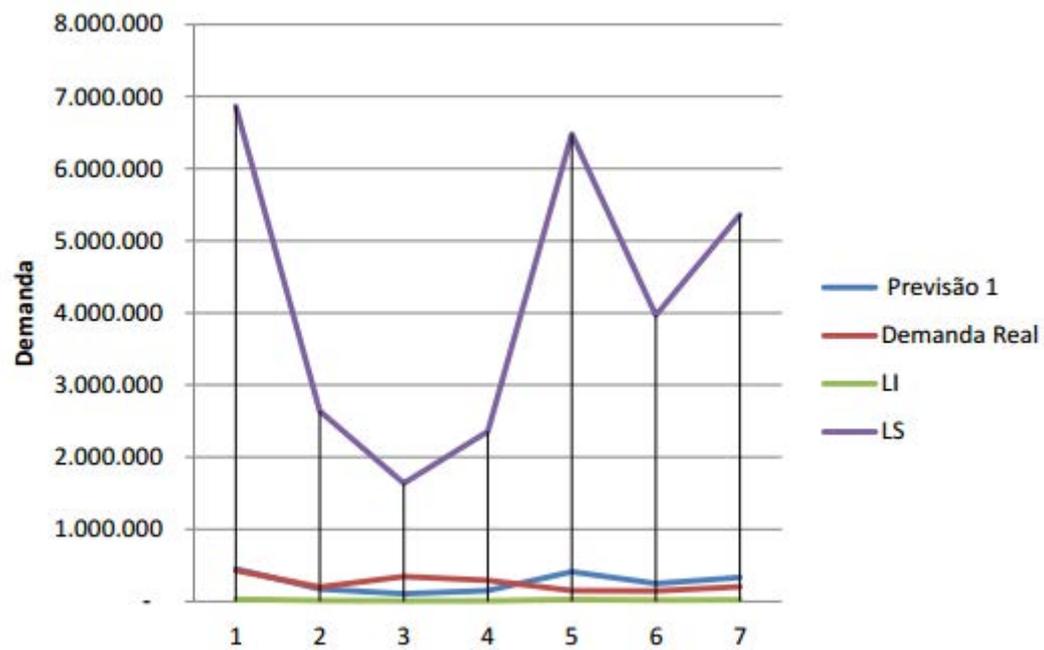


Fonte: o próprio autor

Ao se comparar os dados da previsão com a demanda real do produto, se observa que o modelo fornece uma previsão próxima da demanda nas duas primeiras quinzenas, conforme mostra pontos 1 e 2 da Figura 19. Em seguida a previsão se distancia da demanda real. A forma encontrada para aplicar o modelo adequadamente foi alimentando a série temporal a cada mês com dois novos dados de demanda real e gerando assim, a partir do mesmo modelo, novas previsões futuras, como mostrado na Figura 20.

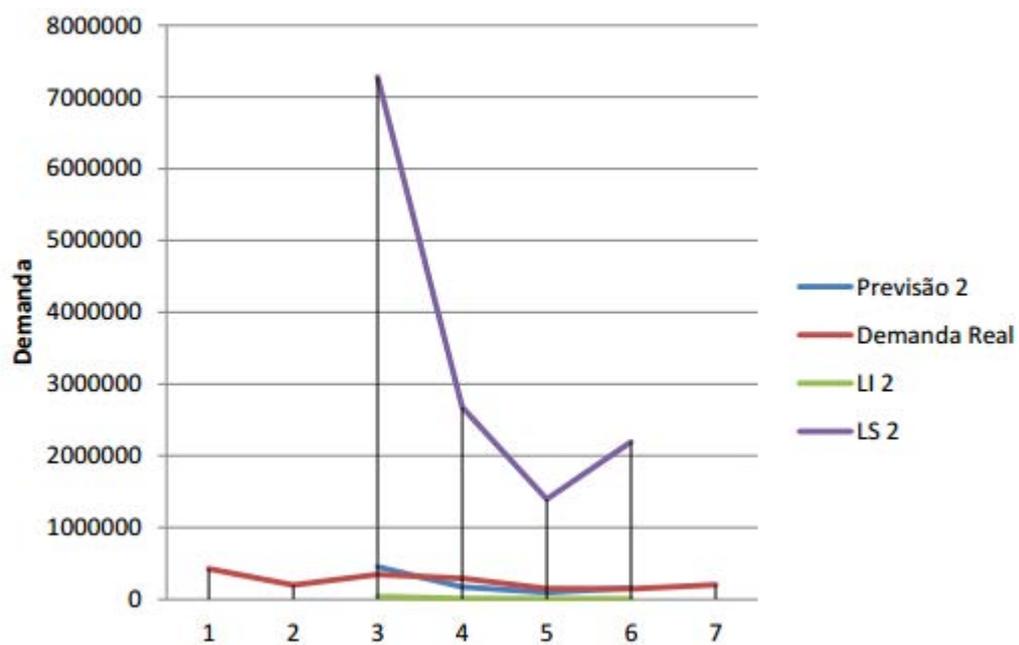
Desta forma, observa-se que a previsão nos pontos 3,4 e 5 da Figura 20 se aproximam mais da demanda real quando comparado com os mesmos pontos na Figura 19 e o modelo gerado se adere novamente sobre a série temporal acrescida de dois valores.

Figura 19-Gráfico comparativo entre demanda real e a primeira previsão



Fonte: o próprio autor

Figura 20-Gráfico comparativo entre demanda real e segunda previsão



Fonte: o próprio autor

4 CONCLUSÕES E RECOMENDAÇÕES PARA FUTURAS PESQUISAS

4.1 VERIFICAÇÃO DOS OBJETIVOS

É possível observar que a aderência do modelo adotado atende aos objetivos do trabalho, uma vez que as previsões geradas permaneceram dentro do intervalo de confiança, como apresentado nas Figuras 18 e 19.

Entretanto, a necessidade de aplicar o modelo SARIMA a cada mês, alimentando a série temporal usada com novos dados de demanda real para atingir um melhor desempenho do modelo, pode ser justificada pelo fato da série usada apresentar dados inferiores ao sugerido pela literatura.

Segundo Khashei e Bijari (2014), previsões geradas por modelos ARIMA necessitam de quantidades grandes de dados históricos para produzir os resultados desejados. De acordo com a limitação de dados, modelos ARIMA requerem pelo menos 50 dados, ou de preferência 100 para cima.

Outro ponto a considerar é a necessidade de percepção do analista em adotar os parâmetros p , d , q , P , D e Q , uma vez que o método utilizado de identificação, estimação e serve para nortear e estimar um modelo ótimo, mas é por meio da verificação, do método de tentativa e erro, que se chegou ao provável modelo ótimo.

Pode-se observar que a previsão gerada pelo modelo se aproxima da previsão gerada pela empresa, que por sua vez se aproxima da demanda real do produto, o que comprova a eficácia do método e possibilidade da empresa utilizar a ferramenta na tomada de decisão para previsões a curto prazo, como forma de validação.

O estudo em questão apresenta contribuição tecnológica, pois o modelo pode contribuir para a análise de séries temporais e colaborar com a geração de dados futuros, assim como a confiabilidade dos dados gerados pode contribuir para melhorar a qualidades das operações, do nível de estoque e nível de serviço.

Sendo assim, conclui-se que o objetivo do trabalho foi alcançado, pois o estudo em cima da série temporal de cada produto somado a confiabilidade da ferramenta e o método auto-regressivo linear SARIMA mostraram-se capazes de gerar dados dentro do intervalo de confiança de 95%.

4.2 RECOMENDAÇÕES PARA FUTURAS PESQUISAS

Recomenda-se realizar o estudo em séries temporais com dados superiores a 50 observações, com preferência 100 observações para cima.

Por se tratar de previsão de demanda de uma indústria que é diretamente influenciada por variáveis aleatórias como ações de marketing, feriados, promoções, moda e ambiente econômico, ressalta-se a possibilidade de futuros estudos envolvendo métodos híbridos de previsão, que envolva abordagens quantitativas e qualitativas.

Ressalta-se a importância do método estudado para aplicação em outros produtos da empresa, abrangendo assim outros segmentos, e assim, verificar a aplicação do modelo auto regressiva e outras séries temporais.

REFERÊNCIAS

ASSOCIAÇÃO BRASILEIRA DE EMPRESAS DE VENDAS DIRETAS. **Venda Direta**. Disponível em: < <http://www.abevd.org.br/venda-direta> >. Acesso em: 10 mai. 2015.

BERTRAND, J. W. M.; FRANSOO, J. C. Modelling and simulation: operations management research methodologies using quantitative modeling. **International journal of operations & production management**, v. 22, n. 2, p. 241-264, 2002.

BOX, G. E. P.; JENKINS, G. M. Time series analysis forecasting and control. Edição revisada. San Francisco: Editora HoldenDay, 1976.

DICKEY, D.; FULLER, W. Distribution of the estimators for autoregressive time series with a unit root. **Journal of the american statistical association**. p. 427-431, 1979.

EFENDIGIL, T.; ÖNÜT, S.; KAHRAMAN, C. A decision support system for demand forecasting with artificial neural networks and neuro-fuzzy models: A comparative analysis. **International journal of expert systems with applications**. Istanbul, Turkey, 2009.

FAVARETTO, F. Impacto das incertezas da previsão da demanda no planejamento detalhado da produção. **P&D em engenharia de produção**, Itajubá, v. 10, n. 1, p. 101-108, 2012.

GOOIJER, J.G.; HYNDMAN R.J. 25 years of time series forecasting. **International journal of forecasting**, v 22, p. 443–473, 2006

HASSAN, J. ARIMA and regression models for prediction of daily and monthly clearness index. **International journal of renewable energy**. Abu Dhabi, United Arab Emirates , 2014.

HUANG, M. G. Real options approach-based demand forecasting method for a range of products with highly volatile and correlated demand. **European journal of operational Research**, v. 198, p. 867-77, 2009.

JUNG, C. F. **Metodologia científica: Ênfase em pesquisa tecnológica**. 3ª Edição Revisada e Ampliada. Difusão Tecnológica Gratuita - Incentivo a Produção Científica Nacional, 2003, p 357. Disponível em:<<http://www.jung.pro.br>>. Acesso em: 18 set. 2015.

KHASHEI, M.; BIJARI, M. Fuzzy artificial neural network (p, d, q) model for incomplete financial time series forecasting. **Journal of intelligent and fuzzy systems**, v. 26, p. 831-845, 2014.

KHASHEI, M.; BIJARI, M.; HEJAZI, S. R. Combining seasonal ARIMA models with computational intelligence techniques for time series forecasting. **Journal of soft comput**, v. 16, p. 1091-1105, 2012.

LIANG, Y. H. Analyzing and forecasting the reliability for repairable systems using the time series decomposition method. **International journal of quality and reliability management**, v. 28, p. 317 -327, 2011.

LIU, D. J.; LI, L. Application Study of Comprehensive Forecasting Model Based on Entropy Weighting Method on Trend of PM2.5 Concentration in Guangzhou, China. **International journal of environmental research and public health**, v. 12, p 7085-7099, 2015.

MAKRIDAKIS, S.; HIBON, M. ARMA Models and the Box-Jenkins Methodology. **Journal of forecasting**, v. 16, p 147-163, 1997.

MARTINS, V.L.M; WERNER, L. **Comparação de previsões individuais e suas combinações: um estudo com séries industriais**. Prod., São Paulo, v. 24, n. 3, Setembro. 2014. Disponível em <<http://www.scielo.br/scielo.php?pid=S0103-65132014000300011>>. Acesso em: 10.out.2015.

MORETTIN, P. A.; TOLOI, C. M. C. **Análise de séries temporais** 2. ed. São Paulo: Edgar Blucher, 2006.

RITZMAN, L. P.; KRAJEWSKI, L. J. **Administração da produção e operações**. São Paulo: Prentice Hall, 2004.

SUCKY, A.A.N.O. A decision support system for demand forecasting in the clothing industry. **International journal of clothing science and technology**, v. 24, p 221-136, 2012.

SUN, Z.L.; CHOI, T.M.; AU, K.F.; YU, Y. **Sales forecasting using extreme learning machine with applications in fashion retailing**: Decision Support Systems, v. 46, p. 411-19, 2008.

ZHENG, T. What caused the decrease in RevPAR during the recession?. **International journal of contemporary hospitality management**, v. 26, p. 1225 – 1242, 2014.

WEB OF SCIENCE. **Relatório de citações**. Disponível em : <apps.webofknowledge.com/CitationReport.do?product=UA&search_mode=CitationReport&SID=1FKsicIMP1JwxGplvNZ&page=18cr_pqd=6&viewtype=summary>. Acesso em : 07 mai. 2015

ZIVOT, E. **Computational finance and financial econometrics**. University of Washington. Disponível em : < <http://faculty.washington.edu/ezivot/econ424.htm> >. Acesso em : 10 out.2015

APÊNDICE A

Tabela 1 - Série temporal do produto analisado

| SÉRIE TEMPORAL | |
|----------------|---------|
| Nº DE DADOS | DEMANDA |
| 1 | 10131 |
| 2 | 482565 |
| 3 | 17126 |
| 4 | 675098 |
| 5 | 545514 |
| 6 | 471908 |
| 7 | 28535 |
| 8 | 82095 |
| 9 | 2723 |
| 10 | 286409 |
| 11 | 370178 |
| 12 | 68042 |
| 13 | 3833 |
| 14 | 186575 |
| 15 | 238561 |
| 16 | 133154 |
| 17 | 372959 |
| 18 | 750490 |
| 19 | 323806 |
| 20 | 133023 |
| 21 | 385931 |
| 22 | 1417124 |
| 23 | 495734 |
| 24 | 28414 |
| 25 | 878890 |
| 26 | 509725 |
| 27 | 703233 |
| 28 | 212111 |
| 29 | 56691 |
| 30 | 309585 |
| 31 | 161505 |
| 32 | 342702 |
| 33 | 153635 |
| 34 | 41359 |
| 35 | 874894 |
| 36 | 356416 |
| 37 | 317737 |
| 38 | 379208 |
| 39 | 592366 |

| | |
|----|--------|
| 40 | 181656 |
| 41 | 40147 |
| 42 | 374731 |
| 43 | 44672 |
| 44 | 266749 |
| 45 | 298548 |
| 46 | 16356 |
| 47 | 158441 |

Fonte:o próprio autor

Tabela 2 - Previsão do Modelo com série derivada

| PREVISÃO SARIMA |
|-----------------|
| 13,0213 |
| 12,0538 |
| 11,5671 |
| 11,9194 |
| 12,9208 |
| 12,4196 |
| 12,7107 |

Fonte:o próprio autor

Tabela 3-Previsão real do modelo com derivação

| PREVISÃO APÓS EXPONENCIAL |
|---------------------------|
| 451.938 |
| 171.751 |
| 105.567 |
| 150.151 |
| 408.726 |
| 247.607 |
| 331.274 |

Fonte:o próprio autor

Tabela 4-Demanda real do produto

| Demanda Real |
|--------------|
| 426.335 |
| 197.095 |
| 344.663 |
| 289.523 |
| 150.854 |
| 143.116 |
| 200.529 |

Fonte:o próprio autor

Tabela 5-Demanda estimada pela empresa

| Estimado pela empresa |
|-----------------------|
| 379.369 |
| 204.328 |
| 338.912 |
| 300.817 |
| 145.000 |
| 129.001 |
| 195.702 |

Fonte: o próprio autor