

UNIVERSIDADE ESTADUAL DO NORTE FLUMINENSE - UENF
MESTRADO EM ENGENHARIA DE PRODUÇÃO

LUIZA RANGEL JUSTINIANO

**PREVISÃO DE DEMANDA PELO MÉTODO BOX JENKINS SAZONAL: O CASO
DE UMA EMPRESA METALMECÂNICA**

CAMPOS DOS GOYTACAZES

Maio - 2018

UNIVERSIDADE ESTADUAL DO NORTE FLUMINENSE - UENF
MESTRADO EM ENGENHARIA DE PRODUÇÃO

LUIZA RANGEL JUSTINIANO

**PREVISÃO DE DEMANDA PELO MÉTODO BOX JENKINS SAZONAL: O CASO
DE UMA EMPRESA METALMECÂNICA**

Dissertação apresentado ao Laboratório de Engenharia de Produção - LEPROD, da Universidade Estadual do Norte Fluminenses Darcy Ribeiro - UENF – Campos / RJ, como parte das exigências para obtenção do título de Mestre em Engenharia de Produção.

Orientadora: Gudélia Guillermina Morales de Arica

Coorientador: José Ramón Arica Chávez

CAMPOS DOS GOYTACAZES, RJ

Maio – 2018

FICHA CATALOGRÁFICA

Preparada pela Biblioteca do CCT / UENF

61/2018

Justiniano, Luiza Rangel

Previsão de demanda pelo método Box Jenkins Sazonal : o caso de uma empresa metalmeccânica / Luiza Rangel Justiniano. – Campos dos Goytacazes, 2018.

91 f. : il.

Dissertação (Mestrado em Engenharia de Produção) -- Universidade Estadual do Norte Fluminense Darcy Ribeiro. Centro de Ciência e Tecnologia. Laboratório de Engenharia de Produção. Campos dos Goytacazes, 2018.

Orientador: Gudélia Guillermina Morales de Arica.

Coorientador: José Ramón Arica Chávez.

Área de concentração: Pesquisa operacional.

Bibliografia: f. 65-70.

1. MODELO BOX-JENKINS 2. SARIMA 3. PREVISÃO DE DEMANDA 4. SÉRIES TEMPORAIS I. Universidade Estadual do Norte Fluminense Darcy Ribeiro. Centro de Ciência e Tecnologia. Laboratório de Engenharia de Produção II. Título

CDD 658.4034


LUIZA RANGEL JUSTINIANO

**PREVISÃO DE DEMANDA PELO MÉTODO BOX JENKINS SAZONAL: O CASO
DE UMA EMPRESA METALMECÂNICA**

Dissertação apresentado ao Laboratório de Engenharia de Produção - LEPROD, da Universidade Estadual do Norte Fluminense Darcy Ribeiro - UENF – Campos / RJ, como parte das exigências para obtenção do título de Mestre em Engenharia de Produção.

Submetida em 18 de Maio de 2018.

BANCA EXAMINADORA:



Prof.ª Gudelia G. M. de Arica – D.Sc

Universidade Estadual do Norte Fluminense Darcy Ribeiro - UENF



Prof. Marcus Vinicius da Silva Sales – D. Sc.

Universidade Federal Fluminense (UFF)



Prof. José Ramón Arica Chávez – D. Sc.

Universidade Estadual do Norte Fluminense Darcy Ribeiro – UENF



Prof. Frederico Galaxe Paes – D. Sc.

Instituto Federal Fluminense (IFF)

Universidade Estadual do Norte Fluminense - UENF

CAMPOS DOS GOYTACAZES, RJ.

Maio-2018

AGRADECIMENTOS

Agradeço a Deus por ter me dado condições para desenvolver este trabalho e principalmente por ele não ter me abandonado nos momentos mais difíceis.

Em seguida, os meus pais pelo amor, compreensão, encorajamento e dedicação, sem os quais, com certeza, nunca teríamos chegado aos objetivos traçados.

E também, à minhas irmãs pelo companheirismo, amizade e por sempre estarem disponíveis a nos ajudar nos momentos que precisamos.

Agradeço também a minha orientadora e meu coorientador, Professora Gudélia G. Morales e José Ramón Arica Chávez pela confiança, incentivo e apoio na orientação.

À Universidade Estadual do Norte Fluminense Darcy Ribeiro, pela oportunidade de continuidade dos meus estudos.

Aos colegas do curso de Mestrado em Engenharia de Produção, pela convivência construtiva e solidária.

A todos que, direta ou indiretamente, acreditaram, incentivaram e colaboraram, durante a realização desta pesquisa.

A Capes, por tornar esse sonho realidade, viabilizando financeiramente.

Por fim, agradeço a Dourizete Castro, meu companheiro, que abdicou de fins de semana e de algumas noites e madrugadas para me apoiar, me ajudar com minhas revisões e avaliações da minha pesquisa. E principalmente pela força que me deu para eu chegar até o final.

RESUMO

Partindo do princípio importante da escolha do modelo adequado para aplicar previsão em certo tipo de série de dados obtidos em sequência foi desenvolvida esta pesquisa, com o principal objetivo de descrever modelos de Séries de Temporais. Esta pesquisa é o estudo de caso de uma empresa do setor metalúrgico americano, fabricante de mais de mil e seiscentos modelos de vibradores industriais, para os quais se estima a demanda de alguns dos seus produtos da linha de pistões de vibração, utilizando técnicas de séries temporais. O modelo de previsão de demanda proposto neste trabalho, Autorregressivo Integrado de Média Móvel Sazonal (SARIMA), melhora a previsão no sentido de confiabilidade e precisão dos dados gerados por ele. Comparando com outros modelos de previsão, através de índices de avaliação que são utilizados na literatura, verificam-se as vantagens, e o comportamento do SARIMA em relação aos métodos de Decomposição, Suavização Exponencial e Média Móvel. Algumas vantagens do uso do SARIMA, encontradas na pesquisa, são a capacidade de apresentar resultados com intervalo de confiança de 95% e previsões para períodos mais longos.

PALAVRAS-CHAVES: Modelo Box-Jenkins; SARIMA; Previsão de Demanda; Séries Temporais.

ABSTRACT

Assuming that it is important to choose the appropriate model to apply forecast to a certain type of data series obtained, in sequence this research was developed, with the main objective of describing Time Series models. This research is the case study of a company in the American metallurgical sector, manufacturer of more than sixteen hundred models of industrial vibrators, for which the demand for some of its vibration piston line products is estimated using a technique of time series. The demand-forecasting model proposed in this work, Seasonal Autoregressive Integrated Moving Average (SARIMA), improves the forecast in the sense of reliability and precision of the data generated by it. Comparing with other prediction models, through the evaluation indexes that are used in the literature, it verifies the advantages and the behavior of the SARIMA in relation to the Decomposition, Exponential Smoothing and Moving Average methods. Some advantages of using SARIMA, found in the research, are the ability to present results with a 95% confidence interval and forecasts for longer periods.

KEYWORDS: Model Box-Jenkins; SARIMA; Forecast of Demand; Time series.

SUMÁRIO

CAPÍTULO I – CONSIDERAÇÕES INICIAIS	9
1.1 Introdução	9
1.2 Objetivo.....	11
1.2.1 Objetivo Geral	11
1.2.2 Objetivo Específicos	11
1.3 Verificação.....	11
1.4 Justificativa	12
1.5 Metodologia	12
1.6 Estrutura do Trabalho.....	14
CAPÍTULO II – PESQUISA BIBLIOMÉTRICA SOBRE PREVISÃO POR SERIE TEMPORAIS NA	
INDÚSTRIA	16
2.1. Pesquisa Bibliométrica	17
2.2 Análise de citação.....	23
2.3 Análise de co-citação	25
2.4 Conclusão da bibliometria	28
CAPÍTULO III –MÉTODOS DE PREVISÃO DE DEMANDA POR SÉRIES TEMPORAIS	30
3.1 Séries temporais.....	30
3.2 Métodos de previsão por séries temporais.....	31
3.2.1 Suavização exponencial.....	32
3.2.2 Média móvel.....	32
3.2.3 Decomposição	33
3.2.4 Sazonal Auto Regressivo Integrado de Média Móvel	34
3.2.4.1 Autorregressão Integrada de Média Móvel (ARIMA)	35
3.2.4.2 Autorregressão Integrada de Média Móvel Sazonal (SARIMA)	38
3.3 Software GRETL.....	39
3.4 Medida de precisão para a previsão	40
CAPÍTULO IV – DADOS E RESULTADOS	42
4.1Dados dos pistões de vibração	42
4.2 Resultado dos Métodos de Previsão	44
4.2.1 Autorregressivo Integrado a Média Móvel Sazonal	44
4.2.2 Suavização exponencial.....	52
4.2.3 Média móvel.....	54
4.2.4 Decomposição	55
4.3 Avaliação dos métodos de Previsão	59
CAPÍTULO V - CONSIDERAÇÕES FINAIS.....	63
REFERÊNCIAS BIBLIOGRÁFICAS	65
ANEXO I	71

ANEXO II	74
ANEXO III	82
ANEXO IV	88

CAPÍTULO I – CONSIDERAÇÕES INICIAIS

Primeiramente será exposta uma visão geral sobre o tema de previsão de demanda por séries temporais, a ser abordado neste trabalho, iniciando com uma introdução que visa apresentar o estado da arte deste tema, além dos objetivos propostos e das motivações consideradas para o desenvolvimento desta pesquisa.

1.1 Introdução

Um dos primeiros passos para se tomar qualquer decisão para o planejamento de uma empresa é a previsão da demanda, de vendas ou de capacidade; ou seja, previsão de dados específicos que fornecem informações adequadas para a tomada de decisões. A importância de usar um modelo adequado de previsão, está em gerar resultados de maior qualidade para que possa chegar a resoluções melhores (ARMSTRONG, 2001). Decisões tomadas agora influem em consequências futuras que podem ser positivas ou negativas para as atividades empresariais. Portanto, a previsão precisa e eficiente é um fator chave para o gerenciamento de uma empresa. Quanto melhor o uso das informações atuais disponíveis para previsões futuras, maiores as chances de sucesso (HOPP, SPEARMAN, 2001). Assim, esta pesquisa leva em consideração a importância do entendimento dos dados históricos de uma empresa no esforço de se fazer a melhor escolha de um método de previsão, fornecendo resultados próximos dos dados reais que permitam uma avaliação da previsão, promovendo, conseqüentemente, um melhor gerenciamento da empresa.

Uma previsão pobre gera efeitos, como excesso ou falta de estoque, produtividade baixa, ineficiência na utilização de recursos e ineficiência na cadeia de suprimento industrial (NENNI *et al.*, 2013).

Por outro lado, embora não existam previsões perfeitas, não se tem como tomar decisões de forma sensata sem dimensionar as quantidades de bens ou serviços a serem produzidos: Qual o tamanho da força de trabalho a se manter ou qual o tamanho de estoque a ser mantido se não houver alguma estimativa da demanda? (HOPP, SPEARMAN, 2001). Nesse sentido, a área industrial deve ser incentivada a sempre manter-se eficiente, com o propósito de gerar dados precisos para uma melhor previsão do futuro.

Existem diversos métodos que podem ser usados para previsão. Os métodos que são relevantes para uma situação considerada dependem dos objetivos do estudo e das condições enfrentadas pela empresa (como o tipo de dados disponíveis). Muitas vezes, não há um único melhor método. Na verdade, é conveniente usar métodos diferentes e combinar as previsões (ARMSTRONG *et al.*, 2008). O objetivo principal não é identificar o melhor método de previsão, mas combinar previsões, se apropriado, para usar mais de um método para a série de dados estudada. Sugere-se selecionar métodos de previsão que parecem relevantes, fazer previsões com cada um deles e, em seguida, calcular a previsão média (ARMSTRONG, 2001). Este procedimento gera ganhos em precisão reduzindo o erro em 12% (GRAEFE *et al.*, 2012).

Embora a literatura recomende utilizar a combinação de vários métodos, ainda assim se faz interessante comparar os métodos. Uma abordagem que pode ser tomada é um tipo de torneio ou competição entre métodos alternativos de previsão. Para fazer isso com sucesso, é necessário atender a três condições: a primeira, é comparar os métodos com base no desempenho anterior; a segunda, é comparar as previsões com os métodos de previsão bem aceitos; e, a última, é utilizar uma amostra adequada para as previsões (ARMSTRONG *et al.*, 2008).

Tendo compreendido as questões iniciais para a escolha de um método de previsão adequado para uma empresa, esta pesquisa tem como objetivo desenvolver o método de previsão chamado Autorregressivo Integrado de Média Móvel Sazonal (SARIMA, *Seasonal Autoregressive Integrated Moving Average*). Este modelo é útil em situações em que os dados de séries temporais apresentam sazonalidade. Essa característica torna o modelo SARIMA adequado para estudos sobre dados mensais de demanda, uma vez que o número de produtos a ser vendido tende a ser sujeito a variações sazonais (WIWANITKIT, 2012). SARIMA é o modelo de regressão linear mais popular para previsão de séries temporais sazonais. Tem obtido grande sucesso em pesquisa acadêmica e aplicações industriais durante as últimas três décadas (CHOI *et al.*, 2011).

A fim de mostrar como o desempenho da metodologia do SARIMA pode gerar uma previsão mais acurada, esta pesquisa também faz uma comparação com outros

métodos de previsão muito comuns: média móvel, suavização exponencial e decomposição (JUSTINIANO, 2015).

Esta pesquisa apresenta o estudo de caso de uma empresa americana no setor de engenharia mecânica (JUSTINIANO, 2015). Devido à confidencialidade solicitada, o nome da empresa não será revelado, mas é registrado que a empresa é fabricante de mais de mil e seiscentos modelos de vibradores industriais para o mercado americano. A empresa forneceu os dados de demanda mensal passada de seus produtos no período de quatro anos (2011 a 2014) e precisa da previsão da demanda de vários produtos. Esses produtos serão chamados de Produto G, H I J K e L, do qual o Produto H é usado para demonstrar a aplicação de métodos de previsão. O Produto H passa por todos os processos da metodologia de previsão SARIMA, por isso foi escolhido de forma aleatória entre os outros produtos com a mesma característica.

1.2 Objetivo

A seguir será apresentado o objetivo geral que conduz a pesquisa, assim como a verificação a ser alcançada no estudo de caso.

1.2.1 Objetivo Geral

Desenvolver uma comparação e análises de comportamento do método de previsão econômica (SARIMA) confrontando seus resultados com outros modelos de previsão, como suavização exponencial, média móvel e decomposição.

1.2.2 Objetivo Específicos

Desenvolver um modelo SARIMA de previsão para a empresa estudada, tendo em vista a comparação da performance do modelo SARIMA com outros modelos, com foco na análise da precisão desses métodos.

1.3 Verificação

Verificar a relevância do modelo SARIMA em relação aos modelos de previsão de Suavização Exponencial, Média Móvel e Decomposição.

1.4 Justificativa

Uma atividade de grande relevância para o planejamento estratégico de uma empresa é o planejamento da sua capacidade, para o qual é necessário um sistema de previsão forte e eficiente (PROTO; MESQUITA, 2003).

Uma empresa com Plano de Negócios e planejamento produtivo eficiente alcança melhores resultados, gerando bom desempenho, fazendo com que a mesma se destaque competitivamente no mercado industrial.

As empresas podem produzir produtos que são estocados, pois tem demanda continua, ou produtos que são produzidos por ordens, por não terem demanda frequente, entretanto, a previsão de demanda se realiza para ambos os tipos de produto (MANCUZO, 2003). Normalmente fatores fora da linha de produção podem interferir nas vendas e pedidos de ordem da companhia. O consumo de um produto pode depender, por exemplo, de fatores naturais, de fatores sazonais, de necessidades dos consumidores, de falta de utilidade ou de geração de novos produtos. Contudo, para evitar gerenciamento de estoque inadequado utiliza-se a previsão de demanda.

1.5 Metodologia

Inicialmente utilizou-se à pesquisa bibliográfica para levantar dados de estudos sobre a previsão por séries temporais na indústria. No intuito de investigar se a ferramenta de previsão se estima importante para a cadeia de suprimento e se vem sendo de interesse de pesquisadores e de empresários. A pesquisa bibliográfica foi realizada através da análise de materiais disponíveis em livros, artigos, teses e dissertações, além de consultar dados disponíveis na mídia eletrônica, tendo como base o procedimento da bibliometria.

Para a realização deste trabalho seguiu-se o método de pesquisa denominado estudo de caso, cuja característica principal é determinar um ou mais objetos de estudo, selecionar variáveis que o influenciam e desenvolver um estudo exaustivo do objeto de maneira que se permita o amplo e detalhado conhecimento do mesmo (VENTURA, 2007).

As etapas de um estudo de caso são quatro (GIL, 2008):

- Delimitação da unidade-caso;
- Coleta de dados;
- Seleção, análise e interpretação dos dados;
- Elaboração de relatório.

Este estudo também consta de uma revisão bibliográfica mais específica sobre previsões de demanda baseadas em modelos de séries temporais, como suavização exponencial, médias móveis e modelo de decomposição, usados com frequência neste tipo de abordagem (HOPP; SPEARMAN, 2001; MANCUZO, 2003; PROTO; MESQUITA, 2003).

Em seguida, de forma mais detalhada se explica o que é o modelo SARIMA abordado neste estudo e o seu possível comportamento com dados de séries temporais. Por fim, o método de previsão de demanda desenvolvido se compara com a demanda real, com o método de média móvel, com o método de suavização exponencial e com o método de decomposição de forma a se ter uma ideia da precisão dos resultados.

A previsão por séries temporais precisa de sequência ordenada de dados que serão provadas estacionárias ou que poderão ser feitas estacionárias, com transformações adequadas. Assim, é conveniente discutir o conceito de estacionariedade.

Por enquanto, considera-se o seguinte. Uma série temporal é uma sequência de medições de uma variável aleatória recolhida ao longo do tempo (de forma discreta), onde na maioria das vezes as medições são feitas em intervalos de tempo regulares (CAVALHEIRO, 2003). Uma série temporal, com horizonte T , será denotada por:

$$\{Y_t\}_{t=1}^T = \{Y_1, Y_2, \dots, Y_T\}. \quad (1)$$

A maioria dos modelos em séries temporais assume que são estacionárias, o que, *grosso modo*, significa que a média, a variância e as covariâncias defasadas (no tempo: t e $t+k$) das variáveis Y_t não dependem do tempo. Uma série temporal que não satisfaz alguma das propriedades anteriores, diz-se série temporal não estacionária. É importante entender a estacionariedade de uma série temporal como certo padrão

de comportamento, pois, se a série não for estacionária só poderá ser estudada no período de tempo em consideração. Cada período diferente será uma nova série. Portanto, não será possível generalizar seu comportamento (GUJARATI, 2004).

Como neste estudo se considera por vez apenas uma única série temporal, os procedimentos para a avaliação de mais de um método de previsão, para uma mesma série temporal, são os erros médios relacionados com os desvios do modelo em relação aos dados coletados (WALLSTRÖM, 2009). Neste caso os desvios clássicos considerados no presente estudo são o Desvio Absoluto Médio (*Mean Absolute Deviation*, MAD) e o Erro Quadrado Médio (*Mean Square Error*, MSE), que medem variações com relação aos dados reais. Também utilizou-se o Erro Percentual Absoluto Médio (*Mean Absolute Percentage Error*, MAPE), que trata de um indicador de acerto de estimativa. Como complemento, uma vez que o sinal de erro de um indivíduo é considerado, é possível calcular erros sistemáticos ou tendenciosidade, por isso também é utilizado o indicador Viés (*Bias*).

Por fim, foram utilizados os softwares Excel (com o uso da ferramenta Solve) e o software GRETLM (*Gnu Regression, Econometrics and Time-series Library*), um software livre que compila e interpreta dados econométrico, para realizar as análises estatísticas, os gráficos e as tabelas apresentadas nesse estudo de caso.

1.6 Estrutura do Trabalho

A estrutura do trabalho inicia-se no Capítulo I com a exposição exploratória sobre a temática abordada, bem como as delimitações da pesquisa quanto aos métodos e metas que serão utilizados para alcançar os objetivos do estudo, apresentando as justificativas plausíveis para o emprego de esforços junto da presente pesquisa.

O Capítulo II, realiza a exploração do tema de previsão por métodos de séries temporais na área industrial e empresarial. Exploração essa realizada pelo método de bibliometria, com o objetivo de retratar o cenário da literatura com relação ao campo de estudo desse trabalho. Através dessas informações prévias, justificar a escolha do tema de pesquisa mostrando que o campo de estudo ainda precisar ser muito explorado.

Já o Capítulo III propõe-se a explicar de forma detalhada as metodologias dos métodos de previsão utilizados no trabalho, além das ferramentas de apoio à realização da pesquisa.

Seguindo para o Capítulo IV, os dados aqui estudados são apresentados e analisados para que uma visão geral das series estudadas seja fornecida. Tendo o conhecimento dos dados, aplicam-se as previsões de demanda e os resultados são apresentados e avaliados.

Por fim, o Capítulo V relata as conclusões do estudo, assim como os resultados mais relevantes e se os objetivos e hipóteses do estudo foram alcançados.

CAPÍTULO II – PESQUISA BIBLIOMÉTRICA SOBRE PREVISÃO POR SÉRIE TEMPORAIS NA INDÚSTRIA

Este capítulo busca levantar dados de estudos sobre a previsão por séries temporais na área de cadeia de suprimento das indústrias e empresas, tendo como base o procedimento da bibliometria. Assim, é investigado se a ferramenta de previsão se percebe importante para a área cadeia de suprimentos e se é de interesse de pesquisadores e de empresários.

A gestão da cadeia de suprimentos tem atraído atenção tanto do lado acadêmico quanto da parte empresarial e industrial que, por sua vez, vem buscando caminhos para melhorar suas posições competitivas no mercado global. Gestão da cadeia de suprimentos está relacionada com coordenação do fluxo do(s) produto(s) e de informação para os fornecedores, produtores, distribuidores, vendedores e consumidores. Recentemente, as empresas perceberam a importância da partilha de informação e integração entre os participantes na cadeia de suprimento, mais ainda existe o receio do compartilhamento de informações sobre sua produção por medo de ser usado de forma desleal ao seu desfavor (ZHAO *et al.*, 2002). Uma forma de incentivar as empresas a compartilharem informações é mostrando o benefício que esse sistema de partilha, pela cadeia de suprimento, pode trazer.

Um fator importante que favorece uma cadeia de suprimentos é a justeza da previsão de demanda (WILLEMAIN *et al.*, 2004). Embora a iniciativa de compartilhar informação na cadeia de suprimentos ajude a reduzir erros de previsão, a capacidade de previsão da empresa continua a ser um trunfo importante porque as previsões não confiáveis resultam em ineficiências na cadeia de suprimento (ZHAO *et al.*, 2002). Uma previsão colaborativa e um re-planejamento permitem que uma empresa e seus fornecedores coordenem as decisões através da troca de complexos modelos de apoio à decisão e estratégias, facilitando a integração de previsão e de produção programada (CARBONNEAU *et al.*, 2008).

Assim, na gestão da cadeia de suprimentos, a previsão de demanda tem um importante papel, pois através desta são obtidas informações de valor para muitas atividades básicas de logísticas incluindo compras, gerenciamento de estoque e transporte (BENKACHCHA *et al.*, 2014). A análise de séries temporais é uma metodologia com base em estatísticas, que podem fornecer previsões de demanda

acuradas. O benefício de previsões precisas não só pode minimizar as diferenças entre as vendas reais e previstas, mas pode ter outras implicações sobre outras complexidades da cadeia de suprimentos, como a gestão de excesso de inventário e obsolescência (MARTIN e FREI, 2003).

A demanda futura desempenha um papel muito importante no planejamento da produção e no gerenciamento de estoques, são necessárias previsões bastante precisas. O setor manufatureiro tem tentado administrar a incerteza da demanda por muitos anos, o que levou a apoiar o desenvolvimento de muitos métodos e técnicas de previsão que podem ser usados e combinados para alcançar a previsão mais ajustada para o tipo de série que se necessite trabalhar (GUTIERREZ *et al.*, 2008).

2.1. Pesquisa Bibliométrica

Uma forma muito utilizada para uma revisão da literatura escrita e análise geral de publicações científicas é a bibliometria. Trata-se de uma técnica quantitativa e estatística de medição dos índices de produção e disseminação do conhecimento científico, surgiu pela necessidade do estudo e da avaliação das atividades de produção e comunicação científica (FONSECA, 1986). Para visualizar os resultados da bibliometria utiliza, aqui, o auxílio de um *software* ou plataforma chamada de *Gephi*, desenvolvido para analistas de dados e cientistas interessados em explorar e entender o relacionamento, por redes ou grafos, entre seus dados de grande tamanho. “*Gephi* é uma plataforma gratuita e de código aberto, visual interativa e exploratória para todos os tipos de redes e sistemas complexos, dinâmicos e grafos hierárquicos” (GEPHI, 2013). A escolha por essa plataforma foi pelo fato da sua flexibilidade e facilidade para visualização dos grafos e pela variedade de indicadores fornecidos para análise de uma rede.

Para o estudo bibliométrico foi seguido a metodologia utilizada por Fahimnia *et al.* (2015). Dessa forma, foi utilizada a mesma base de dados Scopus com as palavras chaves “*Forecast*”, “*Time Series*” e “*Supply Chain*”, que poderiam apresentar no título, resumo ou palavras-chave. A pesquisa foi realizada em Junho de 2016 envolvendo todo o tipo de arquivo, em todas as línguas, em todos os territórios e abrangendo todo período temporal da base.

A pesquisa retornou 89 documentos. Foi feita uma filtragem para apenas serem considerados artigos em revistas científicas, sendo excluído Trabalho de Conferência,

Trabalho de revisão de Conferência, Revisão, Artigo na imprensa e Pequenos questionários, resultando em 57 artigos, como pode ser visto na Tabela 1.

Tabela 1. Tipos de documentos resultantes da pesquisa pela base de dados Scopus

Tipo de Documentos	Resultado da pesquisa
Artigos	57
Trabalho de Conferência	26
Trabalho de revisão de Conferência	2
Revisão	2
Artigo na imprensa	1
Pequenos questionários	1
Total	89

Em seguida, foram exportados os 57 artigos para o software EndNote (ferramenta online que armazena, organiza referências bibliográficas com versão gratuita para estudantes) e foram filtrados todos os artigos onde os autores eram anônimos ou que resultavam irrelevantes a respeito do tema da pesquisa. Foi removido apenas 1, totalizando 56 artigos relevantes publicados no período de 2002 a 2016, como mostra a Figura 1.




Figura 1. Publicações anuais na área de Previsão por series temporais na área de cadeia de suprimento.

Na Figura 1, verifica-se que as pesquisas sobre esse assunto tiveram maior abordagem a partir de 2006, atingindo seu pico em 2010. Verifica-se também, que a partir de 2012 se manteve uma média de até 4 artigos publicados por ano, o que mostra que o interesse nesse tema continua em evidência.

Dos 56 artigos realmente analisados, resultaram 634 citações sendo que a maioria dos artigos foi escrito por mais de um autor. Identificou-se que os trabalhos foram desenvolvidos por 88 instituições, distribuídas em 26 países. A Tabela 2 mostra um resumo geral desses dados.

Tabela 2. Dados Globais

Critério	Quantidade de Publicações
Artigos	56
Autores	146
Periódicos	42
Instituições	88
Países	26
Citados por	634

Para uma análise dos autores foi considerado a relação entre autores, quantidade de publicações e número total de citações. Primeiro, mostra-se na Tabela 3 que, dos 146 autores, apenas 2 tiveram 2 artigos publicados em parceria, o que não são números significativos para classificar os autores. Dessa forma foi criado um ranking dos 10 autores que foram mais citados durante todo o período de 2002 até 2016, mostrado na Tabela 4.

Tabela 3. Quantidade de publicações por autor

Número de artigos publicados	Número de Autores
2	2
1	144
Total	146

Tabela 4. Ranking dos artigos mais citados

Titulo do Artigo	Autor	Ano						Subtotal	Total
		Antes	2012	2013	2014	2015	2016		
<i>A new approach to forecasting intermittent demand for service parts inventories</i>	Willemain, Smart, Schwarz (2004)	74	12	13	7	16	5	53	127
<i>Lumpy demand forecasting using neural networks</i>	Gutierrez, Solis, Mukhopadhyay (2008)	19	10	9	8	10	5	42	61
<i>A Fuzzy agent-based model for reduction of bullwhip effect in supply chain systems</i>	Zarandi, Pourakbar, Turksen (2008)	17	8	7	6	7	0	28	45
<i>Measuring Imputed Cost in the Semiconductor Equipment Supply Chain</i>	Cohen , Ho, Justin Ren, Terwiesch (2003)	29	2	4	1	5	1	13	42
<i>Forecasting Thailand's rice export: Statistical techniques vs. artificial neural networks</i>	Co, Boosarawongse (2007)	20	5	5	5	3	2	20	40
<i>Predictive analysis on electric-power supply and demand in China</i>	Huang, He, Cen (2007)	18	6	4	7	2	1	20	38
<i>Product demand forecasts using wavelet kernel support vector machine and particle swarm optimization in manufacture system</i>	Wu (2010)	12	2	8	4	6	1	21	33
<i>Combining day-ahead forecasts for British electricity prices</i>	Bordignon, Bunn, Lisi, Nan (2013)	0	0	4	10	8	4	26	26
<i>Impacts of forecast, inventory policy, and lead time on supply chain inventoryA numerical study</i>	Warren Liao, Chang (2010)	2	3	8	8	5	0	24	26
<i>Information distortion in a supply chain and its mitigation using soft computing approach</i>	Balan, Vrat, Kumar (2009)	10	6	5	2	0	0	13	23
	Total	201	54	67	58	62	19	260	461

Analisando a Tabela 4, é possível identificar que mesmo que a maioria dos autores apenas publicaram um artigo nesse assunto, todos os 10 autores do ranking tiveram ao todo 461 citações do total de 634 citações. Os autores mais citados são Willemain *et al.*, (2004), obtendo 127 citações, com o artigo “*A new approach to forecasting intermittent demand for service parts inventories*”. Esse artigo mostra a aplicação do método de *bootstrapping*, a qual esse produz previsões mais precisas da distribuição da demanda ao longo de um prazo de execução fixa do que fazer suavização exponencial e, pelas características do produto, tratou de demanda intermitente (isto é, de itens com períodos sem demanda e com baixa variação de quantidade) para o que usou o método de Croston. Outros autores muito citados foram Gutierrez *et al.*, (2008); Zarandi *et al.*, (2008); Cohen *et. al.*, (2003), com 61, 45 e 42 citações, respectivamente.

Para uma análise dos periódicos foi levado em consideração o número de publicações nesse assunto em cada um deles e a classificação do sistema Qualis Capes mais recente (ano de 2014). Os 56 artigos selecionados estão distribuídos em 42 periódicos diferentes, demonstrando que não há uma concentração do tema de pesquisa em um mesmo periódico. A Tabela 5 apresenta os 5 periódicos que tiveram maiores números de publicação no tema da pesquisa. Dentre os 5, apenas um não foi considerado pela classificação Qualis 2013 Capes, os outros se encontrando na classificação A e B mostrando que os periódicos que mais publicaram são de alta relevância para o meio acadêmico.

Tabela 5. Top 5 periódicos e número de publicações

Periódicos	Publicações	Qualis Capes
<i>International Journal Of Production Economics</i>	8	B4
<i>Expert Systems With Applications</i>	4	A2
<i>International Journal Of Forecasting</i>	3	-
<i>International Journal Of Production Research</i>	3	A2
<i>Management Science</i>	2	B2

Com relação a origem das publicações, levou-se em consideração as universidades e o país de origem dos 56 artigos selecionados. Na Tabela 6 se encontram as universidades com maiores números de publicações; estas

tiveram apenas 2 publicações o que não é um número tão significativo. Porém, quando se amplia a visão para o país de origem, os Estados Unidos se destacam com 13 das 56 publicações, como pode ser observado na Tabela 7. Vale ressaltar também que dentre as 5 universidades com os maiores números de publicações nenhuma delas foi americana.

Tabela 6. Top 5 instituições e número de publicação

Instituições	Publicações
<i>Universita degli Studi di Padova</i>	2
<i>Southeast University</i>	2
<i>National Taiwan University</i>	2
<i>Amirkabir University of Technology</i>	2
<i>Bangor University</i>	2

Tabela 7. Top 10 Países e número de publicações

Países	Publicações
Estados Unidos	13
China	6
Taiwan	5
Reino Unido	5
Índia	4
Itália	4
Espanha	4
Canadá	3
Tailândia	3
Dinamarca	2

Tabela 8. Áreas de Pesquisa e número de publicações

Áreas de Pesquisa	Publicações
Engenharia	25
Negócios, Gestão e Contabilidade	24
Ciências da decisão	22
Economia, Econometria e Finanças	12
Ciência da Computação	11
Matemática	8
Ciências Sociais	6
Ciências Agrárias e Biológicas	4
Energia	3
Engenharia Química	2
Ciência ambiental	2
Bioquímica , Genética e Biologia Molecular	1
Terra e Ciências Planetárias	1
Multidisciplinar	1

Com relação às áreas acadêmicas que tiveram mais interesse em pesquisar sobre como previsão por séries temporais interferem na cadeia de suprimento, 3 áreas se destacam, como mostra a Tabela 8. Engenharia com 25 artigos publicados nesse tema, negócio, gestão e contabilidade com 24 publicações e ciência da decisão com 22. Na Tabela 8 também observa-se que a maioria dos artigos são de interesse da área acadêmica das ciências exatas.

Por fim, analisam-se as palavras que mais apareceram nos títulos e nas palavras-chaves dos artigos. Para essa análise não foram levados em consideração os artigos definidos e indefinidos, preposições, símbolos, etc. Na **Erro! Fonte de referência não encontrada.** são mostradas as 13 palavras mais frequentes nas publicações: “*Forecasting*”, “*Supply Chains*”, “*Supply Chain Management*” e “*Time Series*”.

Tabela 9. Palavras-chave mais populares

Palavras chave	Número de vezes que apareceu
<i>Forecasting</i>	30
<i>Supply Chains</i>	23
<i>Supply Chain Management</i>	22
<i>Time Series</i>	20
<i>Time Series Analysis</i>	15
<i>Demand Forecasting</i>	12
<i>Supply Chain</i>	9
<i>Exponential Smoothing</i>	7
<i>Forecasting Method</i>	6
<i>Mathematical Models</i>	6
<i>Neural Networks</i>	6
<i>Competition</i>	5
<i>Computer Simulation</i>	5

2.2 Análise de citação

A análise de citação é uma investigação da frequência, padrão e redes das citações de artigos, livros e trabalhos científicos em geral (LEYDESDORFF e AMSTERDAMSKA, 1990). As citações em trabalhos acadêmicos são usadas para estabelecer ligações com outros trabalhos ou pesquisas. A análise de citação é usado para examinar o grau de conectividade entre pares de nós, ou seja, de artigos em uma amostra de dados (FAHIMNIA *et al.*, 2015). As

ferramentas de análise de citação auxiliam para calcular várias medidas de impacto para os estudiosos baseados em dados de índices de citação (HOANG *et al.*, 2010).

A análise de citação feita estuda a conectividade entre os pares de artigos (nós) na rede criada pelos 57 artigos obtidos na pesquisa bibliométrica. Inicialmente, na análise de citação representada com a plataforma Gephi, revela que 25 artigos dos 57 citaram um ao outro. Aproximadamente 26% dos artigos não foram citados nenhuma vez. Os 10 artigos mais citados pelos próprios 57 artigos (citação local) são mostrados na Tabela 10 e comparados com o número de vezes que os mesmos foram citados entre todos os outros artigos da base de dados *Scopus* (citação global).

Tabela 10. Os 10 artigos mais citados localmente: medidas de citação

Autores (ano)	Citação Local	Citação Global
Willemain, Smart e Schwarz (2004)	4	127
Gutierrez, Solis e Mukhopadhyay (2008)	4	61
Co e Boosarawongse (2007)	2	40
Wu (2010)	2	33
Shahrabi, Mousavi e Heydar (2009)	2	10
Shukla e Jharkharia (2011)	2	9
Turrado García, García Villalba e Portela (2012)	2	8
Cohen, Ho, Justin Ren e Terwiesch (2003)	1	42
Bordignon, Bunn, Lisi e Nan (2013)	1	27
Wallström e Segerstedt (2010)	1	14

A primeira observação a ser notada na Tabela 10 é a variação do número de citação local para o de citação global. Essa diferença mostra que o tema de previsão por séries temporais na área de cadeia de suprimento vem recebendo uma relevante atenção em outras áreas de conhecimento, ou seja, eles foram citados por outros trabalhos que estão fora da nossa pesquisa bibliométrica. Também é observado que a ordem de artigos mais citado na visão local não bate com a ordem de artigos mais citado globalmente. Por exemplo, Cohen, *et al.*, (2003) se encontra na oitava posição com relação a citação local, mas se encontra na quarta posição com relação as citações globais. Esse resultado

mostra que alguns trabalhos podem ser mais populares fora da área de cadeia de suprimento, na visão global.

2.3 Análise de co-citação

A co-citação é uma medição similar as usadas na análise de citação para estabelecer uma relação entre documentos. Essa medição é definida como a frequência com o qual dois documentos são citados juntos por outro documento, ou seja, se no mínimo outro documento citar dois documentos em comum esses documentos podem ser ditos co-citados (SMALL, 1973). É uma indicação de que existe uma probabilidade de que as duas obras tratam de um assunto relacionado para ambas (MARTYN, 1964). Quanto mais co-citações um documento recebe, mais alta é a força de co-citação e mais provável deles serem semanticamente relacionados (SMALL, 1973).

A análise da rede de co-citação é uma forma de análise exploratória de dados que se baseia na teoria de grafos para explorar a estrutura de dados (LEWIS-BECK *et al.*, 2004). A estrutura da rede de co-citações consiste em um conjunto de nós que representam artigos ou periódicos e um conjunto de ligações que representam a co-ocorrência de nós (artigos) na lista de referência de publicações dessa rede (LEYDESDORFF e AMSTERDAMSKA, 1990).

O primeiro mapeamento de co-citação realizado no aplicativo *Gephi*, revelou que existem 21 artigos do total de 57 que foram co-citados por outros artigos dentro desta amostra. Ao importar os dados da nossa amostra de publicação no *Gephi*, a primeira rede de publicação que é formada tem um formato aleatório, ou seja, os nós tem posições aleatórias e as ligações se sobrepõem. Com essa configuração inicial não é fácil observar as características da rede, mas o *Gephi* oferece vários algoritmos para mudar o padrão da rede para que possa ser observada características específicas na rede. Dessa maneira, foi aplicada a opção *Layout Force Atlas* para alterar a primeira configuração aleatória da rede, e ainda de maneira manual foram reposicionados alguns nós para melhor visualização de características relevantes, como os pontos de co-citação, os artigos com o maior valor de *PageRank* (uma medida da importância das citações, neste caso) e os artigos mais citados. A Figura 2 mostra a configuração da rede de publicações analisada no seu formato

aleatório, onde os nós em vermelho são os 57 artigos geradores dessa rede. A Figura 3 mostra a rede configurada no *Layout Force Atlas*.




Figura 2. Rede de Publicações em formato aleatório

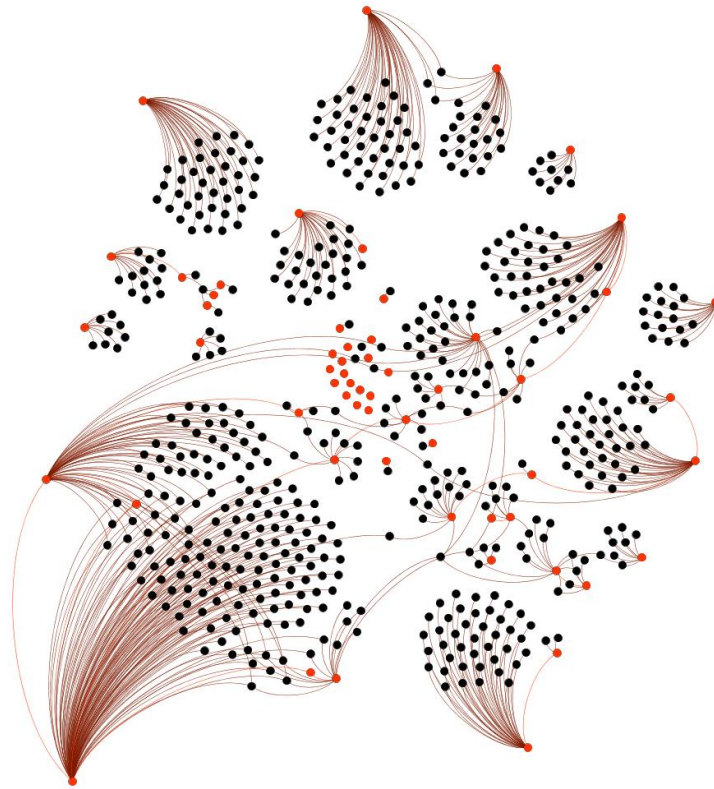


Figura 3. Rede de publicações em formato *Force Atlas*

Para uma melhor visualização das co-citações foi utilizado o formato *Force Atlas* e feito algumas alterações manuais na configuração dos nós. Na Figura 4 são destacados com um círculo azul os pontos de co-citação mais evidentes na rede. Também com o objetivo de incrementar o relatório, foi calculado no próprio *Gephi* os valores de *PageRank*. O *PageRank* é usado para medir a popularidade e o prestígio de um artigo. Dessa forma, na Figura 5, é apresentada a rede de publicação no formato circular com a variação de tamanhos dos nós, onde quanto maior for o tamanho do nó, maior é o valor *PageRank*, ou seja, mais popular e prestigiado é o artigo.

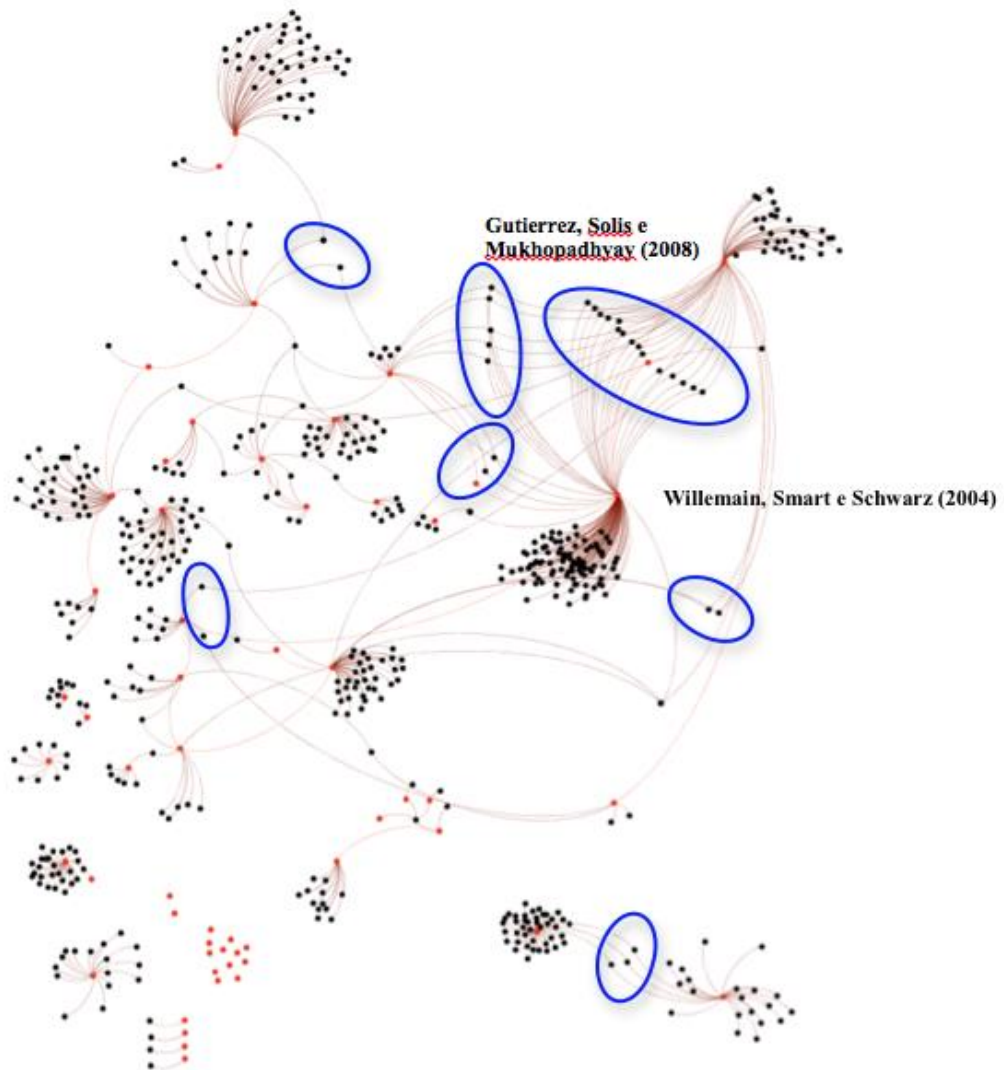


Figura 4. Pontos mais evidentes de co-citação




Figura 5. Medição de *PageRank*

Na Figura 5 se evidencia a importância do artigo escrito por Willemain *et al.* (2004), pois ele foi classificado em primeiro lugar quanto a citações local e globais e obteve uma maior medida na métrica *PageRank*. Além disso, cabe realçar, na Figura 3 o mesmo artigo é o artigo mais co-citado, comprovando assim sua relevância ao tema previsão por séries temporais na área de cadeia de suprimento.

2.4 Conclusão da bibliometria

Através da revisão de literatura pelas ferramentas estatísticas da bibliometria com relação ao campo da previsão por série temporal em cadeias de suprimento, foi possível identificar um crescimento de publicações relacionadas ao tema até o ano 2010. Após esse período houve uma queda nas publicações, porém observa-se uma constância de publicação nesse tema em torno de 4 publicações por ano. Dessa forma, mostra que o assunto ainda vem

sendo investigado e que ainda há grandes oportunidades de pesquisa nessa área. Também, observou-se uma predominância do tema nos artigos das ciências exatas no meio acadêmico. Isso foi detectado tanto para a área de atuação dos artigos quanto para os periódicos que foram publicados. Outro fator observado foi o grande interesse desse tema nos Estados Unidos.

A partir dos 57 artigos selecionados na pesquisa bibliométrica, foi possível identificar uma rede de publicações. Em uma análise inicial dessa rede, o artigo que ganha destaque é dos autores Willemain *et al.*, (2004) que foi o mais citado na visão global, citado por 127 artigos. Dentre os 57 artigos obtidos na pesquisa bibliométrica Willemain *et al.*, (2004) também foi o mais citado, junto com Gutierrez *et al.* (2008), que foram citados por 4 artigos.

Com a plataforma *Gephi*, foi explorado mais a rede de publicações com uma análise de co-citação. Essa análise enfatiza ainda mais a importância do artigo Willemain, Smart e Schwarz (2004) para o tema da pesquisa bibliométrica, pois esse artigo é o que recebe maior número de co-citações, indicando que tem um tema que abrange o interesse de muitos artigos.

O uso do *Gephi* incrementou a pesquisa bibliométrica. Pela metodologia de transversalidade da teoria dos grafos do programa, é possível verificar se o artigo que se destacou na avaliação de referências é realmente o mais relevante para o tema em que está sendo pesquisado. A plataforma, ainda permite uma análise fora do ambiente das palavras-chaves utilizadas na pesquisa bibliométrica, dessa forma, amplia o ambiente de estudo e permite fazer ligações com novos conteúdos.

Por fim, entende-se que o uso da ferramenta de previsão por séries temporais em cadeias de suprimento ainda é pouco explorada encontrando assim, uma oportunidade para estudos futuros da sua aplicação e como essa realmente melhora o processo da gestão da cadeia de suprimento. Outros trabalhos que necessitam ser explorados abordam sobre como o aperfeiçoamento da previsão da demanda de uma empresa afeta toda a cadeia de suprimento.

CAPÍTULO III –MÉTODOS DE PREVISÃO DE DEMANDA POR SÉRIES TEMPORAIS

3.1 Séries temporais

A análise de séries temporais identifica padrões não aleatórios na série de dados supondo que é um sistema relacionado com o tempo, onde o que influencia dados no passado pode continuar influenciando no futuro (MENEZES, 2007). Os métodos de previsão por séries temporais primeiramente modelam o fenômeno estudado para, a partir disso, descrever o comportamento da série, fazer estimativas e avaliar quais dos fatores influem no comportamento da mesma, para o qual existe um conjunto de técnicas estatísticas disponível (LATORRE e CARDOSO, 2001). A análise das séries temporais tem por objetivo determinar um modelo que descreva o padrão da série histórica. Assim, permitindo descrever as características importantes do padrão de séries temporais, explicar como o passado afeta o futuro ou como duas séries temporais podem interagir, prever os valores futuros da série, ou servir como um padrão de controle de uma variável que mede a qualidade do produto em algumas situações de fabricação (ARMSTRONG *et al.*, 2008).

A vantagem da abordagem do método de previsão por série temporal que normalmente resulta em modelos simples, fornecendo uma visão mais clara para o comportamento da série. Portanto, pode sugerir possíveis causas de variação e ajudar a identificar a estrutura básica, levando a uma melhor compreensão do problema (WANG *et al.*, 2012).

Previsões de demanda podem ser feitas por métodos quantitativos, por métodos qualitativos ou combinação de ambos. Os métodos qualitativos se baseiam em opiniões e experiências empresariais, o que os torna mais influenciáveis por interpretações diversas, sendo assim menos confiáveis (PELLEGRINI e FOGLIATTO, 2001). Estes métodos não respondem a um modelo específico, mas a uma abordagem, e são usados principalmente quando não se possuem dados suficientes sobre a demanda (BOX *et al.*, 2015). Por outro lado, os métodos quantitativos consistem em modelos matemáticos baseados em dados históricos da empresa que fornecem informações sobre a variação da demanda durante certo período de tempo (FERNANDES e

ANZANELLO, 2010). Os modelos matemáticos utilizados pelos métodos quantitativos podem ser causais ou de séries temporais. Os causais relacionam a resposta (a demanda) a uma série de fatores que a determinam por meio de uma relação matemática, precisando assim de uma análise dos possíveis fatores, com uma base de dados extensa. Já os métodos de séries temporais, supõem que se pode estabelecer o comportamento imediato da variável estudada (a demanda) a partir apenas do seu comportamento passado, precisando de uma base de dados bastante menor (BOX et al., 2015).

Este estudo é focados nos métodos quantitativos de séries temporais. Os dados de séries temporais têm como característica principal a dependência entre dados vizinhos, que é estudada quando se realiza a análise de séries temporais (EHLERS, 2009). Ou seja, os métodos de previsão quantitativa consistem em modelos matemáticos que levam em conta a informação numérica do passado (séries temporais) e assumem a possibilidade de que alguns aspectos dos padrões passados sejam repetidos no futuro.

Por exemplo, no método de Decomposição (Seção 3.2.3), um método quantitativo de previsão, o primeiro passo na análise de séries temporais é modelar o fenômeno de estudo, em seguida, descrever o comportamento da série, fazer estimativas e avaliar quais os fatores que influenciam o comportamento. Possíveis fatores que influem na série temporal são:

- Tendência (T), que é o comportamento da demanda do produto por um longo período de tempo;
- Variações cíclicas (C), que são flutuações nos valores de variáveis superiores a um ano que podem seguir o ciclo econômico;
- Variação sazonal (S), que é a variação que ocorre ano após ano com uma duração inferior a um ano, muitas vezes no mesmo período e quase na mesma magnitude;
- Variação irregular (I), que é a que não segue um padrão, flutuações não explicadas.

3.2 Métodos de previsão por séries temporais

3.2.1 Suavização exponencial

As aleatoriedades ou coincidências em dados semanais, mensais, sazonais ou anuais de séries temporais podem ser removidas por métodos de suavização (ÖNDER e KUZU, 2014). Existem vários métodos de suavização, por exemplo, Suavização Exponencial, Suavização Exponencial Holt, Suavização Exponencial Holt-Winters. Para este trabalho se utiliza o método chamado Suavização Exponencial (*Exponential Smoothing*).

A Suavização Exponencial é utilizada como uma forma simplificada de prever demanda. A escolha pelo método Suavização Exponencial se justifica pelo fato de ser um método muito usado para prever demanda. Suavização Exponencial é o caminho usado para descontar fatores interferentes dos dados antigos, onde os dados mais recentes têm mais pesos do que os dados mais antigos (HOPP e SPEARMAN, 2001). As relações usadas são:

$$F_t = \alpha Y_{t-1} + (1 - \alpha)F_{t-1}, \quad t = 1, 2, \dots, T \quad (2)$$

onde, t é o período de tempo que esta sendo observado (atual), Y_{t-1} é a demanda respectiva ao período $t - 1$ (período anterior), F_t é a previsão para o período t , e α é uma constante de suavização entre 0 e 1, que pode ser escolhida pelo usuário ou otimizada para um melhor resultado da previsão.

$$\text{Através da } F_t = \alpha Y_{t-1} + (1 - \alpha)F_{t-1}, \quad t = 1, 2, \dots, T \quad (2)$$

, aplicou-se o método de Suavização Exponencial nos dados das séries temporais deste trabalho para a geração da previsão e dos índices de avaliação MAPE, MAD, MSE e VIES (ver Seção 3.4).

3.2.2 Média móvel

A média móvel tem como base o cálculo de uma média simples, contudo ao invés de usar todos os dados anteriores no cálculo de uma média para a previsão se usa apenas alguns dos dados mais recentes (MENTZER e MOON, 2004). A previsão feita por média móvel se realiza com as seguintes formulas.

$$F_t = \frac{1}{m} \sum_{i=t-m}^t Y_i \quad (3)$$

onde, t é o período de tempo que está sendo observado, Y_i é a demanda respectiva ao período i , F_t é a previsão para o período t e m , a ordem do método, é um parâmetro escolhido pelo usuário que representa o intervalo de tempo t que se leva em consideração para o cálculo da previsão (a memória do método), por exemplo, quando $m=3$ utiliza períodos de 3 meses anteriores para calcular uma média e prever o próximo período.

Utilizando períodos de três meses em caso ocorram tendências em curto tempo e de seis meses em caso ocorram tendências em períodos maiores, a relação da Equação 3 foi aplicada para cada produto afim de prever a demanda.

3.2.3 Decomposição

O método de decomposição explica a possível influência das componentes com Tendência (T), Variação Sazonal (S), Variação Cíclica (C) e Variação Irregulares (I) em séries temporais, dividindo cada um desses componentes, identificando o quanto esse componente está influenciando a série e, finalmente, fazendo a previsão (WANG *et al.*, 2012).

Nem todos os modelos de séries temporais apresentam todos os fatores listados acima. A decomposição de dados de tempo ajudará a identificar quais desses fatores estão agindo no conjunto de dados em estudo. Um ponto importante do modelo de decomposição é decidir como relacionar todos os componentes que estão influenciando os dados de séries temporais (MENEZES, 2007). Existem duas opções: o modelo aditivo ($Y = T + S + C + I$) e o modelo multiplicativo ($Y = T \times S \times C \times I$). Este estudo utiliza o modelo multiplicativo, pois a série trabalhada na pesquisa apresenta muita variação e de proporções diferente, ou seja, existe uma dependência entre a sazonalidade e a tendência.(FÁVERO *et al.*, 2003).

A primeira etapa é decompor a Tendência (medir a influência do fator T). Identificar a tendência permite a remoção deste componente da série em estudo, para que ele possa ter uma melhor visão dos outros componentes que podem interferir na demanda (MORETTIN e TOLOI, 2004). O método para obter a tendência utilizada aqui foi a regressão linear.

A segunda etapa é decompor a Variação Sazonal (medir a influência do fator S). Este estágio do método de decomposição, que é o cálculo do índice sazonal, pode ser chamado *dessazonalização* dos dados da série. Isso ajuda a não fazer inferência errada sobre algum aumento ou diminuição ao longo de um período de tempo. O método usado para calcular o índice sazonal é conhecido como proporção por média móvel. Ele mostra quão acima ou abaixo a demanda de um período está em comparação com a demanda de todo o ano.

A terceira etapa é decompor a Variação Cíclica e Irregular (medir a influência dos fatores C e I). As variações cíclicas são flutuações de longo prazo em torno da tendência, mas não têm a frequência que caracteriza o padrão sazonal (BOUZADA, 2012). No entanto, as variações irregulares são derivadas de componentes aleatórias, decorrentes de situações inexplicáveis. Estas variações nem sempre são facilmente visíveis. Alguns casos necessitam de dados por uma década para observar essa variação (MENEZES, 2007). No entanto, para este estudo de caso, essas variações são levadas em consideração para ter uma análise completa das séries temporais trabalhadas. A obtenção de ciclos e irregularidades é possível removendo a tendência e a sazonalidade dos dados iniciais da série.

Antes de iniciar a previsão foi adotado nesse modelo o efeito calendário. O efeito calendário consiste em um ajuste para o comprimento do mês em dias. Se esse ajuste na variação no comprimento do mês não for feito, os efeitos podem aparecer como um efeito sazonal, que pode não causar sérios erros de previsão, mas certamente dificultará a interpretação de quaisquer padrões sazonais (“Forecast Friday Topic”, 2010).

Feito o processo de decomposição, são computados os valores de T, S, C e I. Assim, é possível prosseguir para o processo de recomposição, o processo de associação de todos os componentes que têm influência nas séries temporais pelo modelo de Decomposição considerado, realizando a previsão de demanda.

3.2.4 Sazonal Auto Regressivo Integrado de Média Móvel

Neste trabalho, a metodologia do modelo Autorregressivo Integrado de Média Móvel (ARIMA), proposta por Box e Jenkins (1918), é extensamente

explorada. Essa é uma técnica de previsão avançada que consiste no processo Autorregressivo (AR), onde está a memória dos valores passados, o processo de Integração (I), que faz a série estacionária, e o processo de Média-Móvel (MA), que contabiliza os termos de erros anteriores fazendo com que melhore a previsão (OTU et al., 2014a). O modelo SARIMA é derivado da metodologia ARIMA. Este método incorpora o processo de Média-Móvel Sazonal (SMA) e o processo de Autorregressão Sazonal (SAR) ao modelo ARIMA (MAAROF et al., 2014). Para explicar a metodologia do modelo inicia-se com a explicação do método ARIMA.

3.2.4.1 Autorregressão Integrada de Média Móvel (ARIMA)

A publicação da obra *Time Series Analysis: Forecasting and Control*, por Box e Jenkins (1978), deu início a uma nova geração de ferramentas de previsão. Popularmente conhecida como metodologia de Box-Jenkins (BJ), mas tecnicamente denominada metodologia ARIMA, a ênfase desses métodos não está na construção de modelos de equações, mas em analisar as propriedades probabilísticas ou estocásticas das séries temporais à luz da filosofia “deixem os dados falar por eles mesmos”. A diferença dos modelos de regressão, onde Y_t se explica por k regressores X_1, X_2, \dots, X_k , os modelos de séries temporais do tipo BJ explicam Y_t por valores passados ou defasados de si mesma e de termos de erro estocástico. Por esta razão, às vezes, os modelos ARIMA se denominam atóricos, pois não derivam de uma teoria específica (GUJARATI, 2004).

O método ARIMA é uma extensão do método Média Móvel Autorregressivo (ARMA). Os modelos ARMA, supõem que a série temporal que está sendo modelada satisfaça uma condição de comportamento estável, denominado *estacionariedade* (fraca). Comportamento este caracterizado pelo fato de que a média e a variância de Y_t sejam independentes do tempo, além da autocovariância de Y_t , na defasagem k , dependa só da defasagem e não do tempo; i.e., a série temporal Y_t é *estacionária* (fracamente) se $E(Y_t) = \mu$, $var(Y_t) = E(Y_t - \mu)^2 = \sigma^2$ e $Y_k = E[(Y_t - \mu)(Y_{t+k} - \mu)]$, $k = 1, 2, \dots$

A metodologia ARIMA analisa a série e, se necessário, transforma a série para a condição de estacionariedade (processo que se denomina integração, I). O processo de integração se realiza por diferenças dos valores da série.

Definindo o operador diferença como $\Delta Y_t = Y_t - Y_{t-1}$, geram-se novas séries a partir de Y_t , realizando sucessivas diferenças, se necessário, até a série gerada ser estacionária. Aplicando-se o *operador diferença* sucessivamente d vezes à série original para esta se tornar estacionária, diz-se que a série foi integrada d vezes (note que $d=2$, $\Delta^2 Y_t = \Delta \Delta Y_t = \Delta(Y_t - Y_{t-1}) = \Delta Y_t - \Delta Y_{t-1} = Y_t - 2Y_{t-1} + Y_{t-2}$).

Um teste simples de estacionariedade se baseia na chamada *função de autocorrelação* (FAC). A FAC na defasagem k , denotada por ρ_k , define-se por:

$$\rho_k = Y_k / (\sqrt{\text{var}(Y_t)} \sqrt{\text{var}(Y_{t+k})}) \quad (4)$$

A representação gráfica de ρ_k contra k se conhece como *correlograma populacional*. Desde que ρ_k é adimensional, variando entre -1 e +1, como qualquer coeficiente de correlação, valores próximos de 0 para diversos valores de k indicam que autocovariância Y_k , na defasagem k , não depende do tempo. Assim, se o correlograma populacional está próximo de zero, este sinaliza no sentido da estacionariedade.

Adicionalmente se define a *função de autocorrelação parcial* (FACP) e o correlograma resultante, que não são outra coisa do que o gráfico da FACP contra o comprimento da defasagem. O conceito de autocorrelação parcial é análogo ao de coeficiente de regressão parcial. No modelo de regressão múltipla de k variáveis: o k -ésimo coeficiente de regressão β_k mede a taxa de variação média da variável regredida para uma mudança unitária na k -ésima variável regressora X_k , quando todas as outras variáveis se mantêm constantes. Analogamente, a autocorrelação parcial ρ_{kk} mede a correlação entre observações (de séries temporais) que estão afastadas k períodos, considerando constantes as correlações das defasagens intermediárias (i.e., defasagens menores do que k). Em outras palavras, a autocorrelação parcial entre Y_t e Y_{t-k} é a autocorrelação entre essas duas variáveis depois de eliminar o efeito das Y 's intermediárias ($Y_{t-i}, i = 1, 2, \dots, k-1$, ou seja, variáveis intermediária). As correlações parciais calculam-se na maioria dos pacotes estatísticos (GUJARATI, 2004).

Uma vez integrada, a série passa a ser descrita por um processo de auto regressão de ordem p (AR(p)); isto é, modela-se a série integrada dependendo dos seus p valores passados. Adiciona-se, ainda uma modelagem em função dos erros aleatórios associados aos q últimos valores da variável aleatória, denominado processo de média móvel de ordem q (MA(q)). Finalmente, têm-se os parâmetros p , d e q que descrevem o modelo ARIMA (p,d,q). Depois de identificados os parâmetros do modelo, feitas as estimações do modelo ARIMA, gera-se o diagnóstico para a escolha do modelo mais adequado e por fim é feita a previsão (GOH; LAW, 2002).

Para expressar e entender os modelos ARIMA em geral, Box-Jenkins (1971) propôs o uso da notação do operador de retrocesso (atraso ou defasagem) B e operador de diferença ∇ . Eles não têm significado matemático, senão facilitar a escrita de diferentes tipos de modelos que de outra forma seriam tediosos (OTU et al., 2014). O operador de atraso é definido como $B^m Y_t = Y_{t-m}$. Por exemplo, $BY_t = Y_{t-1}$ e $B^{12}Y_t = Y_{t-12}$. O operador diferença toma a forma $\nabla^d = (1 - B)^d$, quando d diferenças são tomadas para alcançar a estacionariedade nos dados de séries temporais.

A modelagem matemática do ARIMA vem da integração do modelo AR (Auto Regressivo) combinado com o modelo MA (Média móvel). Iniciando a demonstração pela combinação dos modelos AR e MA, temos o modelo ARMA (p, q) dado como (PERMANASARI et al., 2013):

$$\phi_p(B)Y_t = \theta_q(B)e_t, \text{ onde } \begin{cases} \phi_p(B) = 1 - \phi_1 B^1 - \phi_2 B^2 - \dots - \phi_p B^p \\ \theta_q(B) = 1 - \theta_1 B^1 - \theta_2 B^2 - \dots - \theta_q B^q \end{cases} \quad (5)$$

onde B é operador de translação para o passado definido $B^m Y_t = Y_{t-m}$; $\phi_p(B)$ é a parte autoregressiva não-sazonal de ordem p ; e $\theta_q(B)$ é a parte não-sazonal de média móvel de ordem q . No modelo ARMA é feito o processo de integração introduzindo a ordem (d) de diferenças para a série se tornar estacionária.

$$Z_t = \nabla^d Y_t = (1 - B)^d Y_t, \quad (6)$$

onde Z_t é a série estacionária, $\nabla^d = (1 - B)^d$ e d é a ordem de diferenciação. Após, o processo de diferenciação é obtido o modelo ARIMA (p, d, q), dado como:

$$\nabla^d \phi_p(B) Y_t = \theta_q(B) e_t \quad (7)$$

3.2.4.2 Autorregressão Integrada de Média Móvel Sazonal (SARIMA)

A metodologia SARIMA é a mesma do ARIMA. Porém, enquanto o ARIMA só trabalha com séries sem a presença da sazonalidade, o SARIMA considera sazonalidade. De forma simplificada, a metodologia SARIMA é a metodologia ARIMA aplicada duas vezes, na parte não sazonal e na parte sazonal. O modelo SARIMA é representado por SARIMA (p,d,q)x(P,D,Q)_s, onde os parâmetros p, d e q são referentes à parte não sazonal da série, os parâmetros P, D e Q são referentes à parte sazonal da série e o parâmetro s indica a duração do período sazonal em anos, dias ou horas; p e P representam a ordem de autorregressão, d e D representam a ordem de diferenciação, e q e Q representam a ordem de média móvel no modelo. Por exemplo, em uma série de dados diários, para considerar sazonalidade semanal, de dados mensais e sazonalidade trimestral ou de dados mensais e sazonalidade mensal, ter-se-á, respectivamente, $s = 7$ (7 dias na semana), $s = 4$ (quatro trimestre no ano) e $s = 12$ (12 meses no ano) (PERMANASARI, et al., 2013).

Para formalizar o modelo, também é utilizado o operador de retrocesso (B). A modelagem matemática do SARIMA vem do ARIMA e inclui a autorregressão sazonal SAR (P), a média móvel sazonal SMA (Q) e a integração sazonal (D), dado como (MAAROF *et al.*, 2014):

$$\nabla^d \phi_p(B) \nabla_S^D \Phi_P(B^S) Y_t = \theta_q(B) \Theta_Q(B^S) e_t. \quad (8)$$

$$\text{onde} \begin{cases} \phi_p(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p \\ \Phi_P(B^S) = 1 - \Phi_1 B^S - \Phi_2 B^{2S} - \dots - \Phi_P B^{PS} \\ \theta_q(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q \\ \Theta_Q(B^S) = 1 - \Theta_1 B^S - \Theta_2 B^{2S} - \dots - \Theta_Q B^{QS} \end{cases}$$

sendo B é o operador de atraso, como explicado antes, i.e. $BY_t = Y_{t-1}$ e $Be_t = e_{t-1}$. Podemos dizer que Y_t é o valor da previsão no período t, e_t é o valor do ruído branco no período t, $\phi_p(B)$ é um autorregressivo não-sazonal de ordem

ρ , $\Phi_P(B^S)$ é a um autorregressivo sazonal de ordem P , $\theta_q(B)$ é uma média móvel não sazonal de ordem q e $\Theta_Q(B^S)$ é uma média móvel sazonal de ordem Q . Tem-se também $\nabla^d = (1 - B)^d$ como sendo a diferença não sazonal de ordem d e $\nabla_S^D = (1 - B^S)^D$ como sendo a diferença sazonal de ordem D em períodos S .

De forma sucinta, a metodologia Box-Jenkins (BJ), aqui utilizada, consiste em quatro etapas iterativas (PERMANASARI *et al.*, 2013):

Etapa 1: Identificação. Este passo centra-se na seleção da ordem de diferença não sazonal (d), diferença sazonal (D), ordem não-sazonal Autorregressivo (p), ordem sazonal Autorregressivo (P), ordem não sazonal Média Móvel (q) e a ordem sazonal Média Móvel (Q). O número de ordem pode ser identificado observando-se as auto-correlações da amostra (SAC) e as auto-correlações parciais da amostra (SPAC).

Etapa 2: Estimativa. Os dados históricos são usados para estimar os parâmetros do modelo experimental na-Etapa 1.

Etapa 3: Verificação de diagnóstico. O teste de diagnóstico é utilizado para verificar a adequação do modelo tentativo.

Etapa 4: Previsão. O modelo final da Etapa 3 é usado para prever os valores.

A metodologia BJ tem várias vantagens, envolvendo extrair uma grande quantidade de informação da série temporal, usando um número mínimo de parâmetros, e a capacidade de manusear e séries temporais não-estacionárias em elementos não sazonais e sazonais (CALDWELL, 1971; CHANG *et al.*, 2009).

3.3 Software GRETL

O GRETL (*Gnu Regression, Econometrics and Time-series Library*) é um pacote de programas de código aberto, multiplataforma, com ferramentas para pesquisa de dados econométricos e pronto para internet (DE ANDRADE, 2013). Devido estas características, a facilidade de interação com a interface do programa, e o custo zero, foi escolhido esse software dentro outros que trabalham som series temporais.

O GRETl suporta vários estimadores estatísticos de mínimos quadrados, modelos de séries temporais e vários métodos de máxima verossimilhança. Dentre esses, inclui uma interface gráfica do usuário para o ambiente X-12-ARIMA (KURBALIJA *et al.*, 2010). O X-12-ARIMA é um pacote computacional de ajuste sazonal que inclui uma variedade de ferramentas para superar problemas de ajuste e ampliar assim o intervalo de séries temporais econômicas que podem ser sazonalmente ajustadas (LANGSRUD, 2011). Considera vários conceitos, tais como: ajuste sazonal de dia de negociação e efeito de dias de férias alternativo, decomposição alternativa da tendência sazonal-irregular, modelos extensivos de séries temporais e capacidades de seleção de modelo para modelos de regressão linear com erros ARIMA (FINDLEY *et al.*, 1998).

Durante o desenvolvimento da pesquisa, a ferramenta X-12-ARIMA sofreu melhorias, com isso passa-se a ser conhecido como X-13-ARIMA (como é chamada nos relatórios do GRETl). Dentre as melhorias destaca-se novos diagnósticos que auxiliam o usuário a detectar e corrigir inadequações no ajuste, por exemplo, o pré-ajuste da série temporal permitindo tratar de eventos atípicos e não sazonal (efeito calendário, greves, catástrofes, entre outros) que podem afetar o padrão sazonal e conseqüentemente interferir no ajuste (FERREIRA *et al.*, 2015).

Usa-se, aqui, o GRETl e sua ferramenta X-12-ARIMA para os modelos SARIMA propostos. As previsões, seguem os seguintes passos (TSENG *et al.*, 2002):

1. Identificação da estrutura SARIMA $(p,d,q) \times (P,D,Q)_s$, usando a função de autocorrelação (FAC) e a função de autocorrelação parcial (FACP).
2. Estimação dos parâmetros desconhecidos.
3. Testes de qualidade de ajuste sobre os parâmetros estimados.
4. Previsão dos dados futuros com base nos dados conhecidos.

3.4 Medida de precisão para a previsão

Apesar de um modelo raramente ser sempre o melhor para qualquer conjunto de dados, a precisão do modelo de previsão precisa ser avaliada, de modo que o modelo que produz o menor erro, ou seja, a diferença entre a

previsão (F_t) e o valor real da série (Y_t), possa ser identificado. Existem várias maneiras de interpretar erros. Entre uma série de medidas de erros possíveis, os mais utilizados são o Erro Absoluto Médio Percentual (*Mean Absolute Percentage Error*, MAPE), o Erro Quadrático Médio (*Mean Square Error*, MSE), o Desvio Absoluto Médio (*Mean Absolute Deviation*, MAD) e o Viés (erro sistemático ou tendenciosidade) (WITT; WITT, 1995). Cada um deles tem suas vantagens, limitações e aplicações exclusivas. Considerando Y_t como o valor real da série no período t , F_t com o valor de previsão no período t e T como o número de períodos utilizados no cálculo, os erros anteriores estão definidos como:

$$\text{MAPE} = \frac{100}{T} \sum \left| \frac{Y_t - F_t}{Y_t} \right| \quad (9)$$

$$\text{MSE} = \frac{\sum (Y_t - F_t)^2}{T} \quad (10)$$

$$\text{MAD} = \frac{\sum |Y_t - F_t|}{T} \quad (11)$$

$$\text{VIES} = \frac{\sum (Y_t - F_t)}{T} \quad (12)$$

O MAD é um tipo de medida de erro que mede a propagação média do mesmo. Esta medida pode ser usada para determinar a magnitude dos erros de previsão gerados pela metodologia de previsão em uso. A vantagem deste estimador do erro entre o valor anotado na série Y_t e o valor previsto F_t , no tempo t , é a facilidade de interpretação; já uma desvantagem, deve-se ao fato de que a fórmula toma o valor absoluto dos termos de erro, ignorando a importância de uma sobre ou subestimação (GORARD, 2015).

O MSE é simplesmente a média de erros quadrados para todas as previsões. É preferível quando mais peso deve ser dado a grandes erros, porém sua limitação é que pode ser excessivamente sensível a um único grande erro. Assim como o MAD, não fornece informações sobre se o modelo está ou não sobrestimando ou subestimando os dados (GOH; LAW, 2002).

O MAPE define o erro relativo ou percentual, e é especialmente útil quando as unidades de medida de Y_t são relativamente grandes (HYNDMAN; KOEHLER, 2006).

Note que o VIES pode ser positivo, o que significa que a previsão está sendo sobrestimada, ou negativo, o que significa que a previsão está sendo subestimada. O objetivo é achar um valor o mais próximo de zero, contudo, isso não quer dizer que a previsão é precisa e sim que os valores estão balanceados (HOPP; SPEARMAN, 2001).

CAPÍTULO IV – DADOS E RESULTADOS

4.1 Dados dos pistões de vibração

A empresa em estudo forneceu dados mensais dos seus produtos (pistões de vibração), dos anos de 2011 a 2014, dos quais foram selecionados seis produtos (aqui denominados G, H, I, J, K e L). Para demonstração da aplicação da metodologia SARIMA, utiliza-se, aqui, o produto H como exemplo (o mesmo procedimento se realiza para os outros produtos e os resultados se apresentam nos Anexo I e II, ao final deste trabalho). Como também os gráficos e tabelas que serão apresentados foram gerados no software GRETEL.

Nas Tabelas 19 até 24, no Anexo I, estão apresentados os dados da demanda de todos os produtos mencionados, do ano de 2011 ao ano de 2014, totalizando 47 observações mensais (47 meses) para cada caso. A Figura 6 apresenta o gráfico da demanda do produto H. As primeiras observações que podem ser feitas sobre a série é que existe uma tendência decrescente na demanda do Produto H e que provavelmente existe um efeito sazonal na série.

A Figura 7 mostra o correlograma do Produto H (i.e., o gráfico das funções FAC e da FACP versus os períodos de defasagem k). O correlograma permite observar se a série é estacionária ou não. Como o SARIMA só trabalha com séries estacionárias, antes de iniciarmos a montagem do modelo tem-se que tornar a série estacionária (caso ela não seja).




Figura 6 - Gráfico da série temporal da demanda do Produto H.
Fonte: Elaboração própria com base nos dados da pesquisa




Figura 7 - Correlograma do Produto H

Fonte: Elaboração própria com base nos dados da pesquisa

Na Figura 7, no gráfico FAC, observa-se que as defasagens de número 13 e 14 se aproximam de 0, caso a série fosse estacionária, ela não deveria crescer ou decrescer depois desse ponto, ou seja se manter próximo do 0. Não sendo esse o caso, a série parece ser não-estacionária. Para comprovar a estacionariedade da série realizam-se o teste Aumentado de Dickey-Fuller (teste ADF) e o teste KPSS(KWIATKOWSKI et al., 1992).

O teste ADF (denominado *teste de raiz unitária*) tem como hipótese nula (H_0) que a série não é estacionária, sendo a hipótese alternativa (H_1) que a série é estacionária (MODENESI, 2008). Trabalha-se aqui, com nível de significância de 5%. Portanto, se o p-valor (valor crítico), for maior que 0,05 não se rejeita H_0 . Já o teste KPSS tem como hipótese nula (H_0) que a série é estacionária, sendo a hipótese alternativa (H_1) que a série tem raiz unitária (não é estacionária). O teste KPSS trabalha-se, também, com nível de significância de 5%. Este teste faz uma abordagem no domínio da frequência (periodicidade) de uma série temporal, conhecida por Análise Espectral. Na Tabela 11 mostram-se os resultados dos testes de raiz unitária e da análise espectral para todos os produtos.

Tabela 11 - P-valores dos testes de Dickey-Fuller Aumentado e KPSS

Produto	Teste ADF (p-valor)	Teste KPSS (p-valor)	Conclusão
Produto G	0,007731	0,069	Estacionária
Produto H	0,5654	< 0,01	Não estacionária
Produto I	0,6229	>0,10	Não estacionária
Produto J	0,428	0,046	Não estacionária
Produto K	0,8459	0,017	Não estacionária
Produto L	0,199	>0,10	Não estacionária

Características do teste ADF: i) Produto G, H, J: com constante e tendência; ii) Produto I, K e L: sem constante

Características do teste KPSS: i) Produto G, I, K e L: sem tendência; ii) Produto H, J: com tendência

Fonte: Elaboração própria com base nos dados da pesquisa

Como apresentado na Tabela 11, apenas o Produto G é estacionário. Os outros produtos, incluído o Produto H, não resultam estacionários, sendo necessário fazer o processo de diferença nas séries.

Apresentados e analisado os dados dos produtos em estudo, segue para a aplicação da metodologia SARIMA e a apresentação dos resultados da previsão além da comparação com outros métodos de previsão.

4.2 Resultado dos Métodos de Previsão

Inicia-se apresentando a aplicação da metodologia SARIMA e a previsão feita por esse método. Em sequência, apresentam-se os resultados da previsão feita pelos métodos de Média Móvel, Suavização Exponencial e Decomposição, que foram formulados em Justiniano (2015).

4.2.1 Altorregressivo Integrado a Média Móvel Sazonal

Seguindo com o Produto H como exemplo e lembrando que não é uma série estacionária, efetua-se a primeira diferença feita na série e em seguida gera-se o correlograma. Observa-se no gráfico do FAC, Figura 8, que a maioria das defasagens se encontra no intervalo da autocorrelação, muito próxima de zero, indicando possível estacionariedade.




Figura 8 - Correlograma da primeira diferenciação do produto H
 Fonte: Elaboração própria com base nos dados da pesquisa

Da mesma forma, aplicam-se os testes de raiz unitária para verificar se a série se tornou estacionária. Para o teste ADF resultou o p-valor igual a $3,09e-18$, portanto, rejeita-se H_0 . Para o teste KPSS o p-valor resultou maior que 0,10, portanto, não se rejeita H_0 . Concluindo, a série se tornou estacionária.

Dada a estacionariedade da série, continua-se com o primeiro passo da modelagem SARIMA, onde se define o modelo SARIMA $(p,d,q) \times (P,D,Q)_s$. Estabelece-se $s=12$, pois o período é mensal, em ciclos anuais. Define-se a ordem de diferenciação não sazonal do Produto H como $d = 1$, pois só foi realizada uma diferenciação para tornar a série não sazonal estacionária. Para definir os parâmetros autorregressivos não sazonais e de média móvel não sazonal utilizam-se as funções de autocorrelação parcial (FACP), para definir a ordem p , e a função de autocorrelação (FAC), para definir a ordem q . O valor crítico considerado para escolha das ordens é dado por aproximadamente $2/\sqrt{T}$, segundo (PINDYCK; RUBINFELD, 2004), sendo, neste caso, $T = 46$ (as 47 observações iniciais menos 1 da diferença feita). O valor crítico encontrado foi de aproximadamente $2/\sqrt{46} = 0,2948$. Assim, no relatório FACP da Figura 9, observa-se que os valores de FACP que estão acima do valor crítico são o da defasagem 1 e 2, podendo definir, inicialmente, $p = 2$. Agora, no relatório do FAC, também na Figura 9, os dois valores acima do valor crítico são os da defasagem 1 e 2, definindo, logo, inicialmente $q = 2$.

Função de autocorrelação para d_v1
 ***, **, * indicam significância aos níveis de 1%, 5% e 10%
 usando erro padrão $1/T^{0.5}$

Defas.	FAC		FACP		Estat. Q [p-valor]
1	-0.7460 ***		-0.7460 ***		27.3072 [0.000]
2	0.3661 **		-0.4294 ***		34.0337 [0.000]
3	-0.1381		-0.1879		35.0124 [0.000]
4	0.0642		-0.0108		35.2292 [0.000]
5	-0.0949		-0.1253		35.7144 [0.000]
6	0.1161		-0.0761		36.4579 [0.000]
7	-0.0716		0.0331		36.7482 [0.000]
8	0.0249		0.0473		36.7843 [0.000]
9	-0.0284		-0.0527		36.8324 [0.000]
10	-0.0237		-0.2392		36.8668 [0.000]

Figura 9 - Relatório da função de autocorrelação e autocorrelação parcial da primeira diferença
 Fonte: Elaboração própria com base nos dados da pesquisa.

Partindo agora para a análise de sazonalidade da série, primeiramente se gera o periodograma do Produto H, Figura 10. O periodograma é uma análise espectral cujo interesse básico é a periodicidade dos dados (FERNANDES, 2012). Segundo o Teorema do Periodograma acumulado, descrito por Morettin e Tolo (2006), o periodograma pode ser descrito como um estimador da função transformada de Fourier (função de densidade espectral), onde a frequência dos dados é representada no eixo das abscissas e a intensidade da frequência (estimativa da transformada de Fourier) no eixo das ordenadas. Na análise do periodograma, o pico de maior intensidade é a componente periódica. Entretanto, se houver mais de um pico é necessária recorrer ao *teste de raiz unitária sazonal* para comprovar a existência da componente periódica (BATISTA, 2009). Na Figura 10 é possível observar um único pico, o que comprova uma forte presença de sazonalidade, indicando que a série sazonal não parece estacionária. Para confirmar a suspeita de não estacionariedade, aplica-se o teste de raiz unitária Dickey-Fuller Aumentado Sazonal (ADFS), inclui os *dummies* sazonais, na série sazonal do Produto H. O teste ADFS tem o mesmo princípio do teste ADF, (H_0 : a série tem raiz unitária; i.e., não é estacionária). O teste ADFS, realizado com nível de significância de 5%, apresenta-sena Tabela 12. Desde que o p-valor resultou 0,7231, não se rejeita H_0 . A série sazonal não é estacionária.




Figura 10 - Periodograma dos dados do Produto H
 Fonte: Elaboração própria com base nos dados da pesquisa

Tabela 12 - p valores do Teste ADFS

Produto	Teste ADFS (p-valor)	Conclusão
Produto G	0,6249	Não estacionária
Produto H	0,7231	Não estacionária
Produto I	0,6229	Não estacionária
Produto J	0,428	Não estacionária
Produto K	0,7642	Não estacionária
Produto L	0,199	Não estacionária

Fonte: Elaboração própria com base nos dados da pesquisa, gerado pelo GRETL

Na tentativa de tornar a série sazonal estacionária, realiza-se uma diferença sazonal e, em seguida, gera-se o periodograma da série com a diferença sazonal feita (Figura 11). Observa-se agora, nesse periodograma, que não existe apenas uma variação de grande amplitude, indicando mais de um período com o efeito sazonal relevante, podendo ser indicativo da série ter se tornado estacionária. Aplicando o teste de ADFS (Tabela 13), obtém-se o p-valor igual 0,027. Assim, rejeita-se H_0 ; i.e., aceita-se que a série se tornou estacionária.




Figura 11 - Periodograma depois da primeira diferenciação sazonal
 Fonte: Elaboração própria com base nos dados da pesquisa

Tabela 13 - p valores do Teste ADFS depois da primeira diferenciação sazonal

Produto	Teste ADFS (p-valor)	Conclusão
Produto G	1,426e-006	Estacionária
Produto H	0,027	Estacionária
Produto I	3,685e-009	Estacionária
Produto J	6,267e-005	Estacionária
Produto K	2,858e-007	Estacionária
Produto L	2,751e-005	Estacionária

Fonte: Elaboração própria com base nos dados da pesquisa

Após tornar a série sazonal estacionária, identificam-se os parâmetros sazonais. A ordem de diferenciação sazonal (D) é definida pelo número de diferenciações sazonais efetuadas na série; logo $D = 1$. Da mesma forma que na parte não sazonal, obtêm-se os parâmetros de autorregressão sazonal e de média móvel sazonal. Na Figura 12 mostram-se os relatórios da FACP e FAC. O valor crítico agora é aproximadamente $2/\sqrt{35} = 0,33806$, para $n=35$, pois nas 47 observações foi realizada uma diferenciação sazonal, diminuindo 12 observações. A Figura 12 mostra que na FACP, tanto quanto na FAC, os valores que superam o valor crítico se encontram na defasagem 2 e desde que o valor da defasagem 1 não é significativo, pois o p-valor é maior que 0,05, resulta $P = 1$ e $Q = 1$.

Função de autocorrelação para sd_v1
 ***, **, * indicam significância aos níveis de 1%, 5% e 10%
 usando erro padrão $1/T^{0.5}$

Defas.	FAC	FACP	Estat. Q [p-valor]	
1	-0.1341	-0.1341	0.6849	[0.408]
2	0.4318 **	0.4213 **	8.0001	[0.018]
3	0.1199	0.2599	8.5821	[0.035]
4	0.3019 *	0.2238	12.3885	[0.015]
5	0.0606	-0.0095	12.5468	[0.028]
6	0.2994 *	0.1067	16.5493	[0.011]
7	-0.0148	-0.0835	16.5595	[0.020]
8	0.1559	-0.1112	17.7250	[0.023]
9	-0.0812	-0.2092	18.0531	[0.035]
10	0.0616	-0.1411	18.2498	[0.051]

Figura 12 - Relatório da função de autocorrelação e autocorrelação parcial da primeira diferença sazonal
 Fonte: Elaboração própria com base nos dados da pesquisa

Assim, obtém-se o primeiro modelo SARIMA $(p,d,q) \times (P,D,Q)_s$ como sendo SARIMA $(2,1,2) \times (1,1,1)_{12}$, este é o Modelo 1 considerado. No relatório do Modelo 1, gerado pelo X-12-ARIMA (Figura 13), é possível validar o modelo. No relatório analisam-se quais parâmetros são significativos e quais não o são.

Modelo 1: ARIMA, usando as observações 2012:02-2014:11 (T = 34)
 Estimado usando X-13-ARIMA (Máxima verossimilhança exata)
 Variável dependente: $(1-L)(1-L_s) v1$

	coeficiente	erro padrão	z	p-valor
const	0.787748	0.198315	3.972	7.12e-05 ***
phi_1	-0.111926	0.291508	-0.3840	0.7010
phi_2	0.279521	0.174045	1.606	0.1083
Phi_1	-0.185520	0.128794	-1.440	0.1497
theta_1	-1.23387	0.298312	-4.136	3.53e-05 ***
theta_2	0.238833	0.278732	0.8569	0.3915
Theta_1	-1.00000	0.379902	-2.632	0.0085 ***

Figura 13 - Relatório X-12-ARIMA do Modelo1
 Fonte: Elaboração própria com base nos dados da pesquisa

Note, primeiro, que o Theta_1 ($Q = 1$) tem valor significativo, pois o p-valor é menor que 0,05 (nível de significância de 5%). Depois, theta_2 ($q = 2$) não tem valor significativo. Logo, gera-se um segundo modelo, agora com $q = 1$, classificado como Modelo 2 SARIMA $(2,1,1) \times (1,1,1)_{12}$. Na Figura 14 apresenta-se o relatório do X-12-ARIMA para o Modelo 2.

Modelo 2: ARIMA, usando as observações 2012:02-2014:11 (T = 34)
 Estimado usando X-13-ARIMA (Máxima verossimilhança exata)
 Variável dependente: $(1-L)(1-L_s) v1$

	coeficiente	erro padrão	z	p-valor
const	0.794687	0.187058	4.248	2.15e-05 ***
phi_1	-0.354448	0.125799	-2.818	0.0048 ***
phi_2	0.161325	0.135012	1.195	0.2321
Phi_1	-0.199523	0.125725	-1.587	0.1125
theta_1	-0.999784	0.103140	-9.693	3.21e-22 ***
Theta_1	-0.999282	0.417394	-2.394	0.0167 **

Figura 14 - Relatório X-12-ARIMA para o Modelo 2
 Fonte: Elaboração própria com base nos dados da pesquisa

Observa-se que o Theta_1 (Q = 1) se manteve significativa. O theta_1 (q = 1) também é significativa. Porém, percebe-se que phi_2 (p = 2) não é significativo. Então, gera-se o Modelo 3, SARIMA (1,1,1)x(1,1,1)₁₂. Na Figura 15 apresenta-se o relatório do X-12-ARIMA para o Modelo 3.

Modelo 3: ARIMA, usando as observações 2012:02-2014:11 (T = 34)
 Estimado usando X-13-ARIMA (Máxima verossimilhança exata)
 Variável dependente: (1-L)(1-Ls) v1

	coeficiente	erro padrão	z	p-valor	
const	0.713875	0.281375	2.537	0.0112	**
phi_1	-0.506773	0.133584	-3.794	0.0001	***
Phi_1	-0.175154	0.139717	-1.254	0.2100	
theta_1	-0.767046	0.150701	-5.090	3.58e-07	***
Theta_1	-0.998151	0.354079	-2.819	0.0048	***

Figura 15 - Relatório X-12-ARIMA para o Modelo 3

Fonte: Elaboração própria com base nos dados da pesquisa

Na Figura 15, o único parâmetro não significativo é Phi_1 (P = 1), sendo necessário gerar mais um modelo, o Modelo 4 SARIMA (1,1,1)x(0,1,1)₁₂. No relatório X-12-ARIMA do Modelo 4 (Figura 16), verifica-se que todos os parâmetros apresentam valores significativos.

Modelo 4: ARIMA, usando as observações 2012:02-2014:11 (T = 34)
 Estimado usando X-13-ARIMA (Máxima verossimilhança exata)
 Variável dependente: (1-L)(1-Ls) v1

	coeficiente	erro padrão	z	p-valor	
const	0.692413	0.339210	2.041	0.0412	**
phi_1	-0.534091	0.121378	-4.400	1.08e-05	***
theta_1	-0.721821	0.106301	-6.790	1.12e-11	***
Theta_1	-0.998113	0.199039	-5.015	5.31e-07	***

Figura 16 - Relatório X-12-ARIMA para o Modelo 4

Fonte: Elaboração própria com base nos dados da pesquisa

Parte-se, agora, para a etapa de validação do Modelo4 SARIMA (1,1,1)x(0,1,1)₁₂. Escolheu-se um período de seis meses para a validação do Modelo4 (Figura 17). Para a curva da previsão, na Figura 17, apresentam-se os intervalos de confiança (com nível de 95% de confiança). Nota-se que esses intervalos cobrem os dados da série original, indicando que o Modelo 4 tem um bom desempenho.




Figura 17 - Validação do Modelo 4

Fonte: Elaboração própria com base nos dados da pesquisa

Por fim, na Figura 18 e Tabela 14 apresenta-se os resultados da previsão do Produto H, para um período de seis meses futuros. Nota-se que a demanda tende a se manter no mesmo nível com poucas variações e com um intervalo de confiança com uma demanda máxima de aproximadamente 35 unidades e mínima de zero. No Anexo III encontra-se os resultados da previsão dos demais produtos. A Tabela 15 apresenta os modelos SARIMA obtidos para todos os produtos do caso em estudo.




Figura 18 - Previsão do Produto H com o modelo SARIMA(1,1,1)x(0,1,1)₁₂

Fonte: Elaboração própria com base nos dados da pesquisa

Tabela 14 - Previsão do Produto H com o modelo SARIMA(1,1,1)x(0,1,1)₁₂

Para intervalos de confiança de 95%, $z(0,025) = 1,96$					
Obsevações (meses)	Yt	Previsão	Erro Padrão	Intervalo a 95%	
				Mínimo	Maximo
01/2014	1,00	6,52			
02/2014	11,00	3,09			
03/2014	6,00	4,07			
04/2014	4,00	4,69			
05/2014	9,00	5,92			
06/2014	6,00	5,22			
07/2014	16,00	11,22			
08/2014	4,00	8,92			
09/2014	3,00	12,52			
10/2014	10,00	14,54			
11/2014	1,00	- 1,38			
12/2014		12,59	11,339	-9,63	34,82
01/2015		2,23	11,705	-20,71	25,17
02/2015		6,41	12,615	-18,31	31,14
03/2015		9,35	12,631	-15,40	34,11
04/2015		6,25	12,940	-19,11	31,62
05/2015		9,33	13,045	-16,24	34,90

Fonte: Elaboração própria com base nos dados da pesquisa

Tabela 15 - Modelos SARIMA

Produto	Modelo SARIMA
Produto G	SARIMA (2,0,2)x(0,1,1) ₁₂
Produto H	SARIMA (1,1,1)x(0,1,1) ₁₂
Produto I	SARIMA (3,2,1)x(0,1,1) ₁₂
Produto J	SARIMA (1,2,1)x(1,1,1) ₁₂
Produto K	SARIMA (6,1,1)x(0,1,0) ₁₂
Produto L	SARIMA (0,1,1)x(0,1,1) ₁₂

Fonte: Elaboração própria

4.2.2 Suavização exponencial

Através da Equação 2, aplicou-se o método de Suavização Exponencial nos dados das séries temporais deste trabalho para a geração da previsão e dos índices de avaliação MAD, MSE e VIES. As equações obtidas com a aplicação das Equação 2 para cada produto foram diferentes, pois foi aplicado a otimização dos índices de avaliação para a obtenção do α ótimo. O processo de otimização tem o objetivo de minimizar os índices de avaliação da previsão a partir dos seguintes modelos:

$$\text{Minimizar } Z = \frac{\sum_{t=1}^T |e_t|}{T}, \text{ referente ao índice MAD}$$

$$\text{Minimizar } Z = \frac{\sum_{t=1}^T (e_t)^2}{T}, \text{ referente ao índice MSE}$$

$$\text{Minimizar } Z = \frac{\sum_{t=1}^T e_t}{T}$$

Sujeito à

$$e_t = F_t - Y_t$$

$$F_t = \alpha Y_t + (1 - \alpha)F_{t-1}, \quad t = 1, 2, 3, \dots, T$$

$$0 < \alpha < 0,5$$

Como pode ser observado nas restrições, os erros são dependentes da previsão (F_t) e, por sua vez, a previsão é dependente da previsão do período anterior (F_{t-1}) que é dependente do α , dessa forma resultando em uma função não linear. Por isso, utilizou-se a ferramenta Solver do Excel para o cálculo dessa otimização. O Solver utiliza o método de gradiente reduzido para solucionar otimizações não lineares. Também, segundo a metodologia de suavização exponencial, o α dá maior importância para o valor da previsão passada do que para a demanda atual, logo se explica nas restrições o valor de α ser menor que 0,5. Ravindran e Warsing Junior (2013) indicam que os valores de α normalmente usados variam entre 0,1 e 0,4, pois os menores valores de α (por exemplo $\alpha = 0,1$) demoram mais para reagir a mudanças nos dados da demanda, mas a previsão é relativamente suave (baixa variância); por outro lado, valores altos de α podem reagir rápido a mudanças nos dados da demanda, mas a previsão tem variação que resulta em erros com alta variância.

Entendendo que o objetivo é minimizar os valores de MAD, MSE e VIES através de mudança do valor do α (por processo de otimização). Iniciou o processo de otimização com o valor de $\alpha = 0,1$, para todos os produtos. As equações resultantes foram:

$$\text{Para o produto G: } F_t = 0,0869Y_{t-1} + (0,91)F_{t-1}, t = 1, 2, \dots, T$$

$$\text{Para o produto H: } F_t = 0,2405Y_{t-1} + (0,76)F_{t-1}, t = 1, 2, \dots, T$$

Para o produto I: $F_t = 0,0352Y_{t-1} + (0,96)F_{t-1}, t = 1,2, \dots T$

Para o produto J: $F_t = 0,1513Y_{t-1} + (0,85)F_{t-1}, t = 1,2, \dots T$

Para o produto K: $F_t = 0,1243Y_{t-1} + (0,87)F_{t-1}, t = 1,2, \dots T$

Para o produto L: $F_t = 0,0410Y_{t-1} + (0,96)F_{t-1}, t = 1,2, \dots T$

O que diferencia o método de Suavização Exponencial como uma forma de obtenção de tendência para um método de prever demanda, mesmo tendo a mesma forma de raciocínio, é o fato que, utilizado para prever demanda, permite a obtenção da perspectiva futura das demandas para os próximos meses. Por outro lado, usado para obtenção de tendência, utiliza-se apenas para entender o comportamento das series.

Os gráficos e tabelas das previsões por Suavização Exponencial podem ser observados no Anexo II e na Seção Resultados podem ser observados os valores obtidos para os parâmetros de avaliação.

4.2.3 Média móvel

Para a aplicação do método de média móvel a escolha da ordem m (da Equação 3) para prever demanda é um fator muito importante pois, valores mais elevados de m farão um modelo mais estável, porém menos responsivos, para as alterações no processo de previsão (HOPP; SPEARMAN, 2008). Para este estudo se leva em consideração períodos de três em três meses e de seis em seis meses pelo fato de apresentar uma variação muito grande nos dados reais. Não se observa facilmente uma tendência em pequenos ou grandes períodos de tempo. Assim, considerou-se três meses caso ocorra tendências em curto tempo e seis meses caso ocorra tendências em períodos maiores.

Utilizando os períodos de três meses e de seis meses, a Equação 3 foi aplicada para cada produto para prever a demanda. Logo, para cada produto, Equação 3 foi:

Para período de três meses:

$$F_t = \frac{[Y_{t-3} + Y_{t-2} + Y_{t-1}]}{3}$$

Para período de seis meses:

$$F_t = \frac{[Y_{t-6} + Y_{t-5} + Y_{t-4} + Y_{t-3} + Y_{t-2} + Y_{t-1}]}{6}$$

O método de Média Móvel, tanto de ordem 3 quanto de ordem 6 e o método de Suavização Exponencial, foram avaliados pelos parâmetros MAPE, DAM, DQM e VIES.

Os gráficos das previsões por Média Móvel podem ser observados no Anexo II e na seção resultados pode ser observados os valores obtidos para os parâmetros de avaliação.

4.2.4 Decomposição

Para maiores detalhes, o método de Decomposição foi analisado e estudado mais a fundo no Trabalho de Conclusão de Curso da autora, titulado de “Previsão de Demanda: Estudo de Caso em uma Empresa Metalmeccânica por Série Temporal”. Trabalho desenvolvido na Universidade Estadual do Norte Fluminense Darcy Ribeiro em 2015

Os dados da demanda dos produtos são apresentados mensalmente para um período de quatro anos, que é o tempo mínimo recomendado para observação do componente sazonal (MENEZES, 2007).

Após a observação dos gráficos, inicia-se o processo de decomposição que é algoritmicamente explicado a seguir:

Passo 1: Calcular a tendência pelo método de regressão simples.

Passo 2: Dessazonalizar (cálculo dos índices sazonais de cada mês). Os dados coletados da empresa se dividem pelos índices sazonais referentes a seu período.

Passo 3: Obtenção da variação cíclica e irregular. A demanda dessazonalizada obtida no Passo 2 se divide pela tendência obtida no Passo 1 e se obtêm a série de variação cíclica, aplicando média móvel como forma de suavizar as irregularidades do gráfico.

Após cada um desses passos, obtêm-se os índices dos componentes da série temporal com relação à série original, sendo, possível seguir para o processo de recomposição para fazer a previsão de cada um dos produtos.

A recomposição é o processo de associar todas as componentes que causam influência na série temporal pelo modelo considerado (aditivo ou multiplicativo), para fazer a previsão da demanda. Como já mencionado, aqui se considera o modelo multiplicativo, algoritmicamente explicado como segue:

Passo 1: Multiplicar os índices sazonais pela tendência.

Passo 2: Multiplicar o produto obtido no Passo 1 pelos índices de ciclo e irregularidades.

Passo 3: Multiplicar o efeito do calendário para cada mês correspondente ao produto obtido no Passo 2.

Após a recomposição feita se obtêm os dados da previsão. Na previsão da demanda futura, ou seja, para os meses de dezembro de 2014 e todos os meses de 2015, leva-se em consideração a tendência futura (onde não se tem os dados históricos como base). Esclarecendo, todo o processo de recomposição para esse período é feito do mesmo modo, porém, na decomposição (na obtenção dos índices) a tendência e a sazonalidade seguem a equação da regressão feita para a obtenção de tendência dos dados da série original e para as variações cíclicas e irregulares é obtida a regressão para o gráfico suavizado da variação cíclica e irregular e os índices cíclicos desse período seguem a equação dessa regressão. Esse procedimento se explica, pois não tem a existência dos dados reais da série histórica. Assim, faz-se necessário seguir a tendência das séries de dados obtidas para cada componente.

A seguir, são apresentados os resultados do Produto H, utilizado como exemplo. As demais previsões pelo método de decomposição são apresentada no Anexo II.

O fator Tendência (T) do Produto H é dada por $T = 38,377 - 0,857t$ (Figura 19)




Figura 19 – Fator Tendência (T) do Produto H

O fator Sazonalidade (S) do Produto H é analisado na Figura 20 e gerado os índices Sazonais, apresentados na Tabela 15 abaixo:




Figura 20 – Fator Sazonalidade (S) do Produto H

A sazonalidade do produto H tem um período de demanda decrescente de 2011 à outubro de 2012 onde a demanda se mantém quase que constante e volta a cair no início de 2014. Os Índices Sazonais são observados da Tabela 16.

Tabela 16 - Índice sazonal do produto H

Produto H		ANO				Índice Sazonal
MÊS	2011	2012	2013	2014		
Jan		0.6972	0.4292	0.1111	0.4125	
Fev		0.1190	1.4476	1.3822	0.9829	
Mar		1.8561	0.2680	0.9172	1.0138	
Abr		0.5795	0.5340	0.6621	0.5918	
Mai		1.1175	0.9207	1.4694	1.1692	
Jun		0.5375	0.2990	0.9571	0.5979	
Jul	0.6652	1.1473	2.3260		1.3795	
Ago	1.1903	0.2894	2.5091		1.3296	
Set	0.7874	1.3435	1.9726		1.3678	
Out	1.6779	0.6520	0.7636		1.0312	
Nov	0.2540	1.0969	0.2212		0.5240	
Dez	2.2128	1.3779	0.2192		1.2699	

O Fator de Variação Cíclica e Irregular (C e I) é apresentada na Tabela 17 a seguir.

Tabela 17 - Variação cíclica e irregular do produto H

Produto H		ANO				
MÊS	2011	2012	2013	2014	2015	
Jan	2,1321	1,6912	0,5721	0,3639	1	
Fev	1,6649	0,1157	0,9484	1,9280	1	
Mar	0,8265	1,6621	0,1943	1,1963	1	
Abr	2,2723	0,8221	0,7052	1,6525	1	
Mai	0,7777	0,7545	0,6327	2,3811	1	
Jun	2,5164	0,6560	0,3963	4,2244	1	
Jul	0,5821	0,5250	1,3509	7,6379	1	
Ago	1,0260	0,1417	1,5801	4,5492	1	
Set	0,6438	0,6099	1,3042	-11,1966	1	
Out	1,8220	0,3478	0,7352	-9,2089	1	
Nov	0,5274	1,1248	0,4557	-0,9990	1	
Dez	1,8220	0,5679	0,2095	1	1	

Utilizando o Modelo $A = T \times S \times C \times I$ (modelo multiplicativo, onde T representa a Tendência, S a sazonalidade, C a variação cíclica e I a variação Irregular) de decomposição é feita a recomposição, obtendo-se a previsão do Produto H (Tabela 18 e Figura 21).

Tabela 18 - Previsão da demanda do produto H

Produto H	ANO					
	MÊS	2011	2012	2013	2014	2015
Jan			13.5898	4.8670	2.2912	0.2053
Fev	55.5403	29.9806	9.0406	6.6339	0.6910	
Mar	57.6387	22.4210	9.5122	7.9857	1.1369	
Abr	26.7271	15.7577	4.3452	4.2199	0.8746	
Mai	73.9586	20.7135	9.1368	10.4045	2.3324	
Jun	25.6731	8.8516	6.0053	6.7434	1.4610	
Jul	61.4082	13.4363	18.0619	11.4597	4.3010	
Ago	31.4584	12.0143	20.5493	0.2903	5.0163	
Set	48.8173	10.2140	16.6519	1.4162	5.9436	
Out	30.6648	13.9724	7.9185	7.7477	5.4342	
Nov	21.0928	6.6517	2.0488	0.0634	3.0995	
Dez	48.0492	17.0711	3.2752	0.3479	8.9107	

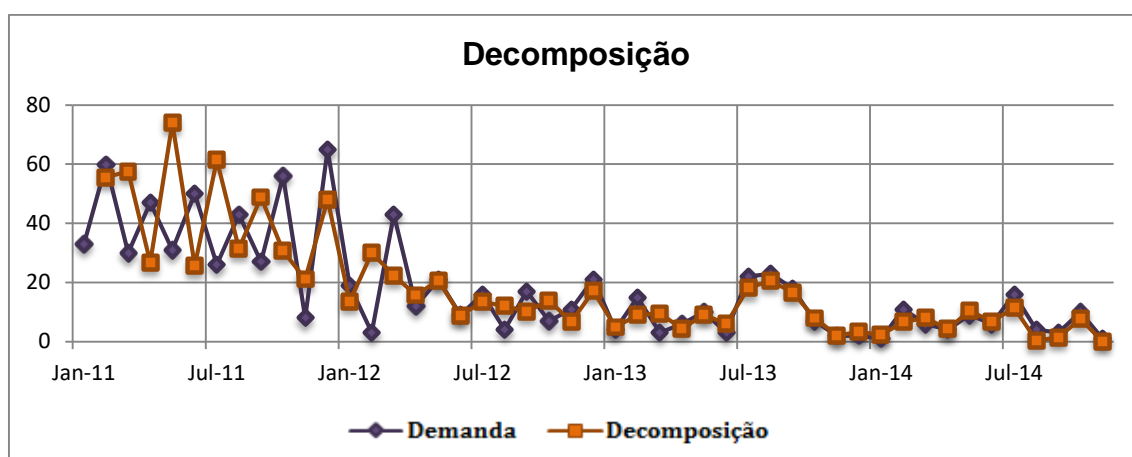


Figura 21 - Previsão da demanda do produto H pelo método de Decomposição

4.3 Avaliação dos métodos de Previsão

Depois de todas as previsões realizadas pelos métodos de séries temporais, é realizada a avaliação de cada uma, de forma a estabelecer se algum dos métodos se adequa melhor e a testar a hipótese deste estudo: Verificar a relevância do modelo SARIMA em relação aos modelos de previsão de suavização exponencial, média móvel e decomposição.

As medidas de avaliação MAPE, MAD, MSE e VIES são aplicadas para todos os métodos para a avaliação em cada um dos produtos estudados. Assim, comparam-se os métodos, permitindo concluir qual método tem o melhor resultado dos parâmetros de avaliação para a maioria dos produtos ou todos.

A Tabela 18, a seguir, compara os métodos Média Móvel para períodos de três meses ($m = 3$), Média Móvel para períodos de seis meses ($m = 6$), Suavização Exponencial, o Método de Decomposição com o modelo multiplicativo e o método SARIMA encontrado nesse estudo, no caso do Produto H o Modelo 4 SARIMA(1,1,1)x(0,1,1)₁₂.

As estatísticas de avaliação da previsão são geradas pelo GRETL, apresentadas na Tabela 19. As medidas de erro do Modelo 4 são comparadas com as de outros métodos de previsão para a mesma série (Produto H), presentes em Justiniano (2015). As medidas de erro para os outros produtos estão apresentadas no Anexo IV.




Observa-se que o modelo de Decomposição apresentou a melhor avaliação com relação às medidas de erro. Ou seja, é o modelo que melhor se ajusta ao conjunto de observações. Porém ter o melhor ajuste não significa produzir as melhores previsões. Até este momento estamos observando os ajustes dos modelos em termo do seu passado, porém é mais interessante para o estudo olhar para o comportamento dos modelos em termo do futuro.

Desta forma o modelo SARIMA, o primeiro apresentado no gráfico da Figura 22, aparenta ter um bom ajuste com relação aos dados reais (dados passados). Mas com relação ao futuro é o único modelo que consegue trabalhar com longos horizontes de tempo e intervalo de confiança para as previsões. Sendo assim, uma vantagem do modelo SARIMA é fornecer uma segurança com relação as variações dos resultados previstos, pois apresenta intervalos de confiança para o futuro. Fornecendo, deste modo, resultados mais consistentes para aplicações com demanda de grandes flutuações e para lidar com possíveis variações futuras da demanda.

Tabela 19 - Estatísticas de avaliação da previsão Produto H

Medida de erro	SARIMA	MM3	MM6	SE	Decomposição
MAPE	164,36	133,78	172,85	151,79	70,71
MSE	89,68	168,47	162,02	155,52	177,82
MAD	7,10	9,07	9,68	10,30	8,39
VIES	-0,91	1,77	3,12	6,28	0,71

MM3 – Média Móvel de ordem 3; MM6 – Média Móvel de ordem 6; SE – Suavização Exponencial
 Fonte: Elaboração própria com base nos dados da pesquisa, gerado pelo GRETL






Figura 22 - Previsões do produto H por diferentes métodos
 Fonte: 1º Gráfico SARIMA (gerado pelo GRET), gráficos 2º e 3º Média Móvel (m=3 e m=6), 4º Suavização Exponencial e 5º Decomposição (JUSTINIANO, 2015)

CAPÍTULO V - CONSIDERAÇÕES FINAIS

Neste estudo aborda-se o assunto da previsão de demanda para as decisões estratégicas e de produção de uma empresa. Este trabalho inicia-se com uma revisão e análise da literatura sobre previsões de demanda por séries temporais. A pesquisa bibliométrica prova a relevância do modelo SARIMA em relação aos modelos de previsão de suavização exponencial, média móvel e decomposição, mostrando que o campo de estudo deste trabalho ainda é uma área em crescimento e com muitas oportunidades para explorar.

Estabelece-se um modelo de previsão de demanda para o caso de uma empresa fabricante de pistões de vibração (setor metalomecânico), que forneceu as séries temporais de demanda. Na literatura, constata-se que as técnicas de modelagem ARIMA (ou SARIMA) são as mais populares para previsão a partir de um conjunto de dados de uma série temporal. Existem três etapas principais na construção de tais modelos (Identificação, Estimativa e Avaliação), das quais a Identificação (que determina os parâmetros do modelo) é a etapa crucial por ser a etapa inicial (não feita de forma correta pode propagar erro por todo o processo de previsão). Para tal, usam-se: a análise de autocorrelação e a análise de correlograma, como método para identificação dos modelos ARIMA (ou SARIMA).

O objetivo deste trabalho é mostrar, através de um estudo de caso que é possível encontrar um método que melhor se adequa (fornecendo um resultado de previsão com erros menores e que melhor trabalha com alta variação). Através de uma comparação com outros métodos de previsão de demanda o método desenvolvido no estudo pode ser avaliado. Desta forma, utilizando a técnica SARIMA desenvolveram-se neste trabalho modelos de previsão para seis produtos da empresa. Para efeitos de apresentação da técnica se usa um dos produtos da empresa (Produto H) como exemplo. O modelo SARIMA resultante para esse produto foi SARIMA $(1,1,1) \times (0,1,1)_{12}$.

Na comparação do modelo SARIMA com modelos obtidos por outras técnicas de previsão de séries temporais, como Média Móvel, Suavização exponencial e Decomposição, ao utilizar medidas conhecidas de erro (MAPE, MSE, MDA e VIES), o modelo SARIMA não resulta o melhor avaliado. Porém isso apenas significa que em

relação aos outros métodos de previsão o SARIMA não apresenta o melhor ajuste em relação aos dados históricos. Mas isso não indica não ter uma boa previsão. Sendo o objetivo prever o comportamento futuro da demanda, o SARIMA é o único que forneceu intervalos de confiança para valores previstos e realiza previsões para um horizonte de tempo mais longo. Utilizando os últimos 6 meses dos dados históricos, para validação do modelo, estes encontram-se no intervalos de confiança gerados pela previsão (com 95% de probabilidade). Fortalecendo, assim, a ideia da confiabilidade do modelo SARIMA em relação aos modelos obtidos pelas outras técnicas.

REFERÊNCIAS BIBLIOGRÁFICAS

ARMSTRONG, J. S. Combining forecasts. In: **Principles of forecasting. A Handbook for Researchers and Practitioners**. Pennsylvania, 2001. p. 417–439. Disponível em: <http://forecastingprinciples.com/paperpdf/Combining.pdf> . Acesso em: 13 Otu. 2015.

ARMSTRONG, J. S.; COLLOPY, F.; ADYA, M. **Principles for Examining Predictive Validity: The Case of Information Systems Spending Forecasts**. Rochester, NY: Social Science Research Network, 21 jul. 2008. Disponível em: <https://papers.ssrn.com/abstract=1164782>>. Acesso em: 22 mar. 2017.

BALAN, S.; VRAT, P.; KUMAR, P. RETRACTED: Information distortion in a supply chain and its mitigation using soft computing approach. **Omega**, v. 37, n. 2, p. 282–299, 1 abr. 2009.

BATISTA, A. **Modelos de séries e redes neurais na previsão de vazão**. Dissertação—Minas Gerais: Universidade Federal de Lavras, 2009.

BENKACHCHA, S. BENHRA, J., EL HASSANI, H. Demand Forecasting in Supply Chain: Comparing Multiple Linear Regression and Artificial Neural Networks Approaches. **International Review on Modelling and Simulations (IREMOS)**, v. 7, n. 2, p. 279–286, 30 abr. 2014.

BORDIGNON, S. et al. Combining day-ahead forecasts for British electricity prices. **Quantitative Analysis of Energy Markets**, v. 35, p. 88–103, 1 jan. 2013.

BOUZADA, M. A. C. **Aprendendo Decomposição Clássica: Tutorial para um Método de Análise de Séries Temporais**. Rio de Janeiro: Universidade Estácio de Sá, 2012.

BOX, G. E. P, JENKINS, M. G., REINSEL, C. G., LJUNG, M. G. **Time Series Analysis: Forecasting and Control**. [s.l.] John Wiley & Sons, 2015.

CALDWELL, J. G. **The Box-Jenkins Forecasting Technique**, 1971. Disponível em: <http://www.foundationwebsite.org/>>

CALMA, A. **Co-Citation Network Analysis Using Gephi**. Slides apresentado em University Of Riverside. Costa Mesa, California, 2015. Disponível em: https://www.academia.edu/20367121/Co-citation_network_analysis_using_Gephi>. Acesso em: 26 jun. 2016

CARBONNEAU, R.; LAFRAMBOISE, K.; VAHIDOV, R. Application of machine learning techniques for supply chain demand forecasting. **European Journal of Operational Research**, v. 184, n. 3, p. 1140–1154, 1 fev. 2008.

CAVALHEIRO, D. Método de previsão de demanda aplicada ao planejamento da produção de indústrias de alimentos. Tese (Mestrado em Engenharia Mecânica) - Universidade Federal de Santa Catarina. Florianópolis, 2003.

CHANG, C.-L.; SRIBOONCHITTA, S.; WIBOONPONGSE, A. Modelling and forecasting tourism from East Asia to Thailand under temporal and spatial aggregation. **Mathematics and Computers in Simulation**, v. 79, n. 5, p. 1730–1744, jan. 2009.

CHOI, T.-M.; YU, Y.; AU, K.-F. A hybrid SARIMA wavelet transform method for sales forecasting. **Decision Support Systems**, v. 51, n. 1, p. 130–140, abr. 2011.

DE ANDRADE, C. H. C. Manual de introdução ao pacote econométrico Gretl. 2013.

CO, H. C.; BOOSARAWONGSE, R. Forecasting Thailand's rice export: Statistical techniques vs. artificial neural networks. **Computers & Industrial Engineering**, v. 53, n. 4, p. 610–627, 1 nov. 2007.

COHEN, M. A. et al. Measuring Imputed Cost in the Semiconductor Equipment Supply Chain. **Management Science**, v. 49, n. 12, p. 1653–1670, 1 dez. 2003.

EHLERS, R. **Análise de Séries Temporais**. [s.l.: s.n.]. Disponível em: <<http://www.icmc.usp.br/ehlers/stemp/stemp.pdf>>.

FAHIMNIA, B.; SARKIS, J.; DAVARZANI, H. Green supply chain management: A review and bibliometric analysis. **International Journal of Production Economics**, v. 162, p. 101–114, abr. 2015.

FÁVERO, L.; DE OLIVEIRA, M. A.; DE ANGELO, C. F. Aplicação de Métodos de Ajustamento Sazonal em Séries Temporais. **Seminários em Administração da Faculdade de Economia, Administração e Contabilidade da USP**, v. 6, 2003.

FERNANDES, F.; ANZANELLO, M. J. Integração de métodos quantitativos e qualitativos para previsão de demanda no setor de autopeças. 2010. **Trabalho de Conclusão de Curso (Curso de Engenharia de Produção - Universidade Federal do Rio Grande do Sul, Porto Alegre, 2010)**.

FERNANDES, J. T. A. **Análise de séries temporais no domínio da frequência: importância do periodograma neste contexto**. PhD Thesis—[s.l.: s.n.].

FERREIRA, P. G. C.; GONDIN, J. L.; MATTOS, D. M. X-13ARIMA-SEATS com R: Um Estudo de Caso para a Produção Industrial Brasileira. Rio de Janeiro: **FGV IBRE**, 2015.

FINDLEY, D. F., MONSELL, C.B., BELL, W.R., OTTO, M.C., CHEU, B. New Capabilities and Methods of the X-12-ARIMA Seasonal-Adjustment Program. **Journal of Business & Economic Statistics**, v. 16, n. 2, p. 127, abr. 1998.

FONSECA, B.P.F.; SAMPAIO, R.B.; FONSECA, M.V.A.; ZICKER, F. Co-authorship network analysis in health research: method and potential use. **Health Research Policy and Systems**, v. 14, n. 1, dez. 2016.

FONSECA, E. N. **Bibliometria: teoria e prática**. São Paulo: EDUSP, 1986.

Forecast Friday Topic: Calendar Effects in Forecasting. Insight Central, 16 dez. 2010. Disponível em: <<https://analysights.wordpress.com/2010/12/16/forecast-friday-topic-calendar-effects-in-forecasting/>>. Acesso em: 23 mar. 2017

GEPHI, O. **Gephi - Makes Graphs Handy.** Org. Disponível em: <www.gephi.org>. Acesso em: 6 jun. 2016.

GIL, A. C. **Métodos e técnicas de pesquisa social.** São Paulo: Atlas, 2008.

GOH, C.; LAW, R. Modeling and forecasting tourism demand for arrivals with stochastic nonstationary seasonality and intervention. **Tourism management**, v. 23, n. 5, p. 499–510, 2002.

GORARD, S. Introducing the mean absolute deviation ‘effect’ size. **International Journal of Research & Method in Education**, v. 38, n. 2, p. 105–114, 3 abr. 2015.

GRAEFE, A.; CUZAN, A. G.; JONES, R. J. ARMSTRONG, J. S, **Combining Forecasts for U.S. Presidential Elections: The Polly Vote**, Principles of Forecasting, USA, 1-25.2012. Disponível em: https://dl.dropboxusercontent.com/u/3662406/Articles/Graefe_et_al_Combining.pdf . Acesso em: 13 Otu. 2015

GUJARATI, D. **“Basic econometrics”**. 4. ed. ed. Boston: McGraw Hill, 2004.

GUTIERREZ, R.S.; SOLISB, A.O.; MUKHOPADHYAY, S. Lumpy demand forecasting using neural networks. **International Journal of Production Economics**, v. 111, n. 2, p: 409 - 420, 2008.

HOANG, D.; KAUR, J.; MENCZER, F. Crowdsourcing Scholarly Data, Proceedings of the WebSci10: Extending the Frontiers of Society On-Line. 2010.

HOPP, W. J.; SPEARMAN, M. L. **Factory physics: foundations of manufacturing management.** 2nd ed ed. Boston: Irwin/McGraw-Hill, 2001.

HUANG, M.; HE, Y.; CEN, H. Predictive analysis on electric-power supply and demand in China. **Renewable Energy**, v. 32, n. 7, p. 1165–1174, 1 jun. 2007.

HYNDMAN, R. J.; KOEHLER, A. B. Another look at measures of forecast accuracy. **International journal of forecasting**, v. 22, n. 4, p. 679–688, 2006.

JUSTINIANO, L. R. **Previsão De Demanda: Estudo De Caso Em Uma Empresa Metalmeccânica Por Série Temporal.** Trabalho de Conclusão de Curso em Engenharia de Produção - Universidade Estadual do Norte Fluminense Darcy Ribeiro, Campos dos Goytacazes - RJ, 2015.

KURBALIJA, V., RADOVANOVIC, M. GELER, Z. IVANOVIC, M. A Framework for Time-Series Analysis. In: DICHEVA, D.; DOCHEV, D. (Eds.). **Artificial Intelligence: Methodology, Systems, and Applications.** Berlin, Heidelberg: Springer Berlin Heidelberg, 2010. v. 6304p. 42–51.

KWIATKOWSKI, D., PHILLIPS, P., SCHMIDT, P., SHIN, Y. Testing the null hypothesis of stationarity against the alternative of a unit root: How sure are we that economic time series have a unit root? **Journal of econometrics**, v. 54, n. 1–3, p. 159–178, 1992.

LANGSRUD, Ø. Seasonal Adjustments: Causes of Revisions. United States Census, 2011. Disponível em: <<https://www.census.gov/srd/www/x13as/>>. Acesso em: 27 mar. 2017

LATORRE, M. DO R. D. DE O.; CARDOSO, M. R. A. Análise de séries temporais em epidemiologia: uma introdução sobre os aspectos metodológicos. **Rev. bras. epidemiol.**, v. 4, n. 3, p. 145–152, nov. 2001.

LEWIS-BECK, M. S.; BRYMAN, A.; LIAO, T. F. (EDS.). **The Sage encyclopedia of social science research methods**. Thousand Oaks, Calif: Sage, 2004.

LEYDESDORFF, L.; AMSTERDAMSKA, O. Dimension of Citation Analysis. **SAGE Journals**, Science, Technology, & Human Values. v. 15, n. 3, p. 305–335, 1 jul. 1990.

MAAROF, M. Z. M.; ISMAIL, Z.; FADZLI, M. Optimization of SARIMA model using genetic algorithm method in forecasting Singapore tourist arrivals to Malaysia. **Applied Mathematical Sciences**, v. 8, p. 8481–8491, 2014.

MANCUZO, F. Análise e previsão de demanda: estudo de caso em uma empresa distribuidora de rolamentos. 2003 TCC (Graduação) - Curso de Engenharia de Produção, Escola de Engenharia, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2003. Disponível em: <<http://www.lume.ufrgs.br/bitstream/handle/10183/2430/000369617.pdf>>. Acesso em: 15 mar. 2015.

MARTIN, L. J.; FREI, J. **Forecasting supply chain components with time series analysis**. 53rd Electronic Components and Technology Conference, 2003. Proceedings. **Anais...** In: 53RD ELECTRONIC COMPONENTS AND TECHNOLOGY CONFERENCE, 2003. PROCEEDINGS. maio 2003

MARTYN, J. Bibliographic coupling. **Journal of Documentation**, v. 20, 1964.

MENEZES, L. Gerenciamento de capacidade e demanda em operações de serviços: um estudo exploratório em uma central de atendimento ao cliente. In: ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO, 30., 2007, São Carlos. Anais. São Carlos: Enegep, 2010, 12 p.

MENTZER, J. T.; MOON, M. A. **Sales Forecasting Management: A Demand Management Approach**. [s.l.] SAGE, 2004.

MODENESI, A. DE M. **Convenção e rigidez na política monetária: uma estimativa da função de reação do BCB-2000-2007**. [s.l.] Texto para Discussão, Instituto de Pesquisa Econômica Aplicada (IPEA), 2008. Disponível em: <<https://www.econstor.eu/handle/10419/91393>>. Acesso em: 23 jun. 2017.

MORETTIN, P. A.; TOLOI, C. M. C. **Análise de Séries Temporais**. [s.l.] ABE- Projeto Fisher e Editora Edgard Blucher, 2004.

MORETTIN, P.; TOLOI, C. **Análise de Séries Temporais**. 2. ed. [s.l.] Editora Edgard Blucher, 2006.

NENNI, M. E.; GIUSTINIANO, L.; PIROLO, L. Demand Forecasting in the Fashion Industry: A Review. **International Journal of Engineering Business Management**, USA, v. 5, n. 37, p.1-6, jul. 2013. Disponível em: <<http://cdn.intechopen.com/pdfs-wm/45565.pdf>>. Acesso em: 14 mar. 2015.

ÖNDER, E.; KUZU, S. Forecasting air traffic volumes using smoothing techniques. **Journal of Aeronautics and Space Technologies (Havacilik ve Uzay Teknolojileri Dergisi)**, v. 7, n. 1, p. 1–21, 1 jan. 2014.

OTU, A., GEORGE, A., JUDE, O., HOPE, M., ANDREW, I. Application of Sarima Models in Modelling and Forecasting Nigeria's Inflation Rates. **American Journal of Applied Mathematics and Statistics**, v. 2, n. 1, p. 16–28, 3 jan. 2014.

PELLEGRINI, F. R.; FOGLIATTO, F. S. Passos para implantação de sistemas de previsão de demanda: técnicas e estudo de caso. **Production**, v. 11, n. 1, p. 43–64, jun. 2001.

PERMANASARI, A. E.; HIDAYAH, I.; BUSTONI, I. A. **SARIMA (Seasonal ARIMA) implementation on time series to forecast the number of Malaria incidence**. IEEE, out. 2013 Disponível em: <<http://ieeexplore.ieee.org/document/6676239/>>. Acesso em: 22 mar. 2017

PINDYCK, R. S.; RUBINFELD, D. L. **Econometria: modelos & previsões**. [s.l.] Elsevier, 2004.

PROTO, L. O. Z.; MESQUITA, M. A. DE. Previsão de demanda para planejamento da capacidade de empresa do setor cimenteiro. XXIII **Encontro Nacional de Engenharia de Produção**, Ouro Preto, Mg, p.1-9, 24 out. 2003. Anual. Disponível em: <http://www.abepro.org.br/biblioteca/ENEGEP2003_TR0701_1038.pdf>. Acesso em: 14 mar. 2015..

RAVINDRAN, A.; WARSING, D. P. Supply chain engineering: models and applications. **CRC Press**, 2017.

SHUKLA, M.; JHARKHARIA, S. ARIMA models to forecast demand in fresh supply chains. *International Journal of Operational Research*, v. 11, n. 1, p. 1, 2011. TSENG, F.-M.; YU, H.-C.; TZENG, G.-H. Combining neural network model with seasonal time series ARIMA model. **Technological Forecasting and Social Change**, v. 69, n. 1, p. 71–87, 2002.

VENTURA, M. M. O estudo de caso como modalidade de pesquisa. **Rev. SOCERJ**, Pedagogia Médica, Rio de Janeiro, v. 5, n. 20, p.383-386, out. 2007. Disponível em: <http://www.polo.unisc.br/portal/upload/com_arquivo/o_estudo_de_caso_como_modalidade_de_pesquisa.pdf>. Acesso em: 14 mar. 2015..

WALLSTRÖM, P. **Evaluation of forecasting techniques and forecast errors: with focus on intermittent demand**. Luleå: Luleå University of Technology, 2009. Disponível em: <https://pure.ltu.se/ws/files/2787901/Peter_Wallstrom_LIC2009.pdf>. Acesso em: 09 jul. 2015.

WANG, C.; GROZEV, G.; SEO, S. Decomposition and statistical analysis for regional electricity demand forecasting. **Energy**, v. 41, n. 1, p. 313–325, maio 2012.

WARREN LIAO, T.; CHANG, P. C. Impacts of forecast, inventory policy, and lead time on supply chain inventory—A numerical study. **Supply Chain Forecasting Systems**, v. 128, n. 2, p. 527–537, 1 dez. 2010.

WILLEMMAIN, T.R.; SMART, C.N.; SCHWARZ H.F. A new approach to forecasting intermittent demand for service parts inventories. **International Journal of Forecasting**, v. 20, n. 3, p. 375 - 387, 2004.

WITT, S. F.; WITT, C. A. Forecasting tourism demand: A review of empirical research. **International Journal of forecasting**, v. 11, n. 3, p. 447–475, 1995.

WIWANITKIT, V. SARIMA for predicting the cases numbers of dengue. **Revista da Sociedade Brasileira de Medicina Tropical**, v. 45, n. 1, p. 140–140, 2012.

WU, Q. Product demand forecasts using wavelet kernel support vector machine and particle swarm optimization in manufacture system. **Journal of Computational and Applied Mathematics**, v. 233, n. 10, p. 2481–2491, 15 mar. 2010.

ZARANDI, M.H.F.; POURAKBAR, M.; TURKSEN, I.B. A Fuzzy agent-based model for reduction of bullwhip effect in supply chain systems. **Expert Systems with Applications**, v.34, n. 3, p: 1680 - 1691, 2008.

ZHAO, X.; XIE, J.; LEUNG, J. The impact of forecasting model selection on the value of information sharing in a supply chain. **European Journal of Operational Research**, v. 142, n. 2, p. 321–344, 16 out. 2002.

ZHAO, X.; XIE, J.; WEI, J. C. The Impact of Forecast Errors on Early Order Commitment in a Supply Chain*. **Decision Sciences**, v. 33, n. 2, p. 251–280, 1 mar. 2002.

ANEXO I

Demandas fornecidas pela empresa norte americana para os seis produtos da linha de pistões de vibração industrial.

Tabela 20 - Demanda do produto G.

Produto G	Ano			
	Mês	2011	2012	2013
Jan	19	8	8	20
Fev	11	14	18	10
Mar	18	8	49	25
Abr	20	18	7	15
Mai	4	9	6	26
Jun	13	39	12	20
Jul	19	16	11	24
Ags	17	12	25	20
Set	12	3	16	23
Out	12	3	19	25
Nov	7	19	15	17
Dez	12	5	12	

Tabela 21 – Demanda do produto H.

Produto H	Ano			
	Mês	2011	2012	2013
Jan	33	19	4	1
Fev	60	3	15	11
Mar	30	43	3	6
Abr	47	12	6	4
Mai	31	21	10	9
Jun	50	9	3	6
Jul	26	16	22	16
Ags	43	4	23	4
Set	27	17	18	3
Out	56	7	7	10
Nov	8	11	2	1
Dez	65		2	

Tabela 22 – Demanda do produto I.

Produto I	Ano			
Mês	2011	2012	2013	2014
Jan	19	5	16	20
Fev	31	37	19	12
Mar	22	20	62	41
Abr	18	25	20	15
Mai	7	10	11	26
Jun	34	10	7	21
Jul	11	18	23	19
Ags	19	24	15	24
Set	36	15	25	32
Out	23	17	11	51
Nov	13	18	26	23
Dez	18	31	28	

Tabela 23 – Demanda do produto J.

Produto J	Ano			
Mês	2011	2012	2013	2014
Jan	23	27	13	33
Fev	9	15	5	19
Mar	28	27	26	26
Abr	10	28	13	12
Mai	16	18	24	15
Jun	14	21	29	26
Jul	17	25	16	37
Ags	10	16	24	27
Set	17	31	24	28
Out	10	10	37	23
Nov	22	19	39	13
Dez	9	26	25	

Tabela 24 – Demanda do produto K.

Produto K	Ano			
Mês	2011	2012	2013	2014
Jan	38	34	19	36
Fev	27	29	24	61
Mar	28	52	36	49
Abr	34	37	33	67
Mai	34	41	39	44
Jun	45	48	59	42
Jul	17	27	49	68
Ags	50	50	31	52
Set	50	24	73	46
Out	40	62	42	54
Nov	20	47	35	48
Dez	23	14	42	

Tabela 25 – Demanda do produto L.

Produto L	Ano			
Mês	2011	2012	2013	2014
Jan	4	2	1	1
Fev	2	2		10
Mar	12	12	6	5
Abr	18	6	4	7
Mai		3	3	5
Jun	6	2	6	8
Jul	5	5	7	13
Ags	7	2	3	4
Set	8	3	7	5
Out		2	5	3
Nov	2	9	11	8
Dez	3	17	5	

ANEXO II

Relação entre a demanda real e os métodos de previsão de demanda Média Móvel, Suavização Exponencial e Decomposição.

Produto G




Figura 23 - Previsões do produto G por Média Móvel (m=3)
Fonte: Elaboração própria com base nos dados da pesquisa




Figura 24 - Previsões do produto G por Média Móvel (m=6)
Fonte: Elaboração própria com base nos dados da pesquisa

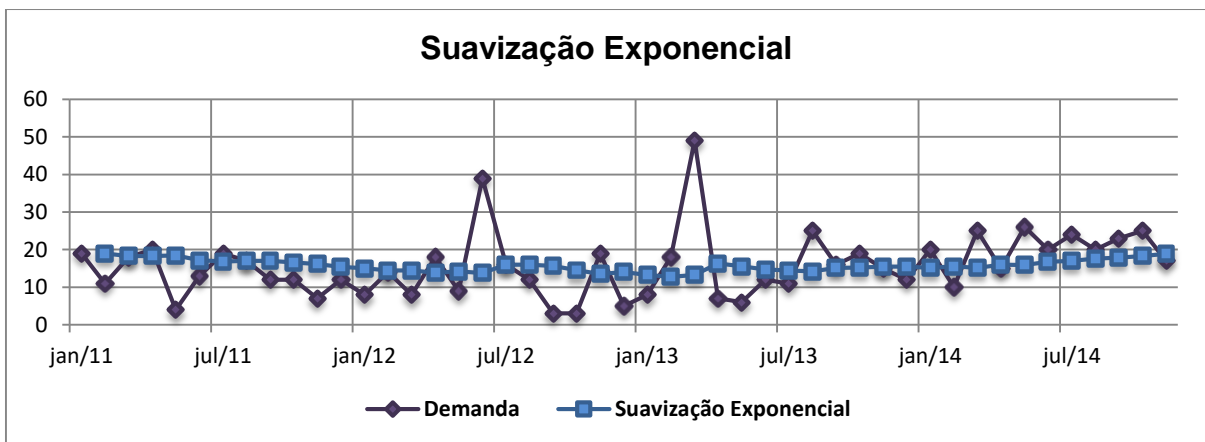


Figura 25 - Previsões do produto G por Suavização Exponencial ($\alpha = 0,0869$)
Fonte: Elaboração própria com base nos dados da pesquisa




Figura 26 - Previsões do produto G por Decomposição
 Fonte: Elaboração própria com base nos dados da pesquisa

Produto H




Figura 27 - Previsões do produto H por Média Móvel (m=3)
 Fonte: Elaboração própria com base nos dados da pesquisa




Figura 28 - Previsões do produto H por Média Móvel (m=6)
 Fonte: Elaboração própria com base nos dados da pesquisa




Figura 29 - Previsões do produto H por Suavização Exponencial ($\alpha = 0,2405$)
 Fonte: Elaboração própria com base nos dados da pesquisa




Figura 30 - Previsões do produto H por Decomposição
 Fonte: Elaboração própria com base nos dados da pesquisa

Produto I




Figura 31 - Previsões do produto I por Média Móvel ($m=3$)
 Fonte: Elaboração própria com base nos dados da pesquisa




Figura 32 - Previsões do produto I por Média Móvel (m=6)
 Fonte: Elaboração própria com base nos dados da pesquisa




Figura 33 - Previsões do produto I por Suavização Exponencial ($\alpha = 0,0352$)
 Fonte: Elaboração própria com base nos dados da pesquisa




Figura 34 - Previsões do produto I por Decomposição
 Fonte: Elaboração própria com base nos dados da pesquisa

Produto J




Figura 35 - Previsões do produto J por Média Móvel (m=3)
Fonte: Elaboração própria com base nos dados da pesquisa




Figura 36 - Previsões do produto J por Média Móvel (m=6)
Fonte: Elaboração própria com base nos dados da pesquisa




Figura 37 - Previsões do produto J por Suavização Exponencial ($\alpha = 0,1513$)
Fonte: Elaboração própria com base nos dados da pesquisa




Figura 38 - Previsões do produto J por Decomposição
 Fonte: Elaboração própria com base nos dados da pesquisa

Produto K




Figura 39 - Previsões do produto K por Média Móvel (m=3)
 Fonte: Elaboração própria com base nos dados da pesquisa




Figura 40 - Previsões do produto K por Média Móvel (m=6)
 Fonte: Elaboração própria com base nos dados da pesquisa




Figura 41 - Previsões do produto K por Suavização Exponencial ($\alpha = 0,1243$)
 Fonte: Elaboração própria com base nos dados da pesquisa




Figura 42 - Previsões do produto K por Decomposição
 Fonte: Elaboração própria com base nos dados da pesquisa

Produto L




Figura 43 - Previsões do produto L por Média Móvel ($m=3$)
 Fonte: Elaboração própria com base nos dados da pesquisa




Figura 44 - Previsões do produto L por Média Móvel (m=6)
 Fonte: Elaboração própria com base nos dados da pesquisa




Figura 45 - Previsões do produto L por Suavização Exponencial ($\alpha = 0,0410$)
 Fonte: Elaboração própria com base nos dados da pesquisa




Figura 46 - Previsões do produto L por Decomposição
 Fonte: Elaboração própria com base nos dados da pesquisa

ANEXO III

Resultado da previsão de demanda pelo modelo SARIMA.

Produto G




Figura 47 - Previsão do Produto G com o modelo SARIMA(2,0,2)x(0,1,1)₁₂

Fonte: Elaboração própria com base nos dados da pesquisa

Tabela 26 - Previsão do Produto G com o modelo SARIMA(2,0,2)x(0,1,1)₁₂

Para intervalos de confiança de 95%, $z(0,025) = 1,96$					
Obsevações (meses)	Yt	Previsão	Erro Padrão	Intervalo a 95%	
				Mínimo	Máximo
01/2014	20,00	14,27			
02/2014	10,00	10,23			
03/2014	25,00	23,76			
04/2014	15,00	16,14			
05/2014	26,00	15,90			
06/2014	20,00	22,28			
07/2014	24,00	21,29			
08/2014	20,00	21,91			
09/2014	23,00	18,39			
10/2014	25,00	17,25			
11/2014	17,00	13,12			
12/2014		7,06	6,605	-5,89	20,00
01/2015		15,57	7,388	-1,09	30,05
02/2015		18,78	7,787	-3,52	34,04
03/2015		33,23	7,838	-17,87	48,60
04/2015		24,17	7,858	-8,77	39,57
05/2015		19,74	7,978	-4,11	35,38

Fonte: Elaboração própria com base nos dados da pesquisa

Produto H




Figura 48 - Previsão do Produto H com o modelo SARIMA(1,1,1)x(0,1,1)₁₂
 Fonte: Elaboração própria com base nos dados da pesquisa

Tabela 27 - Previsão do Produto H com o modelo SARIMA(1,1,1)x(0,1,1)₁₂

Para intervalos de confiança de 95%, $z(0,025) = 1,96$					
Obsevações (meses)	Yt	Previsão	Erro Padrão	Intervalo a 95%	
				Minimo	Maximo
01/2014	1,00	6,52			
02/2014	11,00	3,09			
03/2014	6,00	4,07			
04/2014	4,00	4,69			
05/2014	9,00	5,92			
06/2014	6,00	5,22			
07/2014	16,00	11,22			
08/2014	4,00	8,92			
09/2014	3,00	12,52			
10/2014	10,00	14,54			
11/2014	1,00	- 1,38			
12/2014		12,59	11,339	-9,63	34,82
01/2015		2,23	11,705	-20,71	25,17
02/2015		6,41	12,615	-18,31	31,14
03/2015		9,35	12,631	-15,40	34,11
04/2015		6,25	12,940	-19,11	31,62
05/2015		9,33	13,045	-16,24	34,90

Fonte: Elaboração própria com base nos dados da pesquisa

Produto I




Figura 49 - Previsão do Produto I com o modelo SARIMA(3,2,1)x(0,1,1)₁₂
 Fonte: Elaboração própria com base nos dados da pesquisa

Tabela 28 - Previsão do Produto I com o modelo SARIMA(3,2,1)x(0,1,1)₁₂

Para intervalos de confiança de 95%, $z(0,025) = 1,96$					
Obsevações (meses)	Yt	Previsão	Erro Padrão	Intervalo a 95%	
				Minimo	Maximo
01/2014	20,00	14,79			
02/2014	12,00	26,34			
03/2014	41,00	50,48			
04/2014	15,00	23,03			
05/2014	26,00	13,76			
06/2014	21,00	11,41			
07/2014	19,00	26,15			
08/2014	24,00	24,51			
09/2014	32,00	38,25			
10/2014	51,00	27,04			
11/2014	23,00	29,32			
12/2014		44,56	12,092	-20,86	68,26
01/2015		32,24	12,108	-8,51	55,97
02/2015		50,79	12,529	-26,23	75,35
03/2015		59,64	12,819	-34,52	84,77
04/2015		47,51	14,611	-18,87	76,15
05/2015		42,95	14,749	-14,04	71,85

Fonte: Elaboração própria com base nos dados da pesquisa

Produto J




Figura 50 - Previsão do Produto J com o modelo SARIMA(1,2,1)x(1,1,1)₁₂
 Fonte: Elaboração própria com base nos dados da pesquisa

Tabela 29 - Previsão do Produto J com o modelo SARIMA(1,2,1)x(1,1,1)₁₂

Para intervalos de confiança de 95%, $z(0,025) = 1,96$					
Obsevações (meses)	Yt	Previsão	Erro Padrão	Intervalo a 95%	
				Minimo	Maximo
01/2014	33,00	34,38			
02/2014	19,00	20,96			
03/2014	26,00	34,85			
04/2014	12,00	25,31			
05/2014	15,00	11,93			
06/2014	26,00	13,45			
07/2014	37,00	22,32			
08/2014	27,00	24,87			
09/2014	28,00	38,35			
10/2014	23,00	16,98			
11/2014	13,00	24,67			
12/2014		19,26	8,808	-2,00	36,53
01/2015		8,30	9,990	-11,27	27,88
02/2015		- 2,21	11,982	-25,70	21,27
03/2015		11,47	13,283	-14,56	37,51
04/2015		- 1,71	14,634	-30,39	26,98
05/2015		0,31	15,798	-30,65	31,28

Fonte: Elaboração própria com base nos dados da pesquisa

Produto K




Figura 51 - Previsão do Produto K com o modelo SARIMA(6,1,1)x(0,1,0)₁₂
 Fonte: Elaboração própria com base nos dados da pesquisa

Tabela 30 - Previsão do Produto K com o modelo SARIMA(6,1,1)x(0,1,0)₁₂

Para intervalos de confiança de 95%, $z(0,025) = 1,96$					
Obsevações (meses)	Yt	Previsão	Erro Padrão	Intervalo a 95%	
				Mínimo	Máximo
01/2014	36,00	40,99			
02/2014	61,00	52,71			
03/2014	49,00	42,34			
04/2014	67,00	47,73			
05/2014	44,00	52,06			
06/2014	42,00	46,19			
07/2014	68,00	52,97			
08/2014	52,00	44,03			
09/2014	46,00	50,67			
10/2014	54,00	46,79			
11/2014	48,00	49,38			
12/2014		62,00	11,708	-39,05	84,95
01/2015		54,95	11,708	-32,01	77,90
02/2015		71,11	11,725	-48,13	94,09
03/2015		73,95	11,725	-50,97	96,93
04/2015		82,60	11,835	-59,40	105,79
05/2015		59,80	11,861	-36,55	83,04

Fonte: Elaboração própria com base nos dados da pesquisa

Produto L




Figura 52 - Previsão do Produto L com o modelo SARIMA(0,1,1)x(0,1,1)₁₂
 Fonte: Elaboração própria com base nos dados da pesquisa

Tabela 31 - Previsão do Produto L com o modelo SARIMA(0,1,1)x(0,1,1)₁₂

Para intervalos de confiança de 95%, $z(0,025) = 1,96$					
Obsevações (meses)	Yt	Previsão	Erro Padrão	Intervalo a 95%	
				Minimo	Maximo
01/2014	1,00	1,65			
02/2014	10,00	1,64			
03/2014	5,00	9,20			
04/2014	7,00	8,02			
05/2014	5,00	5,00			
06/2014	8,00	5,84			
07/2014	13,00	7,32			
08/2014	4,00	5,01			
09/2014	5,00	7,71			
10/2014	3,00	6,66			
11/2014	8,00	10,68			
12/2014		10,59	4,391	-1,99	19,20
01/2015		3,88	4,391	-4,72	12,49
02/2015		8,16	4,391	-0,44	16,77
03/2015		10,09	4,391	-1,48	18,69
04/2015		10,52	4,391	-1,91	19,12
05/2015		8,11	4,391	-0,49	16,72

Fonte: Elaboração própria com base nos dados da pesquisa

ANEXO IV

Produto G

Tabela 32 - Estatísticas de avaliação da previsão Produto G

Medida de erro	SARIMA	MM3	MM6	SE	Decomposição
MAPE	170,38	72,76	62,99	64,94	22,64
MSE	92,89	110,36	95,08	79,10	39,26
MAD	7,30	7,08	6,58	5,74	4,78
VIES	-0,17	-0,43	-0,71	-0,48	0,23

MM3 – Média Móvel de ordem 3; MM6 – Média Móvel de ordem 6; SE – Suavização Exponencial
Fonte: Elaboração própria com base nos dados da pesquisa, gerado pelo GRETl

Produto I

Tabela 33 - Estatísticas de avaliação da previsão Produto I

Medida de erro	SARIMA	MM3	MM6	SE	Decomposição
MAPE	48,32	62,11	49,37	44,36	16,72
MSE	109,57	175,28	143,47	123,83	85,01
MAD	8,85	9,31	8,50	6,86	7,08
VIES	0,013	-0,52	-0,79	-1,68	0,17

MM3 – Média Móvel de ordem 3; MM6 – Média Móvel de ordem 6; SE – Suavização Exponencial
Fonte: Elaboração própria com base nos dados da pesquisa, gerado pelo GRETl

Produto J

Tabela 34 - Estatísticas de avaliação da previsão Produto J

Medida de erro	SARIMA	MM3	MM6	SE	Decomposição
MAPE	27,90	42,36	41,49	44,99	45,32
MSE	58,41	71,06	70,68	63,52	37,38
MAD	5,81	6,60	6,95	6,10	4,90
VIES	-4,78e-007	-0,22	-0,64	-0,68	0,45

MM3 – Média Móvel de ordem 3; MM6 – Média Móvel de ordem 6; SE – Suavização Exponencial
Fonte: Elaboração própria com base nos dados da pesquisa, gerado pelo GRETl

Produto K

Tabela 35 - Estatísticas de avaliação da previsão Produto K

Medida de erro	SARIMA	MM3	MM6	SE	Decomposição
MAPE	28,06	35,71	35,18	30,22	45,51
MSE	135,81	214,78	214,12	173,81	115,53
MAD	9,44	11,40	12,01	9,65	8,17
VIES	0,009	-0,46	-1,32	-2,24	0,46

MM3 – Média Móvel de ordem 3; MM6 – Média Móvel de ordem 6; SE – Suavização Exponencial
Fonte: Elaboração própria com base nos dados da pesquisa, gerado pelo GRETl

Produto L

Tabela 36 - Estatísticas de avaliação da previsão Produto L

Medida de erro	SARIMA	MM3	MM6	SE	Decomposição
MAPE	62,42	89,63	82,39	67,75	8,43
MSE	16,54	21,20	15,12	14,98	5,10
MAD	3,13	3,04	2,99	2,27	1,55
VIES	0,015	0,08	0,19	-0,42	0,08

MM3 – Média Móvel de ordem 3; MM6 – Média Móvel de ordem 6; SE – Suavização Exponencial
Fonte: Elaboração própria com base nos dados da pesquisa, gerado pelo GRETl