

UNIVERSIDADE FEDERAL DE SANTA MARIA
CENTRO DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA DE PRODUÇÃO E SISTEMAS
CURSO DE GRADUAÇÃO EM ENGENHARIA DE PRODUÇÃO

Arthur Carlos Linck

**MODELO DE PREVISÃO DE DEMANDA PARA UM PRODUTO DO
ALMOXARIFADO CENTRAL DA UNIVERSIDADE FEDERAL DE
SANTA MARIA**

Santa Maria, RS
2019

Arthur Carlos Linck

**MODELO DE PREVISÃO DE DEMANDA PARA UM PRODUTO DO
ALMOXARIFADO CENTRAL DA UNIVERSIDADE FEDERAL DE SANTA MARIA**

Projeto de pesquisa do Trabalho de Conclusão de Curso apresentado ao curso de Graduação em Engenharia de Produção da Universidade Federal de Santa Maria (UFSM, RS), como requisito parcial para obtenção do título de **Bacharel em Engenharia de Produção.**

Orientador: Prof. Dr. Denis Rasquin Rabenschlag

Santa Maria, RS
2019

MODELO DE PREVISÃO DE DEMANDA PARA UM PRODUTO DO ALMOXARIFADO CENTRAL DA UNIVERSIDADE FEDERAL DE SANTA MARIA

FORECASTING DEMAND MODEL FOR A PRODUCT OF THE CENTRAL WAREHOUSE OF UNIVERSIDADE FEDERAL DE SANTA MARIA

Arthur Carlos Linck¹, Denis Rasquin Rabenschlag²

RESUMO

Instituições públicas de ensino superior mantêm estoques de produtos de consumo básico para uso diário. Geralmente, os gestores de almoxarifados encontram dificuldades para definir a quantidade mais adequada a ser adquirida de cada produto. Nesse contexto, uma técnica que pode auxiliar os gestores na gestão dos almoxarifados em instituições de ensino públicas é a previsão de demanda. Assim, esse trabalho busca responder como um modelo de previsão de demanda pode auxiliar os gestores do almoxarifado de uma instituição de ensino superior pública a melhorarem a eficácia do processo de compras. Para isso, uma análise da demanda de um produto de consumo básico foi realizada e dois modelos de previsão elaborados utilizando técnicas de análise de séries temporais. O modelo ARIMA(3,0,2) obteve melhores resultados nos critérios de comparação e mostrou-se adequado para fins de previsão. Assim, valores futuros da demanda do produto foram previstos para serem utilizados pelos gestores do almoxarifado.

Palavras-chave: Gestão Pública. Previsão de Demanda. Séries Temporais. ARIMA.

ABSTRACT

Higher public education institutions keep stocks of basic consumption products for daily basis use. Usually, the managers of the warehouses find it difficult to choose the right amount to be acquired of each product. In these context, one technique that can be helpful to the managers in managing the warehouses of public institutions is demand forecasting. Therefore, this paper seek to answer how a demand forecasting model can help the managers of a higher public education institution improve the efficiency of the purchase process. To do that, a demand analysis for a product of basic consumption is done and two models are proposed based on time series analysis. The model ARIMA(3,0,2) had the best results in the criteria used to do the comparison and it is appropriate to be used to forecast. Thereby, future values of the demand were forecasted to be used by the managers of the warehouse.

Keywords: Public Management. Demand Forecasting. Time Series. ARIMA.

¹ Graduando, autor: graduando do Curso de Graduação em Engenharia de Produção pela Universidade Federal de Santa Maria – UFSM.

² Orientador, professor do Departamento de Engenharia de Produção e Sistemas da Universidade Federal de Santa Maria – UFSM.

1 INTRODUÇÃO

Instituições públicas de ensino superior mantêm estoques de recursos materiais para seu funcionamento. A aquisição desses materiais envolve um processo burocrático, uma vez que o dinheiro público é o financiador dessas instituições, dificultando a realização de compras, que muitas vezes acabam sendo ineficientes, resultando em estoques elevados ou na falta desses produtos.

Mota e Cancio (2004) contextualizam o problema dos estoques em instituições de administração pública criticando o grande volume financeiro destinado para essa área. Segundo Fenili (2016), “uma conceituação de estoque que se aproxima à realidade do setor público é que estoque é o somatório de materiais armazenados em uma organização, que permanecem reservados para uso oportuno”. Existem vários motivos para se manter estoques, para Slack et al. (2018) um deles é a garantia contra incertezas na demanda. Porém, os custos associados a manutenção de estoques devem ser considerados na administração da organização. Ballou (2006) diz que esse custo pode representar de 20 a 40% do valor do estoque por ano.

Ballou (2001) afirma que “existem muitas variáveis relacionadas a função compras, como por exemplo fornecedores, prazos, preços e mudanças na demanda”. Uma vez identificada a necessidade de aquisição de algum produto, o processo de compra deve ser realizado da melhor maneira possível, com o objetivo de obter a mercadoria na quantidade necessária, com qualidade e pagando um preço razoavelmente baixo (POOLER, V.; POOLER, D.; FARNEY, 2004).

Visando a melhoria na destinação dos recursos públicos, os gestores das instituições poderiam usufruir de técnicas e métodos adequados para a tomada de decisões. Anjos e Guimarães (2017), realizaram um estudo sobre os estoques de 13 universidades federais e concluíram que há necessidade de um sistema de planejamento do setor de armazenagem juntamente com o setor de compras para subsidiar a tomada de decisões no planejamento de materiais para instituições.

Uma ferramenta que contribui para melhorar a eficácia da gestão de compras é a previsão de demanda. É muito importante entender a interação entre a previsão de demanda e o controle de estoque, uma vez que a performance do sistema de estoque é determinada pelos dois componentes em conjunto (ALI; BOYLAN; SYNTETOS, 2012). Existem diversos métodos para a utilização dessa ferramenta e segundo Petropoulos, Wang e Disney (2019), “o objetivo de cada um não é apenas minimizar o erro, mas também maximizar a utilidade dessas previsões”.

Consta no art. 15º da Lei nº 8.666/1993 que para instituições públicas “nas compras deverão ser observadas a definição das unidades e das quantidades a serem adquiridas em função do consumo e utilização prováveis, cuja estimativa será obtida, sempre que possível, mediante adequadas técnicas quantitativas de estimação” (BRASIL, 1993). Assim, um modelo de previsão de demanda tem potencial para auxiliar os gestores públicos na definição dessas quantidades e contribui com a definição de Fenili (2016) para gestão de materiais, que diz “no contexto da administração pública, o objetivo principal da gestão de materiais é maximizar o uso dos recursos na organização, ou seja, evitar desperdícios.”

Dentre os diversos métodos quantitativos para previsão de demanda existentes, os modelos de séries temporais são muito utilizados pois consideram as propriedades estatísticas dos dados históricos da demanda para especificar os parâmetros utilizados (MONTGOMERY et al., 2008). O modelo ARIMA (*Auto Regressive Integrated Moving Average*) tem sido extensivamente estudado por pesquisadores devido as suas propriedades (BABAI et al., 2013). Como exemplo de aplicação, Jacobs e Costa (2011) utilizam o modelo ARIMA para realizar a previsão de demanda de um produto de uma empresa do ramo alimentício.

A partir dessa contextualização, a seguinte questão problema deverá ser respondida: como a elaboração de um modelo de previsão de demanda para materiais de consumo da Universidade Federal de Santa Maria (UFSM) pode auxiliar os gestores do almoxarifado a melhorarem a eficácia do processo de compras?

Na busca da resposta da questão problema, o objetivo geral da pesquisa é desenvolver um modelo de previsão de demanda para um produto de consumo básico na UFSM. Com base nisso, os objetivos específicos são: a) definir um produto para realizar a previsão de demanda; b) analisar e compreender as características da demanda do produto escolhido; c) definir o método de previsão a ser utilizado com base nas características da demanda e d) utilizar o modelo para prever valores futuros da demanda.

2 REFERENCIAL TEÓRICO

O referencial teórico dessa pesquisa busca explicar a gestão de compras, o processo de compras governamentais e os métodos de previsão de demanda de séries temporais.

2.1 GESTÃO DE COMPRAS

A função compras tem a finalidade de suprir as necessidades de materiais, planejá-las e satisfazê-las, no momento e na quantidade correta (DIAS, 2012). Para Fenili (2016), existem três atributos essenciais em uma gestão de compras eficiente: preço econômico, qualidade e celeridade. Os órgãos públicos encontram dificuldades nos aspectos da qualidade e da celeridade, uma vez que no sistema de compras atual é vedada a escolha de uma marca específica e o processo é muito demorado, órgãos públicos de referência na área de compras levam cerca de 45 a 60 dias para realizar uma aquisição.

Dias (2012) afirma que “a necessidade de comprar cada vez melhor é enfatizada por todos os empresários juntamente com as necessidades de estocar em níveis adequados.” Isso não deve ser diferente para o setor público, uma vez que os recursos utilizados nesse tipo de administração são de toda a população.

Para Chiavenato (2014), “o órgão de compras é importante porque assegura o abastecimento normal das necessidades de insumos e materiais da empresa, garantindo o seu funcionamento regular.” Assim, o uso de modelos para auxílio na gestão de compras deve ser considerado nas instituições, uma vez que são uma representação matemática de um sistema para tomada de decisão (MATOPOULOS; BELL; AKTAS, 2016).

2.2 COMPRAS GOVERNAMENTAIS

O sistema de compras da administração pública é baseado na Lei nº 8.666/1993, que estabelece normas gerais sobre licitações e contratos administrativos pertinentes a obras, serviços e compras no âmbito dos Poderes da União, dos Estados, do Distrito Federal e dos Municípios (BRASIL, 1993). O art. 15º dessa lei introduz o sistema de registro de preços, que é regulamentado pelo Decreto de Lei nº 7.892/2013 que permite ao gestor orçar todos os produtos necessários, sem a obrigação de adquiri-los (BRASIL, 2013). Porém, todo o trâmite burocrático de efetuar a compra até o recebimento do material pode levar muito tempo.

Além disso, encontra-se em vigor a Lei nº 10.520/02 que institui a modalidade de licitação para a aquisição de bens e serviços comuns denominada pregão (BRASIL, 2002). Assim, o pregão na forma eletrônica é regulamentado pelo Decreto Federal nº 5.450/2005, no qual, através do art. 4º consta que “a modalidade de pregão, na forma eletrônica, será preferencialmente utilizada em licitações para a aquisição de bens e serviços comuns, sendo que estes procedimentos são realizados através do portal de compras governamentais (BRASIL, 2005).

Os responsáveis pela determinação da quantidade no lote de compra são os supervisores dos almoxarifados das instituições, os quais devem ter o cuidado de elaborar as instruções legais para o procedimento de compras. Porém, a maioria das instituições públicas não conta com uma análise de demanda, o que dificulta a distribuição eficiente dos recursos públicos utilizados para as aquisições de materiais.

2.2.1 Compras na UFSM

Segundo Rosa e Löbler (2014), “as aquisições de material de consumo, material permanente e a contratação de obras e serviços em geral devem ser realizadas através de duas modalidades: Licitação ou Dispensa de Licitação”. Além disso, o processo envolve as relações com os fornecedores da instituição. Na UFSM, o almoxarifado central e o Departamento de Materiais e Patrimônio (DEMAPA) são os responsáveis por conduzir os processos de compras da instituição. A seguir será apresentado o processo de licitação, uma vez que as compras planejadas são realizadas através dele.

2.2.1.1 Processo de Licitação

Conforme o Art. 3º da Lei nº 8.666/1993,

A licitação destina-se a garantir a observância do princípio constitucional da isonomia, a seleção da proposta mais vantajosa para a administração e a promoção do desenvolvimento nacional sustentável e será processada e julgada em estrita conformidade com os princípios básicos da legalidade, da impessoalidade, da moralidade, da igualdade, da publicidade, da probidade administrativa, da vinculação ao instrumento convocatório, do julgamento objetivo e dos que lhes são correlatos. (Redação dada pela Lei nº 12.349, de 2010).

As compras realizadas através de processo de licitação são realizadas a partir do registro de preços e a licitação tradicional (ROSA; LÖBLER, 2014). A documentação necessária

envolve a solicitação de compra, que é gerada pelo almoxarifado central e deve ser aprovada e assinada pelo DEMAPA. Além disso, deve ser feita uma pesquisa de preços com no mínimo três empresas para cada item.

Após a conferência, os documentos são enviados à Pro Reitoria de Administração (PRA) para a autorização ou não das aquisições. Uma vez autorizado o processo, os documentos voltam ao DEMAPA, que os encaminha até a Advocacia-Geral da União (AGU) para análise jurídica. Após autorização da AGU, cabe ao DEMAPA a publicação e divulgação do edital de licitação para realização das compras. Caso a licitação resulte em um contrato, o DEMAPA é o responsável pela sua vigência, e caso contrário, a documentação é enviada ao Departamento de Contabilidade e Finanças (DCF). O fluxograma desse processo é apresentado no Anexo A.

2.3 PREVISÃO DE DEMANDA

Para Correa, Gianesi e Caon (2019), “a habilidade de prever a demanda é utilizar todas as ferramentas disponíveis para conseguir antecipar a demanda futura com alguma precisão.” Isso pode envolver formar e manter uma base de dados históricos, assim como informações que expliquem suas variações e comportamento no passado, bem como utilizar modelos matemáticos adequados que ajudem a explicar o comportamento da demanda. Morettin e Tolo (2004) salientam que “a previsão não constitui um fim em si, mas apenas um meio de fornecer informações para uma consequente tomada de decisões, visando a determinados objetivos.”

Tubino (2017) ressalta que “as previsões têm uma função muito importante nos processos de planejamento dos sistemas de produção, pois permitem que os administradores desses sistemas antevejam o futuro e planejem adequadamente suas ações”. Uma ideia básica de demanda futura é essencial para a eficácia dos sistemas de administração de almoxarifados. Gardner (1990) identifica a previsão como “pré-requisito para decisões sobre estoques”.

Um modelo de previsão de demanda envolve muitas variáveis, Slack et al. (2018) diz que “existe um elemento aleatório na demanda que é praticamente independente de quaisquer fatores óbvios”. Tubino (2017) apresenta cinco etapas para a elaboração de um modelo de previsão de demanda, são elas:

- Etapa 1. Objetivo do modelo: consiste em definir a razão pela qual se necessita de previsões, que produto será previsto, com que grau de acuracidade e detalhe a previsão trabalhará.
- Etapa 2. Coleta e análise de dados: identificar e desenvolver as técnicas de previsão que melhor se adaptam ao histórico de dados coletados.

- Etapa 3. Seleção da técnica de previsão: decidir qual técnica de previsão será utilizada, de acordo com alguns fatores como custo e acuracidade.
- Etapa 4. Obtenção das previsões: obter as projeções futuras da demanda de acordo com os parâmetros obtidos na técnica selecionada.
- Etapa 5. Monitoração do modelo: verificar a extensão do erro entre a demanda real e a prevista para verificar se a técnica e os parâmetros empregados ainda são válidos.

Tradicionalmente a literatura aborda os temas de controle de estoques e previsão de demanda como problemas independentes (SYNTETOS; BABAI; GARDNER, 2015), porém, Prak e Teunter (2019) argumenta que “o controle de estoques depende muito de previsões da demanda futura”.

2.3.1 Séries temporais

Segundo Montgomery et al. (2008), “serie temporal é a sequência de observações, de uma variável de interesse, cronologicamente ordenadas”. Para Morettin e Toloi (2004), existem dois enfoques básicos usados na análise de séries temporais, ambos têm o mesmo objetivo de construir modelos para as séries. Ainda segundo os autores, “a maioria dos métodos de previsão baseia-se na ideia de que observações passadas contêm informações sobre o padrão de comportamento da série temporal”. O enfoque abordado nesse trabalho, refere-se a análise realizada no domínio temporal com modelos paramétricos (com um número finito de parâmetros).

Tubino (2017) ressalta que este é o método mais simples e usual de previsão e quando bem elaborado pode oferecer bons resultados. Para realizar previsões de variáveis únicas, os processos estocásticos de series temporais podem ser representados por diferentes modelos, incluindo abordagens simples, como a suavização exponencial e os modelos auto-regressivos e de médias móveis (XU et al., 2019).

A estacionariedade é uma característica relevante de uma série temporal e está relacionada às suas propriedades estatísticas no tempo. Isso é, uma série temporal estacionaria desenvolve no tempo aleatoriamente ao redor de uma média constante, refletindo alguma forma de equilíbrio estável (MORETTIN; TOLOI, 1981). Assim, para Montgomery (2008) “a estacionariedade reflete na série um comportamento estatístico similar ao longo do tempo e geralmente é caracterizada como uma distribuição de probabilidade constante.”

Gujarati e Porter (2011) mencionam a importância da estacionariedade para o processo de previsão, pois se uma série não é estacionária, podemos estudar seu comportamento apenas

pelo período de tempo em consideração, não sendo possível generaliza-lo para outros períodos. Porém, “a maior parte das séries encontradas na prática apresentam alguma forma de não-estacionariedade”, assim é necessário transformar os dados originais para a maioria das aplicações estatísticas (MORETTIN; TOLOI, 2004).

Existem vários testes para descobrir se uma série temporal é estacionária ou não, um dos mais conhecidos é o teste Dickey-Fuller Aumentado (DFA). Esse é um teste de raiz unitária, que testa a hipótese nula do processo gerador da série possuir raiz unitária, e por consequência gerar uma série não estacionária (GUJARATI; PORTER, 2011).

2.3.2 Modelo Auto Regressivo (AR) e Média Móvel (MA)

Para os modelos Auto Regressivos (AR) e Média Móvel (MA), supõe-se que a série temporal seja gerada por um sistema linear, e que possui um termo de erro aleatório não correlacionado, com média zero e variância constante, denominado ruído branco (GUJARATI, 2000).

Em um modelo $AR(p)$, dado uma série Z_t , essa é descrita por seu valores históricos passados Z_{t-1}, Z_{t-2}, \dots e por um termo de ruído branco (erro) a_t . Esse modelo é representado por Morttin e Toloí (2004) na Equação (1).

$$Z_t = \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p} + a_t \quad (1)$$

Na Equação (1), p refere-se a ordem do modelo auto regressivo, denotado por $AR(p)$. É possível dizer que Z no período t depende de seu próprio valor em p períodos anteriores. Os parâmetros $\phi_1, \phi_2, \dots, \phi_p$ são as constantes, que devem ser estimadas, e se relacionam com os valores antigos da série para formar o modelo. “O modelo definido é chamado de processo auto-regressivo de ordem p ou processo $AR(p)$ ” (BOX; JENKINS, 1976).

Dado uma série Z_t , o modelo de médias móveis descreve-a no período t com um termo de erro e com um parâmetro constante mais uma média móvel dos termos de erro atuais e passados (GUJARATI; PORTER, 2011). Pela notação de Morettin e Toloí (2004), o processo de médias móveis de ordem q ou $MA(q)$ segue a Equação (2).

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

“É muito provável que uma série temporal possua características tanto de processos AR quanto de MA” (GUJARATI; PORTER, 2011). Segundo Morettin e Toloí (2004), “para muitas séries encontradas na prática, se quisermos um modelo com um número não muito grande de parâmetros, a inclusão de termos auto-regressivos e de médias móveis é a solução”, a partir disso surgem os modelos ARMA(p,q), na Equação (3), a seguir:

$$Z_t = \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p} + a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q} \quad (3)$$

2.3.3 Modelo ARIMA (p,d,q)

Os modelos AR(p), MA(q) e ARMA(p,q) são apropriados para descrever séries estacionárias (MORETTIN; TOLOI, 2004). Gujarati e Porter (2011) comentam que: “muitas séries temporais econômicas são não estacionárias, isto é, são integradas.” “A classe dos modelos ARIMA será capaz de descrever de maneira satisfatória séries estacionárias e não estacionárias, mas que não apresentem comportamento explosivo” (MORETTIN; TOLOI, 1981).

Segundo Martin et al. (2016), “os modelos ARIMA(p,d,q) diferem-se dos modelos ARMA(p,d) apenas pela diferenciação que ocorre d vezes, até tornar a série estacionária”. Dada uma série temporal, se esta for integrada de ordem 1 (I[1]), suas primeiras diferenças serão I[0], ou seja, demonstram-se estacionárias. Assim, em geral, se uma série temporal não estacionária, representada por I[d], for diferenciada d vezes, esta série obtida será estacionária I[0] (GUJARATI, 2000). A estrutura do modelo ARIMA é expresso pela Equação (4):

$$\Delta^d Z_t = W_t = \phi_1 W_{t-1} + \dots + \phi_p W_{t-p} + a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q} \quad (4)$$

Como um exemplo de aplicação, Bianchi et al. (1998) faz uso do modelo ARIMA com o intuito de verificar possibilidades de melhoria em um sistema de previsão de demanda de uma *call center*. Uma das razões da popularidade da modelagem ARIMA é seu sucesso na previsão (GUJARATI; PORTER, 2011).

2.3.4 Metodologia de Box & Jenkins

Uma metodologia bastante utilizada na análise de modelos paramétricos é conhecida como abordagem de Box e Jenkins. Tal metodologia consiste em ajustar modelos autorregressivos integrados de médias móveis, ARIMA(p,d,q), a um conjunto de dados (MORETTIN; TOLLOI, 2004). Gujarati e Porter (2011) mostram que a construção do modelo é baseada em um ciclo iterativo composto pelos seguintes estágios: identificação, estimação, verificação do diagnóstico e previsão.

Os mesmos autores descrevem as etapas da seguinte maneira:

- Etapa 1. Identificação: através do correlograma e do correlograma parcial obtidos com as funções de autocorrelação, descobre-se os valores apropriados de p , d e q .
- Etapa 2. Estimação: estimar os parâmetros dos termos autorregressivos e dos termos de média móvel incluídos no modelo.
- Etapa 3. Verificação: verificar se o modelo selecionado se ajusta bem aos dados para saber se é adequado para fins de previsão. Um teste simples é verificar se os resíduos do modelo selecionado são ruídos brancos, se forem o modelo pode ser aceito.
- Etapa 4. Previsão: utilizar o modelo para prever valores futuros.

2.3.5 Erro de previsão

Ballou (2006) define erro de previsão como: “o quão perto do verdadeiro nível da demanda chega a previsão”, isso é expresso pela diferença entre o valor real da demanda e o valor previsto pelo modelo disposto a seguir, na Equação (5):

$$e_t = dr_t - dp_t \quad (5)$$

Onde e_t representa o erro de previsão para o período t , dr_t a demanda real e dp_t a demanda prevista pelo modelo. Para Tubino (2017), “um modelo de previsão para a demanda funciona adequadamente quando apenas os erros decorrentes de variações aleatórias ocorrem”, isso reforça a importância da análise dos erros de previsão para o monitoramento do modelo.

Para Hyndman e Athanasopoulos (2018). “os resíduos são úteis para verificar se o modelo capturou adequadamente as informações nos dados analisados”, assim os resíduos de um modelo de previsão considerado adequado apresentam duas características: não são

correlacionados entre si e possuem média zero. Assim, se alguma dessas propriedades não é satisfeita, o modelo de previsão pode ser modificado (HYNDMAN; ATHANASOPOULOS, 2018). Os mesmos autores ainda salientam que resíduos que apresentam variância constante e são normalmente distribuídos facilitam o cálculo do intervalo de previsão.

Existem várias métricas para avaliar a acurácia do modelo através dos erros de previsão, algumas utilizadas no meio acadêmico são: *Mean Absolute Scaled Error* (MASE), *Mean Absolute Error* (MAE) e *Mean Squared Error* (MSE) (ARMSTRONG; COLLOPY, 1992). Ao analisar a performance de um modelo, além de avaliar o resultado da métrica utilizada, é desejável a comparação com padrões hipotéticos. Um desses padrões é a previsão perfeita, onde o valor previsto e o valor real da demanda são o mesmo resultando em um erro nulo (THOMSON et al., 2019).

O erro médio absoluto é uma medida de erro dependente da escala, ou seja, esse erro está na mesma escala que os dados (HYNDMAN; ATHANASOPOULOS, 2018). O MAE é definido como erro médio absoluto, apresentado na Equação (6):

$$MAE = \frac{1}{n} \sum_{t=1}^n | e_t | \quad (6)$$

Nessa equação, n é o número total de observações e e_t é o erro de previsão para cada uma das observações.

Outra medida de erro dependente da escala é a Raiz do Erro Médio ao Quadrado (RMSE). Um modelo de previsão que minimiza o RMSE irá levar a previsões da média (HYNDMAN; ATHANASOPOULOS, 2018). O formula para o RMSE é apresentada na Equação (7):

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n | e_t^2 |} \quad (7)$$

Hyndman e Koehler (2006) propuseram uma medida de erro de escala como alternativa para os erros percentuais, que em alguns casos não são eficientes, como por exemplo para a comparação da acuracidade de previsões em séries de diferentes unidades. Como medida de avaliação, os mesmos autores definem que se o erro de escala é menor que um ele é vem de um modelo melhor que a média dos modelos computados. Uma vantagem do erro médio absoluto em escala é que ele não gera um resultado indefinido ou infinito, sendo uma boa escolha para

séries com demanda intermitente (PRESTWICH, 2014). Sua fórmula é apresentada nas equações (8) e (9):

$MASE = média (|q_t|)$ (8), onde:

$$q_t = \frac{e_t}{\frac{1}{n-1} \sum_{i=2}^n |y_i - y_{i-1}|} \quad (9)$$

Sendo que e_t representa o erro de previsão e y_i e y_{i-1} as observações da demanda nos períodos i e $i-1$, respectivamente.

2.3.6 Critérios de parcimônia

Três critérios considerados relevantes para a escolha de modelos concorrentes, com o intuito de serem utilizados para previsões futuras são: *Akaike Information Criterion* (AIC), *Akaike Information Criterion corrected* (AICc) e *Bayesian Criterion Information* (BIC). Segundo Montgomery (2008), esses critérios penalizam, a soma dos resíduos ao quadrado, por incluir parâmetros adicionais ao modelo. Ou seja, esses critérios avaliam a relevância dos parâmetros do modelo. “Bons modelos são obtidos pela minimização dos critérios AIC, AICc e BIC” (HYNDMAN; ATHANASOPOULOS, 2018).

Para Hyndman e Athanasopoulos (2018), o critério AICc deve ser preferencialmente utilizado. Ele é a versão corrigida do AIC, que pode apresentar um viés ao analisar a discrepância entre todos os modelos candidatos (MONTGOMERY, 2008).

3 ASPECTOS METODOLÓGICOS

Nessa seção serão apresentados o cenário de realização da pesquisa, a classificação da pesquisa e suas principais etapas.

3.1 CENÁRIO

As ações relacionadas a pesquisa irão ocorrer predominantemente no Almoarifado Central da Universidade Federal de Santa Maria. O almoarifado tem como objetivo “disponibilizar o fornecimento de materiais de consumo necessários para os andamentos das atividades letivas e administrativas na Universidade Federal de Santa Maria” (UFSM, 2019). Ele opera em um espaço com 2,5 mil metros quadrados para receber, armazenar e distribuir os materiais de consumo e estoques da UFSM. Conta com um moderno sistema de armazenamento, que inclui um elevador de cargas com capacidade de uma tonelada e três pavimentos metálicos (mezaninos) dentro da área do edifício.

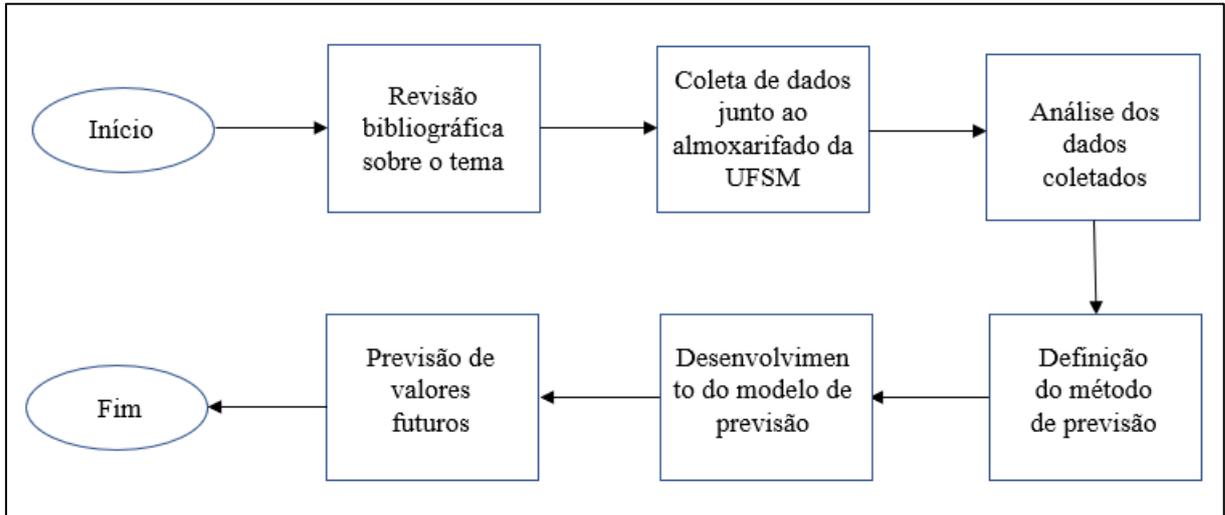
3.2 MÉTODO DE PESQUISA

A pesquisa pode ser classificada como aplicada, pois busca aplicar conhecimentos em uma área específica e com objetivos descritivos, pois busca descrever o comportamento da demanda do almoarifado da UFSM. Os objetivos deverão ser atingidos a partir de um estudo de caso, pois conforme Boaventura (2004), estudo de caso caracteriza-se na aplicação prática de conhecimentos para solucionar problemas. Quanto a abordagem, é uma pesquisa considerada quantitativa, uma vez que será feita a análise do histórico da demanda do almoarifado.

3.3 ETAPAS DA PESQUISA

As principais atividades desenvolvidas na pesquisa para atingir os objetivos definidos foram: revisão bibliográfica sobre os métodos de previsão de demanda, análise do histórico de dados disponibilizados pelo almoarifado central da UFSM, definição do método de previsão a ser utilizado, desenvolvimento o modelo de previsão de demanda e utilização do modelo para previsão de valores futuros. A Figura 1 apresenta um fluxograma com as etapas.

Figura 1 – Etapas da pesquisa



Fonte: Autor (2019).

A etapa da revisão bibliográfica envolveu pesquisar em livros e artigos sobre os métodos de previsão existentes, bem como utilizá-los e quais as características de demanda compatíveis com cada método. Além disso, buscou-se exemplos da utilização de técnicas de previsão de demanda em cenários semelhantes com o desse estudo.

Na segunda etapa foram fornecidos os dados referentes às demandas de alguns produtos e na terceira etapa esses foram analisados com o intuito de selecionar um produto específico para realizar a previsão de demanda. As primeiras atividades para a definição dos possíveis produtos a terem sua demanda analisada foram uma visita ao cenário da pesquisa, o Almoxarifado Central da UFSM e uma entrevista com um dos gestores do órgão. Com base nas possibilidades apresentadas pelo gestor e nas características relevantes para a definição do produto (alta rotatividade, item de primeira necessidade, necessidade de espaço físico no estoque e continuidade de consumo futuro), a categoria de produto que foi escolhida para análise foram as lâmpadas LED.

Na quarta e quinta etapa, dois modelos de previsão foram desenvolvidos de acordo com a metodologia de Box e Jenkins e comparados de acordo com critérios de parcimônia e erro. O desenvolvimento contou com o apoio de *softwares* específicos, sendo eles o Excel e o RStudio. Os principais pacotes utilizados para a análise de séries temporais no R foram: “*tseries*”, “*fpp2*”, “*forecast*”, “*zoo*”, “*urca*” e “*imputeTS*”. Esses pacotes oferecem funções que auxiliam o pesquisador em todos os aspectos do estudo de séries temporais (SHUMWAY; STOFFER, 2011). Além disso, outros pacotes como o “*ggplot2*” e o “*cowplot*” foram utilizados para visualização dos gráficos necessários. Ainda na quinta etapa, o modelo escolhido

foi validado para fins de previsão através da análise residual, com um teste de correlação residual e verificação do valor médio dos resíduos.

Na última etapa, o modelo foi utilizado para realizar a previsão de valores futuros da demanda para um horizonte de curto prazo.

4 ANÁLISE E DISCUSSÃO DOS RESULTADOS

A seguir serão apresentados os resultados da pesquisa, de acordo com as etapas da elaboradas anteriormente.

4.1 DEFINIÇÃO DO PRODUTO PARA PREVISÃO

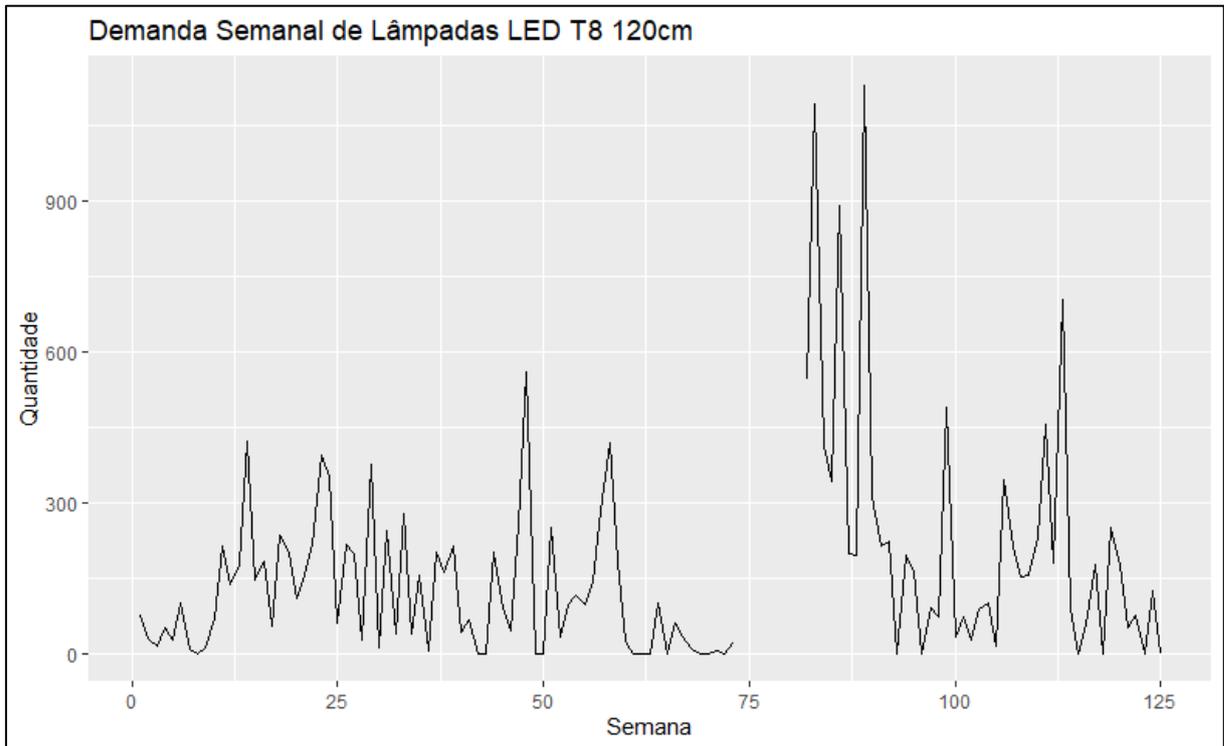
A UFSM está passando por um processo de substituição gradual das lâmpadas de iluminação ambiente, de tubulares para lâmpadas LED. Essa substituição tem o objetivo de reduzir o consumo e os custos com energia elétrica, Zanin et al. (2015) demonstram que essa substituição é viável economicamente e que a redução no consumo de energia elétrica é significativa. Assim, cada vez que o almoxarifado recebe uma solicitação para troca de lâmpadas, a substituta será do tipo LED, salvo casos especiais. Os consumidores desse material são os departamentos da UFSM que, sempre que necessitam, fazem uma requisição do produto ao almoxarifado.

Os dados para análise da demanda foram fornecidos por um dos gestores do almoxarifado. Grande parte dos tipos de lâmpadas LED começaram a ser adquiridas pelo almoxarifado em 2017, assim foram disponibilizados os dados históricos de cinco tipos de lâmpadas LED. O histórico de demanda de todos esses tipos de lâmpadas apresenta irregularidade no consumo, porém a Lâmpada Tubular LED T8 120cm é a que apresenta o histórico de dados mais completo e foi a que mais se aproximou das características citadas anteriormente, assim esse foi o tipo específico escolhido para a realização da previsão de demanda.

4.2 APRESENTAÇÃO DA DEMANDA DO PRODUTO

Na Figura 2 é apresentado o gráfico da série histórica da demanda da Lâmpada Tubular LED T8 120cm, na periodicidade semanal.

Figura 2 – Gráfico da série histórica da demanda da Lâmpada Tubular LED T8 120cm



Fonte: Autor (2019).

A série histórica conta com 125 semanas, tendo seu início na semana do dia 05/03/2017 até o dia 11/03/2017 e o seu término na semana do dia 21/07/2019 até 27/07/2019. Optou-se por realizar a análise na periodicidade semanal devido ao produto não ter um consumo diário constante e a quantidade de observações para uma análise mensal não ser adequada.

Alguns valores não foram coletados, especificamente da semana 74 a 81, totalizando 8 observações que estão em falta. Isso pode ocorrer principalmente por dois motivos: a saída do produto não foi registrada ou uma falha no sistema de informação utilizado para o controle do estoque.

4.2.1 Alternativas para completar a série histórica

Em análises de séries temporais é importante saber lidar com dados ausentes, que acontecem com frequência em situações reais. Para isso, utilizam-se métodos de imputação antes da análise principal da série (BIANCHI et al., 2019). Os principais métodos de imputação de dados para series temporais de variável única são: interpolação linear e não linear, maximização de expectativa, ajustamento de curva, filtros de Kalman, entre outros (ANDIAOJAYA; DEMIRHAN, 2019).

O pacote “*imputeTS*” surge como alternativa para aplicação desses métodos, ele inclui vários algoritmos de imputação e é dedicado para séries temporais de variável única (MORITZ; BARTZ-BEIELSTEIN, 2017). Devido à complexidade da maior parte dos métodos, apenas três deles foram utilizados para completar a série histórica da demanda de Lâmpadas LED, são eles interpolação linear, interpolação *spline* e interpolação *Stineman*. O primeiro, é um método básico de interpolação entre dois pontos. Já o segundo e o terceiro, são métodos avançados de interpolação não linear (DEMIRHAN; RENWICK, 2018). Esses métodos foram escolhidos pelos critérios da relação entre complexidade e resultados alcançados com sua utilização em outros estudos.

Com a utilização da função *na_interpolation()* é possível aplicar os métodos escolhidos com o intuito de completar a série de dados da demanda. O resultado das interpolações é apresentado no Apêndice A. Os três métodos de interpolação completam os dados de maneira semelhante, portanto, realizou-se a análise da série temporal para as três possibilidades e o modelo gerado com o método de interpolação de *Stineman* foi o que apresentou os melhores resultados. A seguir, é apresentado o desenvolvimento da análise desse modelo especificamente.

4.3 ANÁLISE DA SÉRIE TEMPORAL

A série foi analisada através da metodologia de Box e Jenkins para construção de dois modelos ARIMA, que foram comparados de acordo com os critérios de acuracidade e de erro, sendo o melhor escolhido para realizar a previsão da demanda.

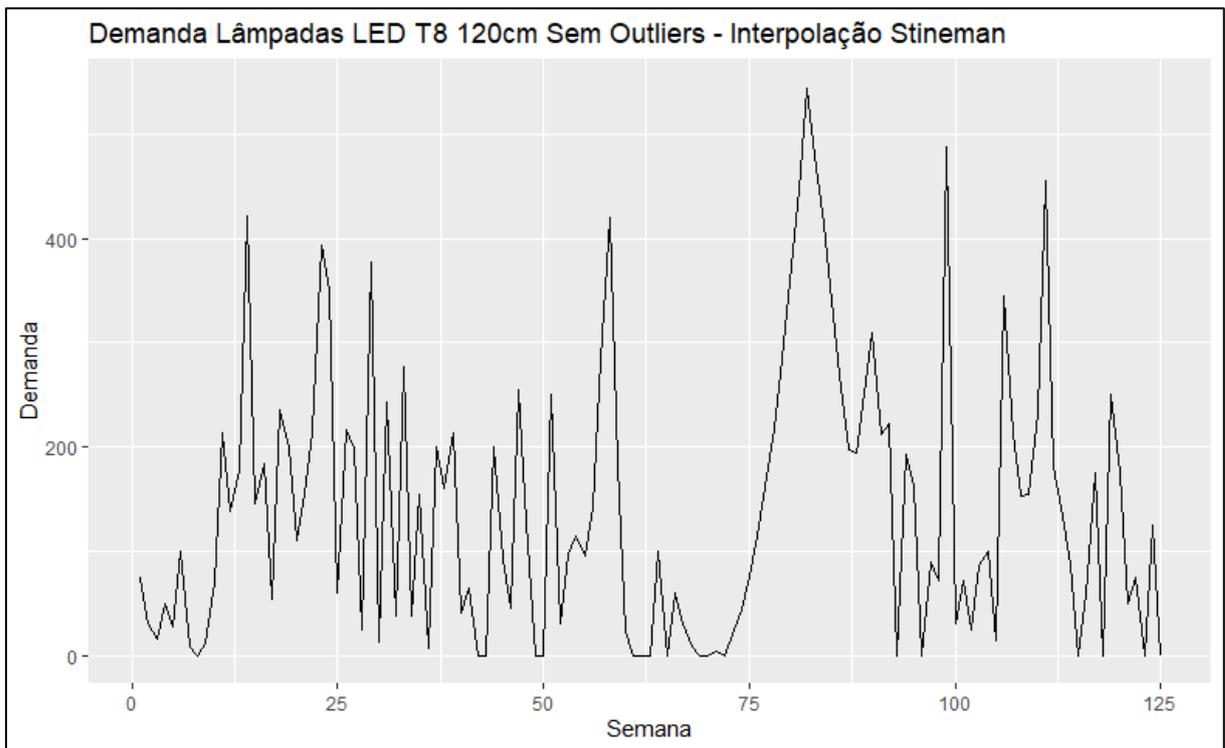
4.3.1 Identificação de *outliers*

Com os dados imputados na série temporal pela interpolação de *Stineman*, o primeiro passo para realizar a análise foi a identificação e remoção de *outliers*. Com o pacote “*forecast*”, foi utilizado a função *tsclean()*, que através da suavização e da decomposição da série, identifica e remove/ajusta os *outliers* automaticamente. Na série demanda de Lâmpadas LED T8 120cm, a função identificou cinco observações como *outliers* e o gráfico do resultado é apresentado na Figura 3.

As cinco observações que destoam do padrão capturado na série de dados são: 48, 83, 86, 89 e 113. Percebe-se que nenhuma dessas observações está no intervalo dos dados que foram interpolados e sabendo quais demandas semanais são consideradas *outliers*, foi possível

buscar um padrão que pudesse explicar esse fenômeno. Analisando a origem dos dados fornecidos pelo gestor, percebeu-se que em todas essas semanas o Centro de Ciências da Saúde (CCS) da UFSM requisitou uma quantidade muito acima da média. Assim, considera-se que a quantidade requisitada pelo CCS não foi para reposição/substituição de lâmpadas antigas, mas sim para o primeiro uso do produto, o que justifica o ajuste da quantidade dessas semanas na série.

Figura 3 – Demanda de lâmpadas Led com a remoção dos outliers



Fonte: Autor (2019).

4.3.2 Identificação da ordem dos modelos candidatos

A identificação dos valores apropriados de p , d e q nos modelos ARIMA é feita através dos correlogramas de autocorrelação e autocorrelação parcial da série. Porém, essas funções devem ser aplicadas a séries consideradas estacionárias. Para testar a estacionariedade da série da demanda de lâmpadas, fez-se uso do teste de raiz unitária Dickey-Fuller Aumentado (DFA), o qual considera a hipótese nula de não estacionariedade da série. O resultado para o teste é apresentado na Tabela 1, onde é possível perceber que o valor da estatística do teste é $-2,49$, se enquadrando entre os valores críticos de 1% e 5%. Assim, é possível rejeitar a hipótese nula de não estacionariedade para o nível de significância de 5%.

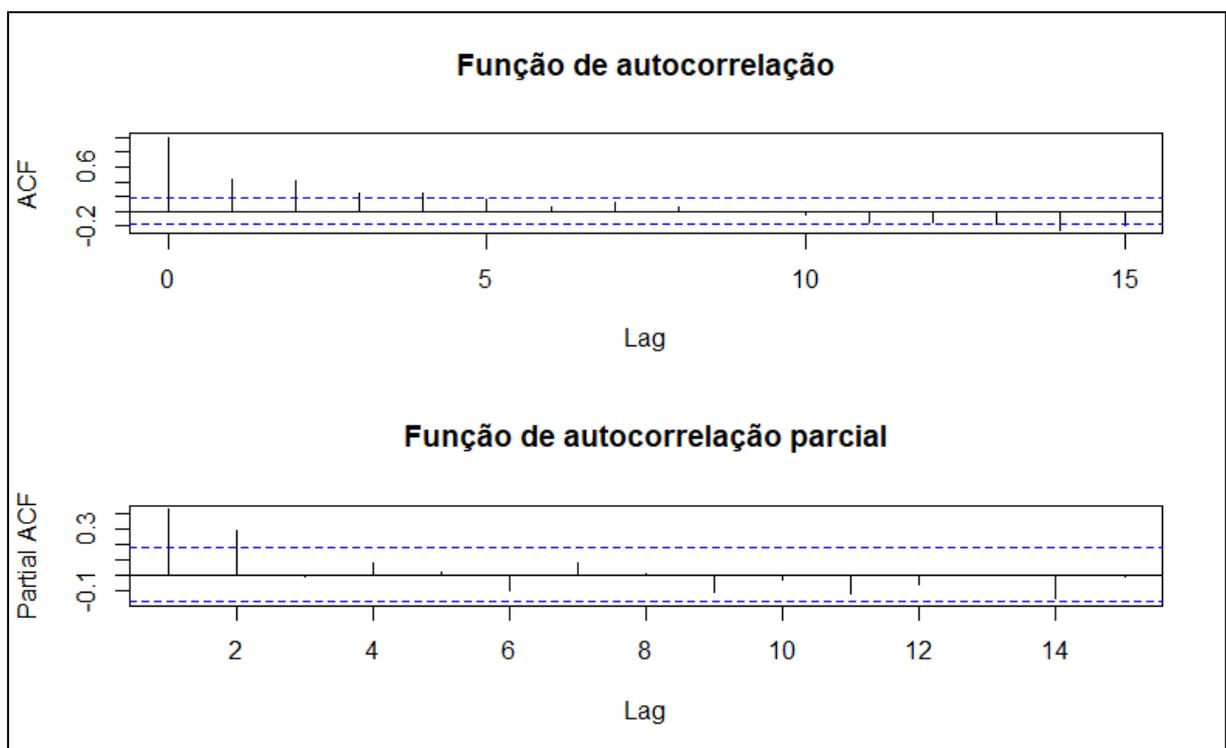
Tabela 1 – Teste DFA da série de demanda de lâmpadas LED

Valor do teste	Valor crítico do teste		Decisão do teste
-2,57	1%	-2,58	Série não estacionária
	5%	-1,95	Série estacionária
	10%	-1,62	Série estacionária

Fonte: Autor (2019).

Como a série é considerada estacionária, é possível realizar a análise dos correlogramas, apresentados na Figura 4. A função de autocorrelação (FAC) apresenta valores significativos nas quatro primeiras ordens, já a função de autocorrelação parcial (FACP) apresenta valores significativos nas duas primeiras ordens.

Figura 4 – Correlogramas da demanda de Lâmpadas LED T8 120cm



Fonte: Autor (2019).

Assim, procedeu-se à estimação da ordem do primeiro modelo ARIMA candidato. A ordem da parte autoregressiva (p) é determinada pelo número de valores significativos na FACP e a ordem da parte de médias móveis (q) pelos valores significativos na FAC. No caso, o primeiro modelo candidato será um ARIMA(2,0,4), que é gerado utilizando a função *Arima()*.

O segundo modelo candidato foi estimado através da função *auto.arima()* do pacote “*forecast*”. Essa função retorna o melhor modelo ARIMA ajustado de acordo com o critério de parcimônia escolhido (BIC, AIC ou AICc) (HYNDMAN; KHANDAKAR, 2008). Aplicando a função para a série histórica da demanda, obteve-se um modelo ARIMA(3,0,2).

Para a elaboração dos dois modelos, fez-se uso de uma transformação de Box-Cox com o intuito de garantir que as previsões e o intervalo de previsão sejam positivos (HYNDMAN; ATHANASOPOULOS, 2018). Essa transformação, quando aplicada nos dados ajusta o conjunto de dados para a distribuição normal, reduzindo a variância da série. Os modelos construídos a partir dos dados transformados apresentam melhor desempenho nos critérios de comparação (BOX; COX, 1964). A transformação de Box-Cox é feita de forma automática com a variável *lambda* = “*auto*” nas funções *auto.arima()* e *Arima()*. Na prática, essas funções estimam os parâmetros dos modelos pelo Método da Máxima Verossimilhança (MLE). O Apêndice B apresenta os modelos e os respectivos valores de cada um de seus parâmetros, bem como o valor de *lambda* utilizado para a transformação.

4.3.3 Comparação dos modelos concorrentes

A seguir os modelos candidatos são comparados de acordo com os critérios de parcimônia e de erro de previsão. Os critérios de parcimônia são: AIC, AICc e BIC, e os critérios de erro de previsão são: MAE, RMSE e MASE. A Tabela 2 apresenta os valores de cada um dos critérios para os modelos.

Tabela 2 – Critérios de comparação para os modelos candidatos

Modelos candidatos	PARCIMÔNIA			ERRO		
	AIC	AICc	BIC	MAE	RMSE	MASE
ARIMA(2,0,4)	749	750	771	97,0	134,7	0,93
ARIMA(3,0,2)	747	748	766	96,1	133,6	0,92

Fonte: Autor (2019).

Os dois modelos apresentam valores para os critérios de comparação muito próximos. Porém, como o modelo ARIMA(3,0,2) tem os menores valores em todos os critérios comparativos, ele será o escolhido para realizar a previsão de demanda.

4.4 VERIFICAÇÃO DO MODELO SELECIONADO

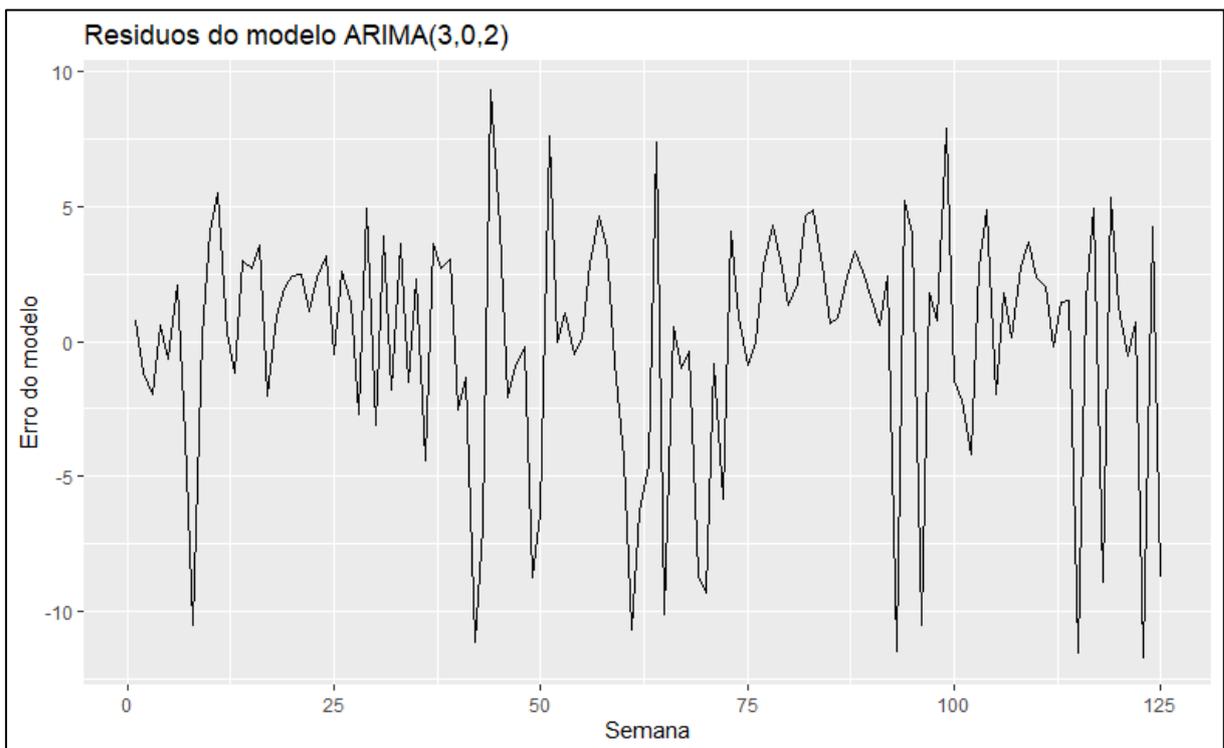
Para verificar se o modelo escolhido se adequa bem para fins de previsão, a análise dos resíduos do modelo é uma boa alternativa. Um bom modelo de previsão apresenta resíduos não correlacionados e com média zero (HYNDMAN; ATHANASOPOULOS, 2018).

4.4.1 Análise residual

Os resíduos do modelo são apresentados no gráfico da Figura 5. Nele é possível perceber que o erro do modelo se comporta entre -10 e 10, aproximadamente. Para testar a correlação dos resíduos, na Figura 6 são apresentados os gráficos da FAC e FACP para os resíduos do modelo. Além disso, o teste de Ljung-Box, que testa a hipótese nula de independência em uma série temporal foi realizado e é apresentado no Apêndice C.

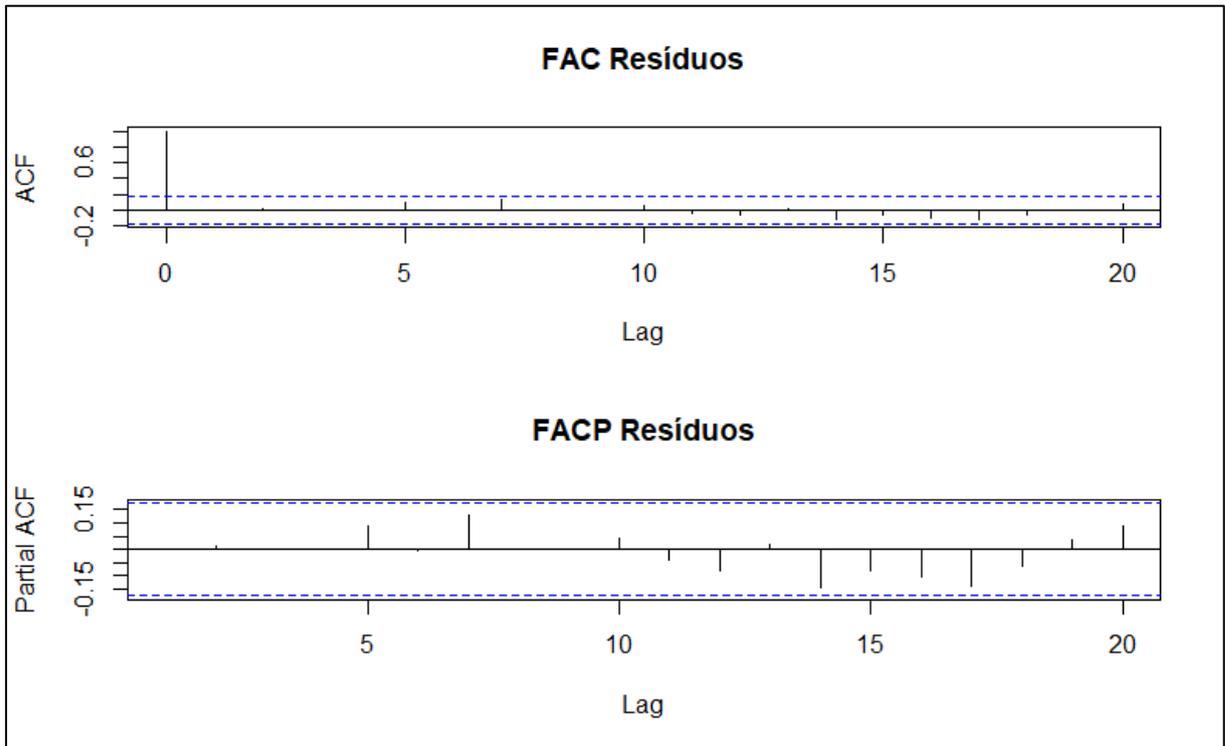
Os correlogramas não apresentam nenhum valor significativo, logo os resíduos devem ser não correlacionados. Através do teste de Ljung-Box não é possível rejeitar a hipótese nula de independência dos resíduos, pois a estatística do teste é 12,3 com um *p-valor* de 0,903.

Figura 5 – Gráfico dos resíduos do modelo selecionado



Fonte: Autor (2019).

Figura 6 – Funções de autocorrelação para os resíduos



Fonte: Autor (2019)

Para o cálculo da média dos resíduos, utilizou-se a função *mean()*, que aplicado aos resíduos do modelo, resulta em -0.0088. Logo, a média dos resíduos é considerada zero. Assim, os resíduos do modelo ARIMA(3,0,2) estão de acordo com os critérios estabelecidos por Hyndman e Athanasopoulos (2018) para considerar o modelo adequado para fins de previsão.

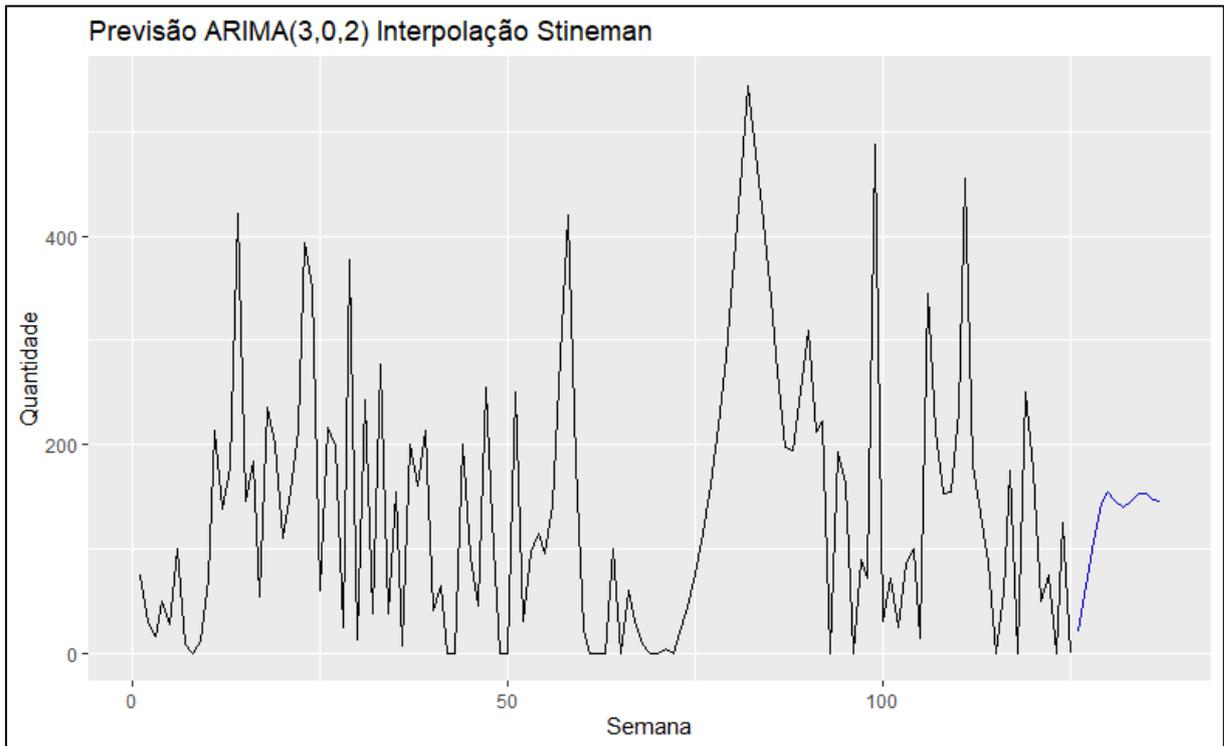
4.5 PREVISÃO DE VALORES FUTUROS

A última etapa na metodologia de Box e Jenkins é previsão, onde o modelo escolhido é utilizado para realizar a previsão de valores futuros. Através da função *forecast()*, é possível realizar a previsão para o número de períodos desejados, com a variável “h” igual ao número de períodos futuros. Outra variável que deve ser considerada nessa função é a “*biasadj*”, pois como uma transformação de Box-Cox foi realizada nos dados para a geração do modelo, essa variável deve ser verdadeira para que o modelo seja transformado de volta e os valores sejam previstos da maneira correta (PEIRIS; PERERA, 1988).

A Figura 7 apresenta a previsão de demanda para as Lâmpadas LED T8 120cm para 12 períodos, gerada com o modelo ARIMA(3,0,2). Como a previsão de demanda pode auxiliar o almoxarifado na organização do estoque, o horizonte de previsão de curto/médio prazo é

utilizado (HYNDMAN; ATHANASOPOULOS, 2018). A Tabela 3 apresenta os valores previstos para o horizonte de 12 semanas.

Figura 7 – Previsão de demanda para Lâmpadas LED T8 120cm para 12 períodos



Fonte: Autor (2019).

Tabela 3 – Valores previstos para o consumo de Lâmpadas LED T8 120cm

Semana	126	127	128	129	130	131	132	133	134	135	136	137
Quantidade	21	65	108	145	155	145	141	146	153	153	147	145

Fonte: Autor (2019).

5 CONSIDERAÇÕES FINAIS

A previsão de demanda é uma ferramenta importante, que pode contribuir com o planejamento das organizações. No setor público, onde grande parte das entidades são ineficientes operacionalmente e tem dificuldades no processo de compras, a previsão de demanda é uma alternativa que pode colaborar com a utilização adequada dos recursos públicos.

Durante o estudo, constatou-se que os gestores do Almoxarifado da UFSM ainda não utilizam de técnicas de previsão para o planejamento das compras, porém o órgão conta com um sistema informatizado que disponibiliza os dados históricos de consumo dos materiais, e a adoção e utilização dessas técnicas é uma alternativa viável.

Mesmo assim, como foi observado durante a realização do trabalho, ocorreram algumas falhas, técnicas ou humanas, na utilização do sistema que produziram dados faltantes na série histórica e dificultaram o estudo da demanda do produto em questão. Contudo, após a série histórica ser completada com uma interpolação de *Stineman* e os *outliers* serem removidos, a mesma apresentou-se estacionária. Dois modelos foram comparados segundo critérios de parcimônia e de erro, sendo o modelo ARIMA(3,0,2), que foi apontado pela função *auto.arima()*, apresentou os melhores resultados e tem as características adequadas para realizar a previsão de valores futuros da demanda.

O estudo apresenta como resultado uma previsão do consumo de Lâmpadas LED T8 120cm para 12 semanas, como é possível perceber pelo gráfico e pela tabela do item 4.4, os valores previstos a partir da semana 130 tendem a ficar oscilando em torno de 148 unidades, o que revela que o modelo provavelmente não é adequado para previsões muito distantes do período atual. Uma sugestão para utilização do modelo é a atualização do mesmo conforme o consumo real do produto, verificando se os critérios continuam adequados para fins de previsão.

Nesse contexto, um aspecto relevante na pesquisa é a periodicidade da série temporal estudada. Como as lâmpadas LED começaram a substituir as lâmpadas fluorescente em 2017, a série histórica foi apresentada na periodicidade semanal, para facilitar o estudo devido a quantidade de observações ser mais adequada do que na periodicidade mensal. Para estudos futuros no órgão em questão, sugere-se a previsão de demanda de produtos com a série histórica mensal, para facilitar e auxiliar os gestores no planejamento das compras, uma vez que essas não ocorrem com muita frequência.

Em relação aos critérios de escolha dos modelos candidatos, os valores para os dois modelos comparados são muito próximos entre si. Porém, o MAE e o RMSE podem ser considerados elevados, assim para estudos futuros da demanda do mesmo produto, sugere-se

completar os dados ausentes com outros métodos mais sofisticados, que considerem outras variáveis que podem afetar o consumo e que podem representar a demanda do produto de maneira mais adequada para aquele período. Outra possibilidade é realizar a previsão de demanda de com vários modelos adequados para esse fim. Assim, usa-se a média dos valores previstos para cada período como a previsão final, conforme Clemen (1989), essa técnica aumenta a acuracidade das previsões.

Com o modelo de previsão elaborado nesse estudo, o Almojarifado da UFSM pode compreender o comportamento da demanda de um de seus produtos, e com a quantidade estimada o órgão pode realizar um planejamento para as compras e para o estoque, melhorando a eficácia do processo. Além disso, como estudos sobre a demanda dos produtos do órgão de questão são escassos, o trabalho se torna relevante ao apontar várias oportunidades de estudos futuros em uma área que pode ter uma contribuição relevante com a gestão dos recursos da UFSM.

REFERÊNCIAS

- ALI, M. M.; BOYLAN, J. E.; SYNETOS, J. E. Forecast errors and inventory performance under forecast information sharing. **International Journal of Forecasting**, v. 28, n. 4, p. 830-841, 2012.
- ANDIOJAYA, A.; DERMIRHAN, H. A bagging algorithm for the imputation of missing values in time series. **Expert systems with applications**, v. 129, n. 1, p. 10-26, 2019.
- ANJOS, T. E. P.; GUIMARÃES, I. F. G. O controle de estoque em instituições públicas: uma análise em treze universidades brasileiras. In: CONGRESSO INTERNACIONAL DE ADMINISTRAÇÃO, 30., 2017, Ponta-Grossa. **Anais...** Ponta Grossa: ADM, 2017. Disponível: <<http://www.admpg.com.br/2017/selecionados.php>>. Acesso em: 17 maio 2019.
- ARMSTRONG, J. S.; COLLOPY, F. Errors measures for generalizing about forecast methods: empirical comparisons. **International Journal of Forecasting**, v. 8, n. 1, p. 69-80, 1992.
- BABAI, M. Z.; ALI, M. M.; BOYLAN, J. E.; SYNETOS, J. E. Forecasting and inventory performance in a two-stage supply chain with ARIMA(0,1,1) demand: Theory and empirical analysis. **Int. J. Production Economics**, v. 143, n. 2, p. 463-471, 2013.
- BALLOU, R. H. **Gerenciamento da cadeia de suprimentos**. 4. ed. Porto Alegre: Bookmann, 2001.
- BALLOU, R. H. **Gerenciamento da cadeia de suprimentos/logística empresarial**. 5. ed. Porto Alegre: Artmed, 2006.
- BIANCHI, F. M.; LIVI, L.; MIKALSEN, Ø. K.; KAMPFMEYER, M.; JENSSEN, R. Learning representation of multivariate time series with missing data. **Pattern recognition**, v. 96, article 106973, 2019.
- BIANCHI, L.; JARRETT, J.; HANUMARA, R. C. Improving forecasting for telemarketing centers by ARIMA modeling with intervention. **International Journal of Forecasting**, v. 14, n. 4, p. 497-504, 1998.
- BOAVENTURA, E. M. **Metodologia de pesquisa**: monografia, dissertação, tese. 1. ed. São Paulo: Atlas, 2004.
- BOX, G. E. P.; COX, D. R. An analysis of transformations. **Journal of the Royal Statistical Society**, v. 26, n. 2, p. 211-252, 1964.
- BOX, G. E. P.; JENKINS, G. M. **Time series analysis**: forecasting and control. San Francisco: Holden-Day Inc, 1976.
- BRASIL. Decreto n. 5.450, de 31 de maio de 2005. Regulamenta o pregão, na forma eletrônica, para aquisição de bens e serviços comuns, e dá outras providências. **Diário oficial da União**. Brasília, DF, 1 jun. 2005. Disponível em: <http://www.planalto.gov.br/ccivil_03/_ato2004-2006/2005/decreto/d5450.htm>. Acesso em: dia 22 maio 2019.

BRASIL. Decreto n. 7.892, de 23 de janeiro de 2013. Regulamenta o Sistema de Registro de Preços previsto no art. 15 da Lei nº 8.666, de 21 de junho de 1993. **Diário oficial da União**. Brasília, DF, 23 jan. 2013. Disponível em: <http://www.planalto.gov.br/ccivil_03/_ato2011-2014/2013/Decreto/D7892.htm>. Acesso em: 24 maio 2019.

BRASIL. Lei n. 10.520, de 17 de julho de 2002. Institui, no âmbito da União, Estados, Distrito Federal e Municípios, nos termos do art. 37, inciso XXI, da Constituição Federal, modalidade de licitação denominada pregão, para aquisição de bens e serviços comuns, e dá outras providências. **Diário oficial da União**. Brasília, DF, 18 jul. 2002. Disponível em: <http://www.planalto.gov.br/ccivil_03/leis/2002/L10520.htm>. Acesso em: 24 maio 2019.

BRASIL. Lei n. 8.666, de 21 de junho de 1993. Regulamenta o art. 37, inciso XXI, da Constituição Federal, institui normas para licitações e contratos da Administração Pública e dá outras providências. **Diário oficial da União**. Brasília, DF, 22 jun. 1993. Disponível em: http://www.planalto.gov.br/ccivil_03/leis/L8666cons.htm>. Acesso em: 24 maio 2019.

CLEMEN, R. Combining forecasts: A review and annotated bibliography with discussion. **International Journal of Forecasting**, v. 5, n. 4, p. 559-583, 1989.

CORRÊA, H. L.; GIANESI, I. G. N.; CAON, M. **Planejamento, programação e controle da produção – MRP II/ERP**. 6. ed. São Paulo: Atlas, 2019.

DERMIHAN, H.; RENWICK, Z. Missing value imputation for short to mid-term horizontal solar irradiance data. **Applied Energy**, v. 225, n. 1, p. 998-1012, 2018.

FENILI, R. R. **Gestão de materiais**. 2. ed. Brasília: Enap, 2016.

GARDNER, E. S. Evaluating forecast performance in an inventory control system. **Management science**, v. 36, n. 4, p. 401-518, 1990.

GUJARATI, D. N. **Econometria básica**. São Paulo: Pearson Makron Books, 2000.

GUJARATI, D. N.; PORTER, D. C. **Econometria básica**. 5. ed. Porto Alegre: AMGH, 2011.

HYNDMAN, R. J.; ATHANASOPOULOS, G. **Forecasting: principles and practice**. 2. ed. Melbourne: OTexts, 2018.

HYNDMAN, R. J.; KHANDAKAR, Y. Automatic time series forecasting: The forecast package for R. **Journal of Statistical Software**, v. 27, n. 3, 2008.

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.

JACOBS, W.; COSTA, M. Previsão da demanda de um produto industrial utilizando a metodologia de Box-Jenkins. **Revista de Destaques Acadêmicos CETEC/UNIVATES**, v. 3, n. 4, p. 77-93, 2011.

MAKRIDAKIS, S.; WHEELWRIGHT, S. C.; HYNDMAN, R. J. **Forecasting: methods and applications**. 3. ed. New York: Wiley, 1998.

- MARTIN, A. C.; HENNING, E.; WALTER, O. M. F. C.; KONRATH, C. Análise de series temporais para previsão da evolução do número de automóveis no município de Joinville. **Revista Espacios**, v. 37, n. 6, p. 29-44, 2016.
- MONTGOMERY, D. C.; JENNINGS, C. L.; KULAHCI, M. **Introduction to time series analysis and forecasting**. 1. ed. Hoboken: John Wiley & Sons. Inc, 2008.
- MORETTIN, P. A.; TOLOI, C. M. C. **13º Colóquio brasileiro de matemática**. vol. 1. Rio de Janeiro: Instituto de Matemática Pura e Aplicada, 1981.
- MORETTIN, P. A.; TOLOI, C. M. C. **Análise de séries temporais**. São Paulo: Edgar Blucher, 2004.
- MORITZ, S.; BARTZ-BEIELSTEIN, T. **imputeTS**: Time Series Missing Value Imputation in R. **The R Journal**, v. 9, n. 1, p. 207-218, 2017.
- MOTA, F. G. L.; CANCIO, A. J. Avaliação da potencialidade de redução de estoques no governo federal. In: ENANPAD, 28., 2004, Curitiba/PR. **Anais...** Rio de Janeiro: ANPAD, 2004. CD-ROM.
- PEIRIS, M.; PERERA, B. On prediction with fractionally differenced ARIMA models. **Journal of Time Series Analysis**, v. 9, n. 9, p. 215-220, 1988.
- PETROPOULOS, F.; WANG, X.; DISNEY, M. S. The inventory performance of forecasting methods: Evidence from the M3 competition data. **International Journal of Forecasting**, v. 35, n. 1, p. 251-265, 2019.
- POOLER, V. H.; POOLER, D. J.; FARNEY, S. D. **Global purchasing and supply management**. 2. ed. Boston: Kluwer Academic Publishers, 2004.
- PRAK, D.; TEUNTER, R. A general methods for addressing forecasting uncertainty in inventory models. **International Journal of Forecasting**, v. 35, n. 1, p. 224-238, 2019.
- PRESTWICH, S. D.; ROSSI, R.; TARIM, S. A.; HNIC, B. Mean-based error measures for intermittent demand forecasting. **International Journal of Production Research**, v. 52, n. 22, p. 6782-6791, 2014.
- R CORE TEAM. (2015). An Introduction to R. Fonte: The Comprehensive R Archive Network:<https://cran.r-project.org/doc/manuals/r-release/R-intro.pdf>
- ROSA, C. D. T.; LÖBLE, M. L. **Manual de padronização dos processos administrativos da UFSM**. 1. ed. Santa Maria: UFSM, 2014.
- SHUMWAY, R. H.; STOFFER, D. S. **Time Series Analysis and Its Applications: With R Examples**. 3. ed. Springer Texts in Statistics, 2011.
- SLACK, N.; BRANDON-JONE, A.; JOHNSTON, R. **Administração da produção**. 8. ed. São Paulo: Atlas, 2018.
- SYNTETOS, A. A.; BABAI, M. Z.; GARDNER JR. E. S. Forecasting intermittent inventory demands: simple parametric methods vs. bootstrapping. **Journal of Business Research**, v. 68, n. 8, p. 1746-1752, 2015.

THOMSON, M. E.; POLLOCK, A. C.; ÖNKAL, D.; GÖNÜL, M. S. Combining forecasts: Performance and coherence. **International Journal of Forecasting**, v. 35, n. 2, p. 474-484, 2019.

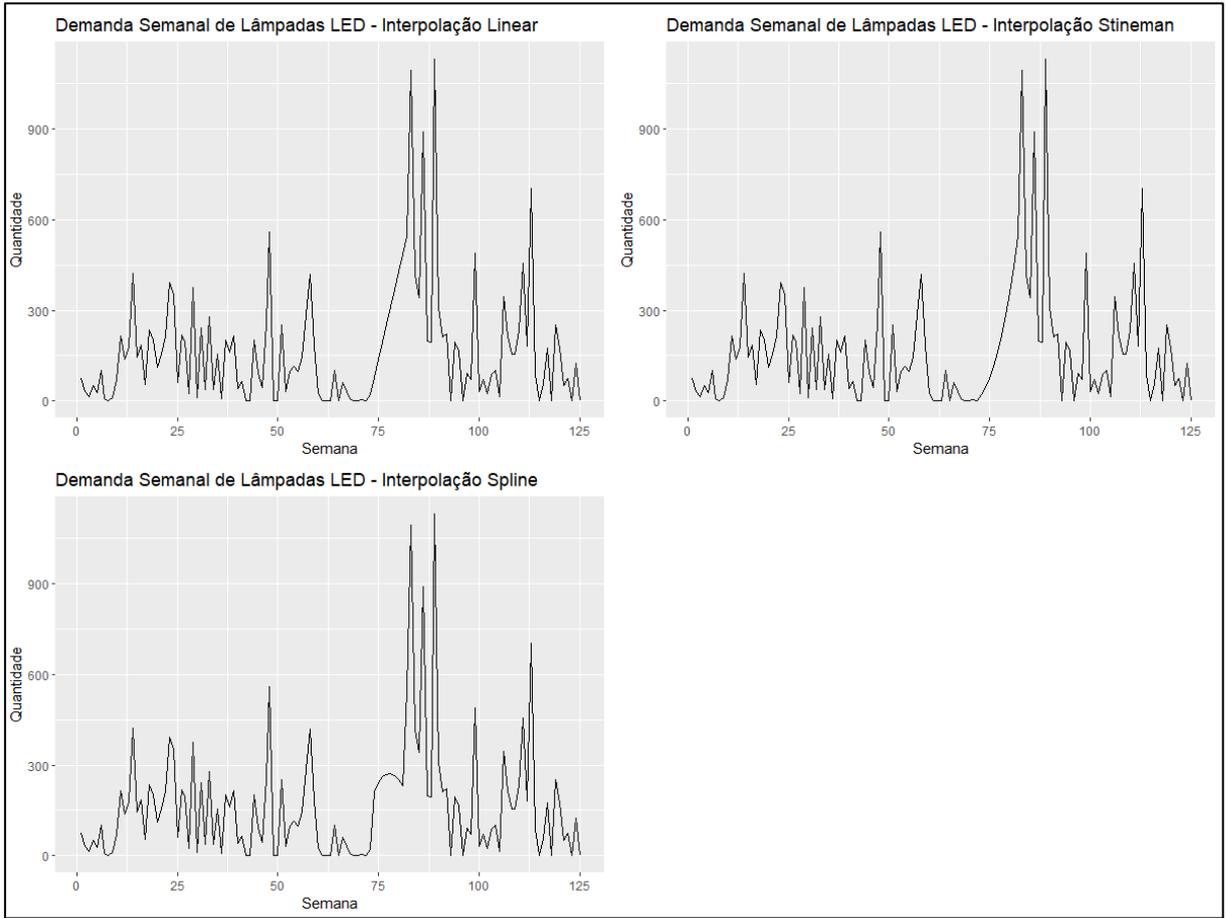
TUBINO, D. F. **Planejamento e controle da produção: teoria e prática**. 3. ed. São Paulo: Atlas, 2017.

UNIVERSIDADE FEDERAL DE SANTA MARIA. **Departamento de materiais e patrimônio**. Santa Maria: UFSM, 2019. Disponível em: <<https://www.ufsm.br/orgaos-executivos/demapa/almoxarifado-central/>>. Acesso em: 8 ago. 2019.

XU, S.; CHAN, H. K.; ZHANG, T. Forecasting the demand of the aviation industry using hybrid time series SARIMA-SVR approach. **Transportation Research Part E**, v. 122, p. 169-180, 2019.

ZANIN, A.; BAGATINI, F. M.; BARICHELLO, R.; TIBOLA, A. Análise do Custo x Benefício na troca de Lâmpadas Convencionais por Lâmpadas LED: O Caso de uma Universidade Comunitária do Sul do Brasil. In: CONGRESSO BRASILEIRO DE CUSTOS, 22., 2015, Foz do Iguaçu. **Anais eletrônicos...** Foz do Iguaçu: UNIOESTE, 2015. Disponível em: <<https://anaiscbc.emnuvens.com.br/anais/article/view/3926>>. Acesso em: 24 out. 2019.

APÊNDICE A – MÉTODOS DE INTERPOLAÇÃO



APÊNDICE B – PARÂMETROS DOS MODELOS CANDIDATOS

```

Series: interpstine
ARIMA(3,0,2) with non-zero mean
Box Cox transformation: lambda= 0.184121

Coefficients:
      ar1      ar2      ar3      ma1      ma2      mean
    0.8148 -0.8412  0.2585 -0.5954  0.9609  5.7324
s.e.  0.0980  0.1057  0.0978  0.0463  0.0482  0.7120

sigma^2 estimated as 21.26:  log likelihood=-366.53
AIC=747.05  AICc=748.01  BIC=766.85

Training set error measures:
              ME      RMSE      MAE  MPE  MAPE      MASE      ACF1
Training set 64.47673 133.6402 96.1697 -Inf  Inf  0.9258647 0.1828611
Series: interpstine
ARIMA(2,0,4) with non-zero mean
Box Cox transformation: lambda= 0.184121

Coefficients:
      ar1      ar2      ma1      ma2      ma3      ma4      mean
    0.4006 -0.6441 -0.1904  0.8627  0.2990  0.1396  5.7431
s.e.  0.1804  0.1140  0.1983  0.1477  0.1213  0.1640  0.6807

sigma^2 estimated as 21.5:  log likelihood=-366.65
AIC=749.31  AICc=750.55  BIC=771.93

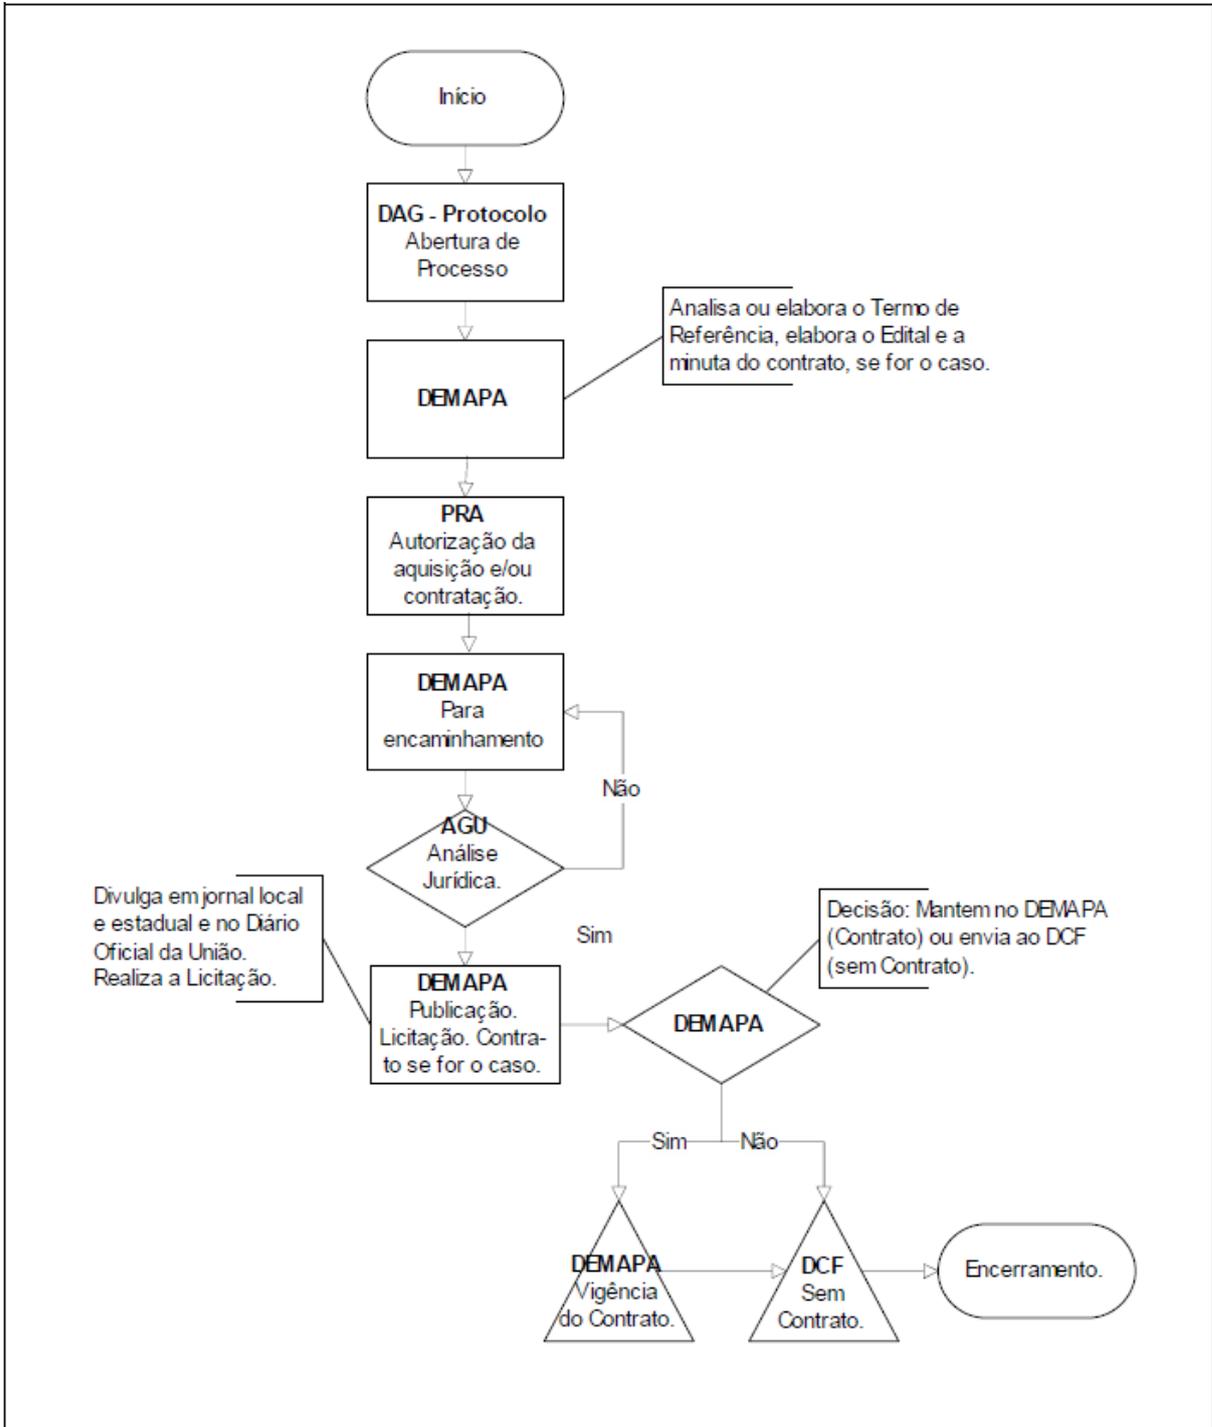
Training set error measures:
              ME      RMSE      MAE  MPE  MAPE      MASE      ACF1
Training set 65.18271 134.7328 97.02654 -Inf  Inf  0.9341139 0.2032294

```

APÊNDICE C – TESTE DE LJUNG-BOX PARA CORRELAÇÃO RESÍDUAL

```
Box-Ljung test  
data: arimainstine$residuals  
X-squared = 12.364, df = 20, p-value = 0.903
```

ANEXO A – FLUXOGRAMA DO PROCESSO DE COMPRA ATRAVÉS DE LICITAÇÃO NA UFSM



Fonte: Rosa e Löbler (2014).