



CENTRO UNIVERSITÁRIO UNIVATES
CENTRO DE CIÊNCIAS EXATAS E TECNOLÓGICAS
CURSO DE ENGENHARIA DE PRODUÇÃO

**PREVISÃO DA DEMANDA POR MEIO DE TÉCNICAS DE
SÉRIES TEMPORAIS EM EMPRESA DE SERVIÇOS DE
TRANSPORTE RODOVIÁRIO**

Augusto Siqueira

Lajeado, novembro de 2016

Augusto Siqueira

**PREVISÃO DA DEMANDA POR MEIO DE TÉCNICAS DE
SÉRIES TEMPORAIS EM EMPRESA DE SERVIÇOS DE
TRANSPORTE RODOVIÁRIO**

Monografia apresentada na disciplina de Trabalho de Conclusão de Curso, do Curso de Engenharia de Produção, ao Centro de Ciências Exatas e Tecnológicas, do Centro Universitário UNIVATES, como parte da exigência para a obtenção do título de Bacharel em Engenharia de Produção.

Orientador: Prof. William Jacobs

Lajeado, novembro de 2016

RESUMO

A previsão de demanda de passageiros em empresas de transporte rodoviário é essencial, visto a competitividade com que este setor trabalha e a necessidade de se obter um planejamento de suas atividades, visto que cada ampliação e investimento deste setor, representa um incremento considerável em seu serviço. O presente estudo tem por objetivo definir o melhor modelo para a previsão de demanda de passageiros dentre as técnicas de séries temporais consideradas. Foram considerados três métodos de previsão de séries temporais, são: (i) médias móveis, pela sua simples aplicação e flexibilidade; (ii) suavização exponencial, pela sua eficiência computacional e razoável precisão; e, (iii) *Box-Jenkins*, por sua eficiente precisão e ponderação. A análise dos dados é realizada com indicadores de eficácia do método (MAE e MAPE de ajustamento e previsão), comparando um método ao outro, com o mesmo critério de análise. O método de pesquisa é constituído das seguintes etapas: (i) coleta dos dados; (ii) organização dos dados; (iii) modelagem e previsão da série temporal; (iv) comparação das previsões realizada com indicadores; e, (v) apresentação e análise dos resultados. O trabalho é um estudo de modelagem quanto aos procedimentos técnicos, aplicado quanto à natureza, descritivo quanto aos objetivos e quantitativo quanto a abordagem do problema. O melhor resultado dentre os métodos aplicados foi obtido pela metodologia de *Box-Jenkins*, com um MAPE de previsão de 2,25%, mas em relação à metodologia de *Holt-Winters*, apenas 5,58% superior. Em termos de análises estatísticas, se considera o método de *Box-Jenkins*, com a modelagem SARIMA (1,0,2)(1,0,2)₁₂, como o melhor método de capacidade preditiva para a série temporal estudada.

Palavras-chave: Previsão de demanda. Séries temporais. Médias móveis. Suavização exponencial. *Box-Jenkins*.

ABSTRACT

The forecast demand of passengers in road transport enterprises is essential, given the competitiveness that this sector work and the need to obtain a planning of their activities. The present study aims to find the best methodology, analyses, time series forecasting, for the road passenger demand forecasting in a transport company. Were considered to be three methods of forecasting of time series, are: (i) moving averages, for its simple application and flexibility; (ii) exponential smoothing, for its computational efficiency and reasonable accuracy; and, (iii) Box-Jenkins, for its efficient precision and deliberation. The analysis of the data is given with indicators of effectiveness of method, comparing one method to another, with the same criteria of analysis. The research method consists of the following steps: (i) data collection; (ii) Organization of data; (iii) modelling and forecasting of time series; (iv) comparison of methods performed with indicators; and, (v) presentation and analysis of results. The work is a study of how modeling technical procedures applied as to the nature, descriptive and quantitative goals regarding how to approach the problem. The best result among the methods used were obtained by the Box-Jenkins methodology, with a MAPE of 2.25% forecast, but in relation to the methodology of the Holt-Winters, little 5.58% only. In terms of statistical analysis, the Box-Jenkins method, with modeling SARIMA (1,0,2)(1,0,2)₁₂, as the best method of predictive capacity for the time series studied.

Keywords: Demand forecasting. Time series. Moving averages. Exponential smoothing. Box-Jenkins.

LISTA DE FIGURAS

Figura 1 – Etapas de previsão de demanda.....	22
Figura 2 – Componentes do custo em relação à previsão de demanda	25
Figura 3 – Métodos e técnicas de previsão.....	26
Figura 4 – Padrões básicos das séries temporais	31
Figura 5 – Tipo de tendência e sazonalidade.....	37
Figura 6 – Metodologia de <i>Box-Jenkins</i>	44
Figura 7 – Metodologia da pesquisa.....	53
Figura 8 – Planejamento da pesquisa	56

LISTA DE QUADROS

Quadro 1 – Seleção de métodos quantitativos para previsão de demanda	27
Quadro 2 – Técnicas de previsão de séries temporais	30
Quadro 3 – Ponderação de alfa.....	36
Quadro 4 – Comportamento de FAC e FACP nos modelos AR, MA, ARMA.....	46

LISTA DE GRÁFICOS

Gráfico 1 – Série temporal.....	60
Gráfico 2 – Modelagem da série temporal utilizando o modelo de MMS	62
Gráfico 3 – Modelagem da série temporal utilizando os modelos de SEHWM	64
Gráfico 4 – Função de Auto Correlação da série temporal	65
Gráfico 5 – Função de Auto Correlação Parcial da série temporal	65
Gráfico 6 – Modelagem utilizando o modelo SARIMA (1,0,2)(1,0,2).....	67

LISTA DE TABELAS

Tabela 1 – Modelagem da série temporal utilizando os modelos de MM.....	61
Tabela 2 – Modelagem da série temporal utilizando os modelos de SE.....	63
Tabela 3 – Modelagem da série temporal utilizando a metodologia de <i>Box-Jenkins</i>	66
Tabela 4 – Comparação entre os melhores métodos	68
Tabela 5 – Demanda real e previsão.....	69

LISTA DE ABREVIATURAS E SIGLAS

AR	<i>Autoregressive</i>
ARIMA	<i>Autoregressive Integrated Moving Average</i>
ARMA	<i>Autoregressive Moving Average</i>
DAER	Departamento Autônomo de Estradas de Rodagem
FAC	Função de Auto Correlação
FACP	Função de Auto Correlação Parcial
MA	<i>Moving Average</i>
MAE	<i>Mean Absolute Error</i>
MAPE	<i>Mean Absolute Percentage Error</i>
MMEP	Média Móvel Exponencial Ponderada
MMP	Média Móvel Ponderada
MMS	Média Móvel Simples
PO	Pesquisa Operacional
SE	Suavização Exponencial
SEH	Suavização Exponencial de Holt

SEHW	Suavização Exponencial de <i>Holt-Winters</i>
SEHWA	Suavização Exponencial de <i>Holt-Winters</i> Aditivo
SEHWM	Suavização Exponencial de <i>Holt-Winters</i> Multiplicativo
ST	Série Temporal
TLB	Teste de <i>Ljung-Box</i>

SUMÁRIO

1 INTRODUÇÃO	12
1.1 Tema	13
1.2 Problema de pesquisa.....	13
1.3 Objetivo geral.....	14
1.4 Objetivos específicos.....	14
1.5 Justificativa	14
1.6 Delimitação do trabalho.....	16
1.7 Estrutura do trabalho	17
2 REFERENCIAL TEÓRICO	18
2.1 Serviços de transporte rodoviário	18
2.2 Previsão de demanda.....	20
2.2.1 Etapas da metodologia de previsão de demanda	21
2.2.2 Seleção da técnica de previsão de demanda	24
2.2.3 Técnicas de previsão de demanda	26
2.2.4 Séries temporais.....	29
2.3 Método de médias móveis	32
2.3.1 Média móvel simples (MMS).....	33
2.3.2 Média móvel ponderada (MMP).....	34
2.3.3 Média móvel exponencial ponderada simples (MMEP)	35
2.4 Suavização exponencial (SE)	36
2.4.1 Suavização exponencial de Holt (SEH).....	38
2.4.2 Suavização exponencial sazonal de <i>Holt-Winters</i> (SEHW).....	39
2.4.2.1 Suavização exponencial sazonal de <i>Holt-Winters</i> aditivo (SEHWA)	39
2.4.2.2 Suavização exponencial sazonal de <i>Holt-Winters</i> multiplicativo (SEHWM)	41
2.5 Metodologia de <i>Box-Jenkins</i> ou ARIMA.....	42
2.5.1 Função de auto correlação simples e função de auto-correlação parcial	45
2.5.2 Métodos estacionários	48
2.5.2.1 Modelo autorregressivo (AR)	48
2.5.2.2 Modelo de médias móveis (MA)	48
2.5.2.3 Modelo autorregressivo de médias móveis (ARMA).....	49
2.5.3 Métodos não estacionários	49
2.5.3.1 Modelo autorregressivo integrado de médias móveis (ARIMA).....	50
2.5.3.2 Modelo sazonal autorregressivo integrado de médias móveis (SARIMA).....	50

2.6 Critérios de avaliação	51
3 METODOLOGIA.....	53
3.1 Método da pesquisa	53
3.1.1 Dados históricos e a demanda analisada	54
3.1.2 Modelagem das séries temporais.....	54
3.1.3 Comparação dos métodos e seus resultados.....	55
3.2 Classificação de pesquisa	57
3.2.1 A pesquisa quanto aos objetivos.....	57
3.2.2 A pesquisa quanto à natureza da abordagem.....	57
3.2.3 A pesquisa quanto aos procedimentos técnicos	58
4 MODELAGEM E PREVISÃO DA DEMANDA.....	59
4.1 Série temporal da demanda de passageiros	59
4.2 Modelagem e previsão da série temporal	60
4.2.1 Modelagem e previsão utilizando o método de Médias Móveis	61
4.2.2 Modelagem e previsão utilizando o método de Suavização Exponencial.....	622
4.2.3 Modelagem e previsão utilizando o método de <i>Box-Jenkins</i>	64
4.3 Discussão dos resultados	67
5 CONCLUSÕES.....	70
REFERÊNCIAS	72

1 INTRODUÇÃO

Diariamente, todas as pessoas, entram em contato com operações de serviço. São clientes ou usuários de ampla variedade de serviços comerciais e públicos, como por exemplo, serviços de berçário, hospitais, lojas, estabelecimentos educacionais, empresas de entretenimento, serviços de polícia, restaurantes, televisão e internet. De fato, a sociedade é responsável pela prestação de serviços, não apenas como parte do próprio trabalho, em organizações como as citadas, mas também como parte da vida diária: servindo refeições, oferecendo serviços de táxi, organizando finais de semana, ou fornecendo serviços de apoio emocional a amigos e famílias (JOHNSTON; CLARK, 2010).

O planejamento das atividades operacionais de uma organização é um dos principais desafios enfrentados pelos gestores que atuam na prestação de serviços. Neste sentido, uma correta previsão de demanda é parte fundamental para um bom desempenho organizacional, uma vez que irá refletir diretamente nos resultados econômico-financeiros e mercadológicos alcançados. Por ser o serviço uma atividade que pressupõe a simultaneidade entre a produção e o consumo (utilização), ou seja, o serviço é produzido e consumido ao mesmo tempo, a organização das atividades precisa estar de acordo com uma boa previsão de demanda, para permitir que o custo operacional seja adequado ao nível de qualidade exigido pelo mercado e que possibilite lucro à empresa (FITZSIMMONS apud VERRUCK; BAMP; MILAN, 2009).

O sucesso no desenvolvimento de um planejamento e orientação estratégica da empresa está diretamente relacionado à capacidade de identificação e previsão de mudanças no ambiente de negócios, o que torna a ferramenta de previsão de demanda um ponto crítico na tomada de decisão gerencial. As empresas podem melhorar sua eficiência antecipando problemas e

desenvolver planos para responder a estes problemas (ARMSTRONG, apud FURTADO, 2007).

Previsões de demanda desempenham um importante papel em diversas áreas na gestão de organizações; por exemplo: na área financeira (no planejamento da necessidade de recursos), na área de recursos humanos (no planejamento de modificações no nível da força de trabalho) e na área de vendas (no agendamento de promoções). Tais previsões são também essenciais na operacionalização de diversos aspectos do gerenciamento da produção, como na gestão de estoques e no desenvolvimento de planos agregados de produção (PELLEGRINI; FOGLIATTO, 2001).

É justo esperar a mais alta precisão onde quer que exista uma relação de causa e efeito, o executivo deveria entender que previsões exatas são praticamente impossíveis de conseguir com as técnicas atualmente disponíveis, como o previsor deveria reconhecer que seus esforços se destinam mais a fornecer uma indicação, do que propriamente um veredito sobre as condições futuras (RIGGS, 1981).

1.1 Tema

O tema do estudo é a previsão de demanda, aplicada a uma empresa de serviços de transporte rodoviário, tomando como base os modelos de Média Móvel, Suavização Exponencial e *Box-Jenkins*, por meio de técnicas de séries temporais.

1.2 Problema de Pesquisa

A empresa do presente estudo, atua no mercado há 56 anos, e suas projeções e previsões, tanto para ampliação e investimentos, sempre foram qualitativas, se fazendo um trabalho de análise do histórico de vendas de passagens, e a partir de então, feito as projeções com base na experiência e visão de mercado da direção da empresa.

Com base na situação citada acima, apresenta-se o seguinte problema de pesquisa: Qual o método quantitativo para realizar a previsão de demanda, que melhor se encaixa em um dos serviços de transporte que a empresa oferta para a sociedade?

1.3 Objetivo geral

Este estudo tem por objetivo geral analisar qual a melhor técnica de previsão de séries temporais, para previsão de demanda de passageiros em empresa de transporte coletivo.

1.4 Objetivos específicos

Quanto aos principais objetivos desta monografia, citam-se:

- pesquisar na literatura sobre o tema previsão de demanda;
- pesquisar as principais técnicas de previsão de séries temporais e comparar os resultados da modelagem e previsão obtidos por cada técnica;
- prever a demanda de passageiros em linha de transporte coletivo para o segundo semestre de 2016 e comparar o resultado obtido com a demanda real;

1.5 Justificativa

Toda organização que já possui uma estrutura ajustada e com padrões a exercer frente ao mercado competitivo, deve ou possui uma área de planejamento, este planejamento vindo de diversas formas de dentro da empresa. Para tal existem formas de se planejar vendas, produção, estoque, investimentos, e todo recurso que a empresa toma por decisão mover capital e pessoal para tal. No caso a empresa em questão possui dados históricos de sua produção, que é o serviço de transportes, para tanto o estudo abordará a série histórica e tentará expor uma

previsão de demanda para o 1º semestre de 2016, fazendo a comparação e verificação dos dados obtidos.

Com a disponibilidade de dados históricos do produto ou serviço, pode-se gerar a previsão de diversas formas, considerando-se que os dados obtidos são uma série temporal, independente do seu tipo, e de variável única. Serão utilizados três métodos que buscam ter a melhor geração da previsão de demanda, com o intuito de analisar o melhor modelo a série temporal.

Além de dados históricos de vendas, uma boa previsão requer a manutenção de uma base de dados relevantes que ajudem a explicar o comportamento das vendas no passado, os erros cometidos nas previsões e a entender o efeito de determinadas ações sobre o mercado, entre outros. Se perguntado sobre o resultado efetivo de promoções, descontos de preço e outras ações, o pessoal de vendas normalmente é reticente em afirmar com certeza, porque, embora muitas dessas ações já tenham sido executadas, seus efeitos não foram devidamente analisados e documentados. O que a empresa sabe normalmente é o que está na memória de seus representantes. Para que a experiência do passado seja útil para o futuro, é preciso que essa experiência seja documentada para análise futura em situações semelhantes. O mesmo princípio vale para informações sobre o mercado, a concorrência, as decisões governamentais, etc. (CORRÊA; GIANESI; CAON, 2009).

Uma característica importante dos serviços é que não é possível ser estocado, e armazenado, ou seja, uma vez oferecido, se não utilizado, se transforma em perda de receita e/ou custo irreversível. Sendo assim, as previsões de demanda são indispensáveis não apenas para o planejamento e formulação das estratégias empresariais, como também estão intrinsecamente ligadas à própria sobrevivência da organização no mercado (GIANESI; CORRÊA, 1994).

Em operações que têm capacidades relativamente fixas como linhas aéreas e hotéis, é importante usar a capacidade da operação para gerar receitas com todo seu potencial. Uma abordagem usada por esse tipo de operações é chamada gestão de rendimento. Isto é realmente um conjunto de métodos, alguns dos quais, podem ser usados para assegurar que uma operação maximize seu potencial para gerar lucros. A gestão do rendimento é especialmente útil quando (SLACK; CHAMBERS; JOHNSTON, 2009):

- a capacidade é relativamente fixa;

- o mercado pode ser segmentado de forma bastante clara;
- o serviço não pode ser estocado de nenhuma forma;
- os serviços são vendidos antecipadamente;
- o custo marginal de realização de uma venda é relativamente baixo.

Os métodos de médias móveis serão analisados por serem de simples aplicação; a previsão se torna mais precisa quando se tem um número pequeno de observações; e a grande flexibilidade de acordo com o padrão comportamental da série. Serão utilizados os modelos de suavização exponencial, por terem uma grande popularidade e serem atribuídos à sua simplicidade, à eficiência computacional e à sua razoável precisão (MORETTIN; TOLOI, 2006). Já os métodos de *Box-Jenkins* serão utilizados por serem postulados como parcimoniosos (ponderados), pois contêm um número pequeno de parâmetros, se ajustam com séries não estacionárias e as previsões obtidas são bastante precisas, comparando-se favoravelmente com os demais métodos (MORETTIN; TOLOI, 2006).

1.6 Delimitação do trabalho

O tema a ser abordado é a análise especificamente de métodos estatísticos, e a análise de seus resultados.

Os dados são de uma empresa de transporte rodoviário do Vale do Taquari, sendo esta empresa, chamada de Empresa X, durante o trabalho, pois a abertura de informações de seus dados poderia lhe prejudicar. Mas no contexto geral o que interessa no estudo, são os dados do histórico de vendas do serviço de transporte. Sendo este serviço, a linha Lajeado - Porto Alegre, que tem viagens diárias, mas a demanda analisada será mensal, pois a empresa e todas as demais concorrentes têm o dever de prestar contas para o Departamento de Transportes do Rio Grande do Sul (DAER), sendo esta prestação de contas mensal.

1.7 Estrutura do trabalho

No Capítulo 1 é apresentado o tema, objetivos, justificativa, delimitação e estrutura da monografia.

No Capítulo 2 são apresentados os conceitos sobre previsão de demanda, e informações relativas a esta para atender a proposta de estudo, também são apresentados conceitos sobre séries temporais, e após os métodos de previsão escolhidos para análise.

No Capítulo 3 é apresentado o método de planejamento de pesquisa e sua classificação, também é demonstrado cronograma de atividades para o estudo.

No Capítulo 4 é apresentada a série temporal, e as modelagens de cada método, tomando a sequência por complexidade de cada método, Médias Móveis, Suavização Exponencial e *Box-Jenkins*. Após realizadas as modelagens são apresentados seus respectivos resultados.

No Capítulo 5 é apresentado a conclusão do estudo, e suas principais ponderações, tomando como base o objetivo do estudo. E por fim, apresentado sugestões de futuras pesquisas.

2 REFERENCIAL TEÓRICO

No capítulo 2, são apresentados os principais conceitos referentes à previsão de demanda; também são apresentados conceitos sobre séries temporais, cujos métodos serão a base de estudo. Na sequência da apresentação dos conceitos serão apresentados três métodos e suas variações para previsão de demanda utilizando séries temporais, estacionárias ou não estacionárias.

2.1 Serviços de transporte rodoviário

Para Johnston e Clark (2010), o conceito de serviço é o modo como a organização pretende ter seus serviços percebidos por seus clientes, funcionários, acionistas e financeiros; em outras palavras o conceito de serviço é a proposição do negócio.

Com o aumento da prestação de serviços, algo que de certa forma, pode surpreender o empresário ou gerente do negócio, por ser algo intangível, a previsão de quanto se vai produzir ou prestar o serviço deve ser estimada de alguma maneira. Esta estimativa, através de uma previsão de demanda, aliado a uma ferramenta computacional seria o ideal para todo prestador de serviço, independente da sua magnitude empresarial (KOTLER, 2000). É em função disto que o presente trabalho está disposto a pesquisar dentro do setor de serviços de transportes rodoviários.

Além disso, Gianesi e Corrêa (1994) citam fatores que estão relacionados ao aumento da demanda de serviços. São eles: (i) desejo de melhor qualidade de vida das pessoas (consumidores); (ii) ampliação da urbanização, que torna necessários alguns serviços tais como educação, transporte e segurança; (iii) mudanças demográficas; (iv) mudanças socioeconômicas, como é o caso do aumento da participação da mulher no mercado de trabalho; e (v) mudanças tecnológicas de uma forma geral.

Um ramo de serviços em que essa relação fica bastante evidente é no setor de transportes públicos, em especial o transporte coletivo urbano. Os desafios para os gestores desta área, está em encontrar o equilíbrio entre a oferta do serviço e a sua demanda real. Esse equilíbrio é um ponto crítico, uma vez que uma oferta de serviço menor do que a demanda além de levar à insatisfação do usuário, irá incentivá-lo a buscar formas alternativas de transporte. Por outro lado, uma oferta superior à demanda, pode se reverter em custos elevados, onerando o sistema ou, até mesmo inviabilizando-o (VERRUCK; BAMPI; MILAN, 2009).

O transporte rodoviário de passageiros, no Brasil, é um serviço público essencial. O grau de importância deste setor pode ser avaliado ao se observar que este é o meio de transporte principal na movimentação coletiva de pessoas no território nacional. A dinâmica desse setor tem incentivado para que seja adotada uma sistemática ágil de planejamento dos serviços a serem oferecidos aos usuários. Nesse contexto, a geração de estimativas do volume de movimentações, é um dos aspectos mais importantes a ser considerado no planejamento de novos serviços (GONÇALVES; BEZ; NOVAES, 2007).

A demanda real por transporte de ônibus, em geral, não pode ser inferida diretamente do volume de passageiros transportados, pois parte dessa demanda pode utilizar outra modalidade de transporte ou, simplesmente, não viajar, em decorrência das características da oferta disponível (frequência, tarifa, conforto, etc.) ou de suas próprias preferências (GONÇALVES; BEZ; NOVAES, 2007).

Visto as características e definições de serviço, principalmente no ramo de transportes, a próxima seção apresenta o conceito de previsão de demanda e sua essencialidade dentro de organizações.

2.2 Previsão de demanda

Uma previsão de demanda é o ato de predizer eventos futuros, se utilizando de dados históricos e sua projeção para o futuro, de fatores subjetivos ou intuitivos, ou ambos combinados. Sendo necessária para auxiliar na determinação de que recursos são necessários, da programação dos recursos existentes e da aquisição de recursos adicionais. Podendo os métodos de previsão se basear em modelos matemáticos que usam os dados históricos disponíveis, em métodos qualitativos que aproveitam a experiência gerencial ou em uma combinação de ambos (RITZMAN; KRAJEWSKI, 2004).

Ter a capacidade de satisfazer a demanda atual e futura é uma responsabilidade da administração da produção. Um equilíbrio adequado entre capacidade e demanda pode gerar altos lucros e clientes satisfeitos, enquanto que não existe este equilíbrio, pode ser potencialmente desastroso (SLACK; CHAMBERS; JOHNSTON, 2009).

Realizar previsões de demanda é importante no auxílio da determinação dos recursos necessários para a empresa. Em tempos de abertura de mercados, essa atividade torna-se imprescindível. Os mercados alcançados pela empresa, assim como a concorrência que a disputa, mudam continuamente, exigindo novas previsões de demanda em períodos mais curtos (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, apud WERNER; RIBEIRO, 2003).

Tomar como base o desempenho passado de um produto para elaborar estimativas sobre a atividade futura é ainda um dos métodos de previsão mais utilizados e mais seguros, possuindo também a vantagem de ser quantificável e objetivo. No entanto este método não é perfeito, dando origem a informações inexatas quando as condições econômicas prevalecentes na época deixam de existir. O bom senso se faz necessário para qualquer método de previsão (RIGGS, 1981). Ainda mais no período de instabilidade econômica que se vivencia, tanto nacional, quanto internacional, a mais precisa previsão tomando como base valores passados, podem vir a não se confirmar em virtude de oscilações na economia.

Previsões de demanda não são isentas de erros. Quanto mais distantes no tempo, menor a acurácia da previsão. Deve-se cuidar, não só na coleta das informações, mas também na escolha da metodologia a ser utilizada, estabelecendo uma prática para identificar, dentre os métodos já propostos, o mais adequado ao caso (BALLOU, 2005).

Ritzman e Krajewski (2004) apontam que o desafio de prever a demanda dos clientes encontra-se na raiz da maioria das decisões empresariais. É uma tarefa complexa, porque a demanda por bens e serviços pode variar de maneira expressiva. Por exemplo, a demanda por fertilizantes para gramados aumenta previsivelmente nos meses de primavera e verão; no entanto, os fins de semana específicos em que a demanda cresce podem depender de fatores incontrolláveis, como o clima. Algumas vezes os padrões são mais previsíveis. Desse modo, a demanda semanal por cortes de cabelo em uma barbearia local pode ser razoavelmente estável de semana a semana, com a demanda diária mais intensa aos sábados de manhã e menos intensa às segundas-feiras e terças-feiras. Prever a demanda nessas situações requer descobrir os padrões em que se baseiam as informações disponíveis.

2.2.1 Etapas da metodologia de previsão de demanda

Uma análise de previsão de demanda, é realizada em várias etapas e possui vários componentes. Cada etapa e cada componente requerem uma atenção especial para que se possa obter um produto final melhor, isto é, uma previsão mais confiável (RIGGS, 1981).

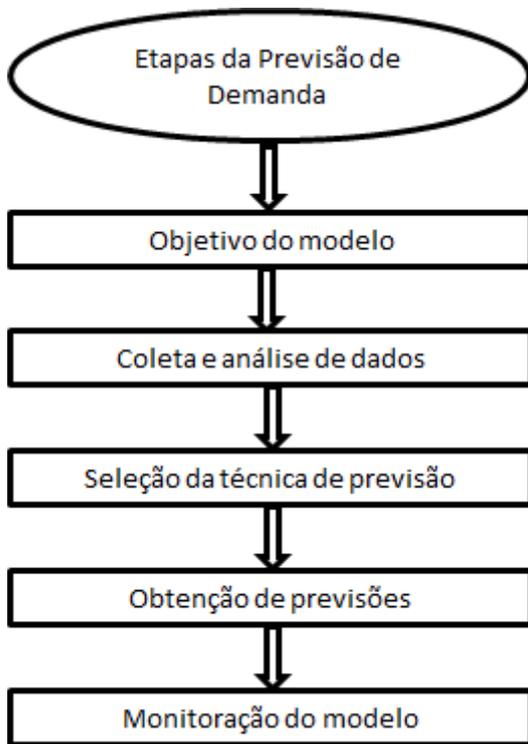
Como cita Tubino (2000), apesar do poder da matemática e do poder dos recursos dos computadores, é impossível prever com exatidão as demandas de produtos e serviços novas variáveis surgem a cada momento. No entanto, podem-se prever valores aproximados quando a matemática se une à experiência pessoal do planejador.

A elaboração de um sistema de previsão requer, de uma organização, conhecimento e habilidade em quatro áreas básicas: *(i)* identificação e definição dos problemas a serem tratados na previsão de demanda; *(ii)* aplicação dos métodos de previsão; *(iii)* procedimentos para seleção do método apropriado a situações específicas; e *(iv)* suporte organizacional para adaptar e usar os métodos de previsão requeridos (PELLEGRINI; FOGLIATTO, 2001).

A aplicabilidade de um sistema de previsão de demanda depende de três condições: *(i)* disponibilidade de informações históricas; *(ii)* possibilidade da transformação das informações históricas em dados numéricos; e, *(iii)* suposição da repetição de padrões observados em dados passados no tempo futuro (PELLEGRINI; FOGLIATTO, 2001).

No que se refere às etapas da metodologia de previsão de demanda, pode-se tomar como base a Figura 1, fluxograma que compõe os passos para fazer uma previsão de demanda.

Figura 1 – Etapas de previsão de demanda



Fonte: Adaptado pelo autor com base em Martins e Laugeni (2003).

As etapas de um modelo de previsão, segundo Tubino (2000), são basicamente cinco: por primeiro é definido o objetivo do modelo, que é a base para a coleta e análise de dados, após seleciona-se a técnica de previsão mais apropriada, em seguida é calculada a previsão da demanda, e por fim, se monitora e atualiza os parâmetros empregados com base nos erros de previsão. Na definição do objetivo do modelo, se determina, qual o produto ou família de produtos que está se realizando a previsão, e qual a necessidade da precisão da previsão, baseado nos recursos disponíveis.

Iniciando-se pelo objetivo do modelo, definindo a razão pela qual há necessidade de previsões, que produto ou grupo de produtos, que grau de precisão e detalhamento será trabalhado (CASTRO; NETTO, 2013). Diversos fatores devem ser analisados nesta etapa: como e onde a previsão será usada, e como se enquadra dentro da organização. A definição do

nível de detalhe é influenciada por diversos fatores, tais como disponibilidade de dados, acurácia, custo da análise e preferências gerenciais (PELLEGRINI; FOGLIATTO, 2001).

A segunda etapa consiste na coleta e análise dos dados, com o objetivo de identificar e desenvolver a técnica de previsão que melhor se ajuste à situação. Tendo em vista que quanto mais dados coletados melhor será a confiabilidade técnica (CASTRO; NETTO, 2013).

Após esses passos, seleciona-se a técnica que mais se adapta à situação desejada. Este passo é muito importante, pois na escolha da técnica aumenta-se o grau de acerto das previsões. Em seguida, com as informações coletadas, se escolhe o método mais aplicável à situação da empresa, levando em conta a tecnologia, se a entidade tem condições de utilizar pacotes computacionais complexos; o prazo a serem feitas previsões, para curto ou longo prazo e a viabilidade econômica (CASTRO; NETTO, 2013).

Na etapa de obtenção de previsões, os dados históricos são agrupados e representados graficamente. Desta maneira, podem-se identificar possíveis valores espúrios na série temporal, o que dificultaria a sua modelagem. Valores ilegítimos podem ser causados por erros de digitação, falta de produtos, promoções esporádicas e variações no mercado financeiro, entre outras causas (PELLEGRINI; FOGLIATTO, 2001).

A última etapa consiste em monitorar o modelo quanto aos erros estabelecidos, se os erros são satisfatórios, ou seja, validando o modelo. Se não, o modelo terá que ser revisado e serão feitos novos testes com outras técnicas em previsões futuras. (CASTRO; NETTO, 2013). Neste ponto, o processo de implantação de previsão é considerado concluído, tendo início o seu processo de manutenção (PELLEGRINI; FOGLIATTO, 2001).

Visto as etapas de previsão de demanda e diante da proposta de estudo que se apresenta a presente monografia, que é análise de métodos de previsão para a escolha da melhor técnica entre diversas disponíveis, neste capítulo será aprofundada e demonstrada a etapa da seleção da técnica de previsão, cujo encontra-se na Seção 2.2.2.

2.2.2 Seleção da técnica de previsão de demanda

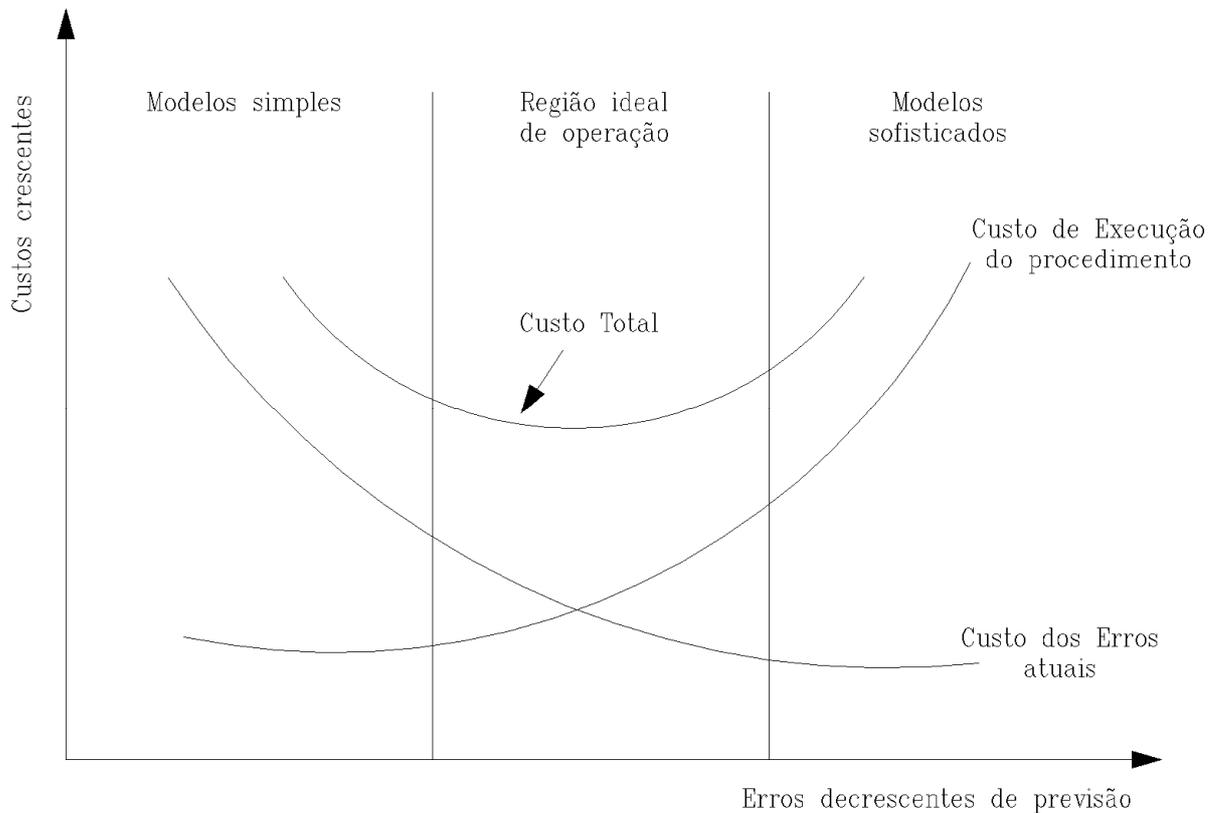
Dessa forma, a escolha do melhor método para previsão, depende dos seguintes fatores (MONTGOMERY; JOHNSON; GARDINER, apud FURTADO, 2007):

- forma requerida de previsão;
- período, horizonte e intervalo de previsão;
- disponibilidade de dados;
- acurácia requerida;
- padrões de demanda;
- custo de desenvolvimento, instalação e operação;
- facilidade de operação;
- compreensão e cooperação da administração.

O nível ótimo de previsão é quando o custo de execução de um método de previsão compensa exatamente o custo de operação, decorrente de se trabalhar com uma previsão inferior ou inadequada. À medida que a atividade de previsão aumenta, os custos para o agrupamento e análise de dados aumentam, assim como os custos de controle do sistema. Por outro lado, as previsões de qualidades inferiores podem resultar em custos não previstos de mão-de-obra, matéria-prima e de capital, assim como custos de expedição e perda de rendimentos (MONKS, 1987).

É importante observar, que o aumento da precisão da previsão, conseqüentemente, eleva seu custo. Em contrapartida, os custos relacionados às incertezas geradas pelo erro do modelo diminuem. Assim, percebe-se a existência de um ponto ótimo onde os custos totais de incerteza e implantação do método são reduzidos, no qual, na Figura 2 é apresentado a relação de custos em relação a previsão de demanda, otimizando a seleção da técnica de previsão.

Figura 2 – Componentes do custo em relação à previsão de demanda



Fonte: Feliciano (2009).

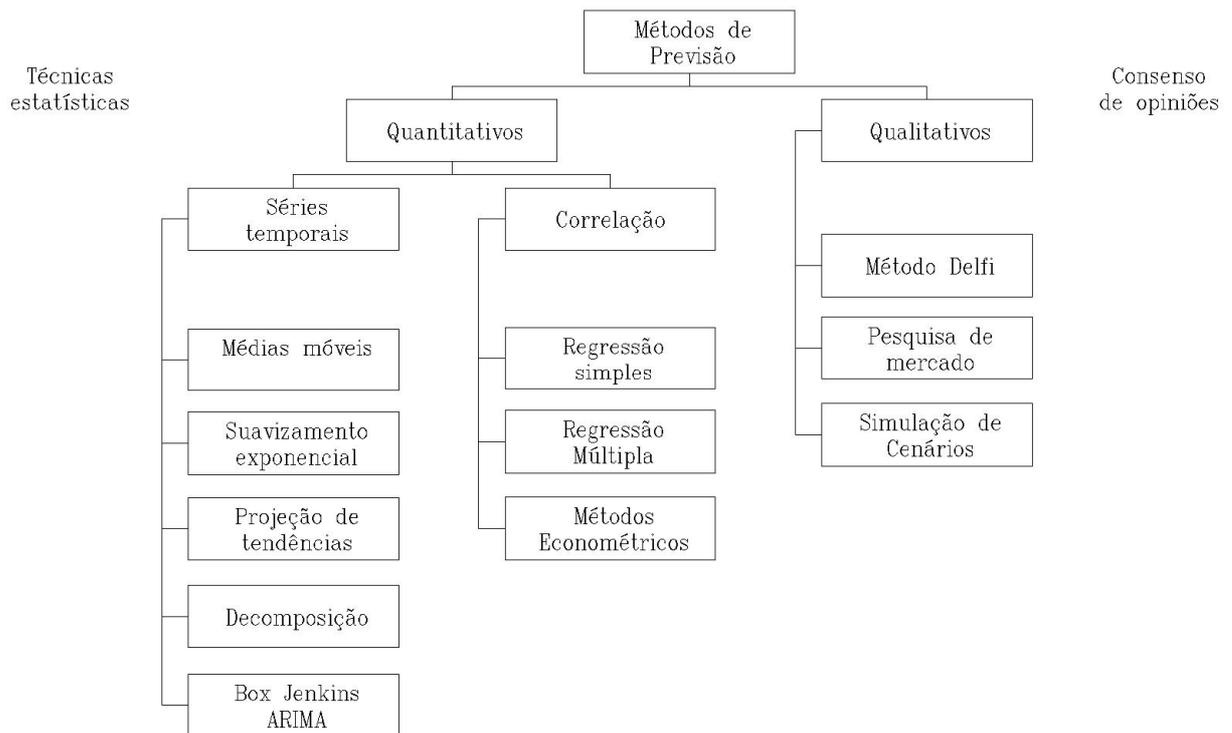
A previsão de curto prazo talvez seja a atividade mais complexa no controle de produção, para obter alta precisão de resposta. Em contrapartida, horizontes de planejamento maiores trazem respostas mais vagas e maiores erros de previsão. Existem alguns métodos que são bastante elaborados e que exigem conhecimento matemático considerável, enquanto outros são menos elaborados. Não existe unanimidade sobre qual o melhor método (FELICIANO, 2009).

A seleção do método mais apropriado não é uma tarefa simples. É preciso procurar o equilíbrio entre o custo de aplicação e o valor dos resultados. Estudos preliminares não exigem análises detalhadas, mas os empreendimentos maiores requerem o emprego de métodos tão exatos quanto possível (RIGGS, 1981).

2.2.3 Técnicas de previsão de demanda

Segundo Slack, Chambers e Johnston (2009), os modelos e as técnicas de previsão podem ser classificados em termos de objetividade e subjetividade, e relações causais e não causais. As técnicas objetivas utilizam procedimentos específicos e sistemáticos, já as subjetivas envolvem aspectos como percepção e julgamento pessoal baseado em experiências. Já as técnicas não causais se utilizam de valores passados de uma variável para prever seus valores futuros, ao passo que as técnicas causais fazem previsões através de equações que mostram a relação causa-efeito.

Figura 3 – Métodos e técnicas de previsão



Fonte: Adaptado pelo autor com base em Lustosa et al. (2008).

Dois tipos gerais de técnicas de previsão são adotados para projetar a demanda: métodos qualitativos e métodos quantitativos. Os métodos qualitativos incluem o método de julgamento, que traduz as opiniões dos gerentes, especialistas, pesquisas de consumidores e estimativas da equipe de vendas em estimativas quantitativas. Os métodos quantitativos incluem o método causal e a análise da série temporal. O método causal usa dados históricos para as variáveis

independentes, como campanhas promocionais, condições econômicas e ações dos concorrentes, a fim de prever a demanda (RITZMAN; KRAJEWSKI, 2004). Na Figura 3 são demonstrados alguns métodos de previsão de demanda fazendo a diferenciação entre seus respectivos tipos.

Em um estudo quantitativo o pesquisador conduz seu trabalho a partir de um plano estabelecido, com hipóteses claramente especificadas e variáveis operacionalmente definidas. Busca a precisão, evitando distorções na etapa de análise e interpretação dos dados, garantindo assim uma margem de segurança em relação às interferências obtidas (GODOY, 1995).

Em característico, modelos quantitativos são resultados de um processo, descritos em linguagem matemática e computacional, que utilizam técnicas analíticas (matemáticas, estatísticas) e experimentais (simulação) para cálculo de valores numéricos das propriedades do sistema tratado, podendo ser usados para analisar os resultados de diferentes ações possíveis no sistema. Modelos quantitativos compreendem um conjunto de variáveis que podem variar em um domínio específico e variáveis de desempenho que inferem a qualidade das decisões obtidas a partir de relações causais e quantitativas entre essas variáveis (MIGUEL, 2012). No Quadro 1 é apresentado os modelos de séries temporais e algumas características.

Quadro 1 – Seleção de métodos quantitativos para previsão de demanda

Método de previsão	Quantidade de dados históricos	Padrão dos Dados	Horizonte de Previsão	Tempo de Preparação	Experiência do Pessoal
Média móvel simples	2 a 10 observações	Os dados devem ser estacionários	Curto	Curto	Pouca sofisticação
Média móvel ponderada	10 a 15 observações	Tendência	Curto para médio	Curto	Ligeira sofisticação
Suavização Exponencial	Pelo menos 4 a 5 observações por temporada	Tendência	Curto para médio	Curto	Sofisticação moderada
Análise de regressão	10 observações por variável	Consegue lidar com diferentes padrões	Curto, médio ou longo	Médio	Sofisticação considerável
Técnica de <i>Box-Jenkins</i>	50 ou mais observações	Precisa ser estacionário ou transformado em estacionário	Curto, médio ou longo	Longo	Alta sofisticação

Fonte: Adaptado pelo autor com base em Jacobs, Chase e Aquilano (2006).

A previsão de média móvel exponencial ponderada não é mostrada nesta tabela, mas teria as mesmas características que a média móvel ponderada. A média móvel ponderada pode

ser mais engenhosa se a pessoa que estiver fazendo a previsão incluir a sazonalidade ou outras influências cíclicas. Observe que os modelos variam de simples para complexos. Termos como curto, médio ou longo são relativos ao contexto no qual são utilizados. No entanto, na previsão de negócios curto prazo geralmente se refere a menos de três meses; médio prazo, de três meses a dois anos; e longo prazo, mais do que dois anos. No geral, modelos de curto prazo compensam pela variação aleatória e se ajustam às mudanças em curto prazo (como as respostas dos consumidores a um novo produto). As previsões de médio prazo são úteis aos efeitos sazonais, e os modelos de longo prazo detectam as tendências gerais e são especialmente úteis na identificação dos principais pontos (JACOBS; CHASE; AQUILANO, 2006).

Existe um método mais adequado para a previsão, dado um horizonte de planejamento? A resposta pode ser positiva, guardadas algumas cautelas. Na verdade, seja a previsão de longo prazo (2 a 10 anos), médio prazo (1 a 2 anos) ou curto prazo (até um ano), o melhor método é aquele que fornece os valores mais próximos entre a previsão e a demanda real. Do ponto de vista estritamente teórico, seria difícil defender um ou outro método. Qualquer que seja o caso, porém, é necessário o teste de vários métodos até se encontrar o mais adequado ao caso específico que se está analisando (MOREIRA, 2008).

As medidas de erros de previsão proporcionam informações importantes para escolher o melhor método de previsão para um produto ou serviço. Elas também orientam os gerentes na seleção dos melhores valores para os parâmetros necessários para o método. Os critérios a serem adotados para a escolha do método de previsão e do parâmetro incluem: (1) minimizar o viés, (2) minimizar o MAP ou o MAPE, (3) atender às expectativas gerenciais de mudanças nos componentes da demanda e (4) minimizar o último período do erro de previsão. Os dois primeiros relacionam-se a medidas estatísticas baseadas no desempenho histórico, o terceiro reflete as expectativas do futuro que podem não estar baseadas no passado e o quarto é um meio de usar o método que aparentemente está apresentando melhor resultado na ocasião em que uma previsão tiver de ser feita (RITZMAN; KRAJEWSKI, 2004).

Os métodos apresentados são baseados em dados históricos. Prevalece a hipótese implícita de que “o futuro é uma continuação do passado”. Caso isso não ocorra, outras metodologias de previsão devem ser utilizadas (MARTINS; LAUGENI, 2003).

A presente seção demonstrou as principais técnicas de previsão de demanda, visto estas, a Seção 2.2.4 apresenta o conceito de séries temporais, e suas principais técnicas e características.

2.2.4 Séries temporais

Uma série temporal é uma sequência de observações da demanda ao longo do tempo. Em geral, as observações são espaçadas igualmente (dias, semanas, meses, trimestres, anos, etc.). Não se irá associar a demanda a qualquer outra variável da qual supostamente possa depender; a hipótese básica no uso de séries temporais é de que os valores futuros das séries podem ser estimados com base nos valores passados (MOREIRA, 2008).

Uma das suposições mais frequentes que se faz a respeito de uma série temporal é a de que ela é estacionária, ou seja, varia no tempo aleatoriamente ao redor de uma média constante, apresentando alguma forma de equilíbrio estável (MORETTIN; TOLOI, 2006). O fato essencial sobre análise de séries temporais é de que o conjunto de observações sucessivas é dependente e se deve levar em conta a ordem delas. Quando a série temporal pode ser prevista exatamente, denomina-se determinística. A maioria das séries é não determinística ou aleatória. Para séries aleatórias, previsões exatas são impossíveis e essa deve ser substituída, admitindo que futuros valores têm uma distribuição de probabilidades condicionada pelo conhecimento de valores observados no passado (CORDEIRO, 2002).

Os procedimentos de previsão utilizados dentro de organizações variam muito, podendo ser simples e intuitivos ou mais quantitativos e complexos (MORETTIN; TOLOI, 2006). No Quadro 2 é demonstrada as técnicas e formas de utilização de alguns dos modelos disponíveis dentro de séries temporais.

Os métodos aplicados a séries temporais se utilizam de informações históricas que dizem respeito somente à variável dependente. Esses métodos baseiam-se na hipótese de que o padrão anterior da variável dependente continuará no futuro. A análise de séries temporais identifica os padrões básicos da demanda que se combina para indicar um padrão histórico de variável dependente, desenvolvendo, então, um modelo para repeti-lo (RITZMAN; KRAJEWSKI, 2004).

Quadro 2 – Técnicas de previsão de séries temporais

Técnicas de previsão de séries temporais	Características dos modelos
Média móvel simples	Pondera-se um período de tempo contendo um número de pontos dividindo a soma dos valores dos pontos pelo número dos pontos. Cada um deles, tem influência igual.
Média móvel ponderada	Pontos específicos podem ser ponderados mais ou menos do que outros, como parecerem adequados pela experiência.
Suavização Exponencial	Pontos recentes são ponderados mais ou menos do que outros, declinando exponencialmente à medida que outros dados se tornam mais antigos.
Análise de regressão	Adapta uma linha reta aos dados passados, geralmente relacionando os valores de dados no tempo. A técnica de adaptação mais comum é a de mínimos quadrados.
Técnica de <i>Box-Jenkins</i>	Muito complicada, mas aparentemente a técnica estatística mais precisa disponível. Relaciona uma classe de modelos estatísticos aos dados e adapta o modelo à série temporal.
Projeções de Tendência	Adapta uma linha de tendência matemática aos pontos e a projeta no futuro.

Fonte: Jacobs, Chase e Aquilano (2006).

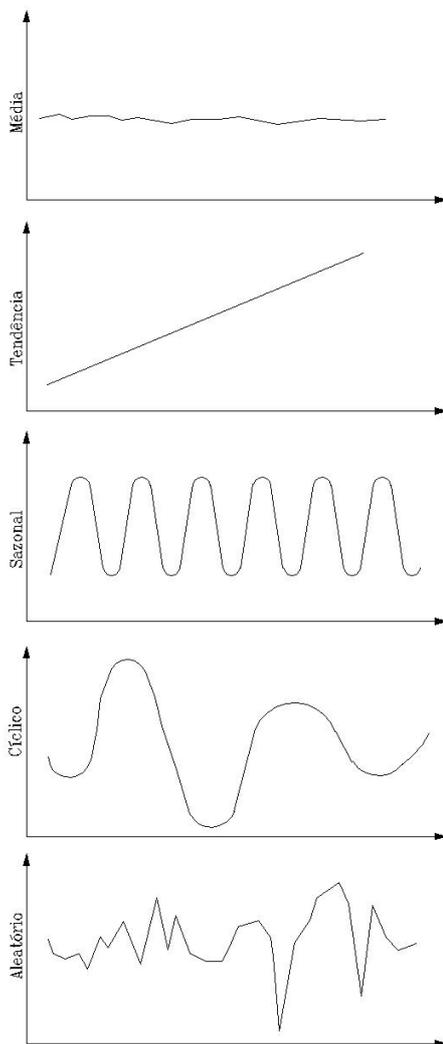
Ritzman e Krajewski (2004) também listam as observações repetidas da demanda de um produto ou serviço, que em sua ordem de ocorrência formam um padrão. Os cinco padrões básicos da maioria das séries temporais de demanda são:

1. horizontal ou média: flutuação dos dados em torno de uma média constante;
2. tendência: aumento ou diminuição na média das séries ao longo do tempo;
3. sazonal: um padrão repetido de aumentos ou diminuições da demanda, dependendo da hora do dia, da semana, do mês ou da estação;
4. cíclico: aumentos ou diminuições graduais da demanda menos previsíveis em períodos mais longos de tempo (anos ou décadas);
5. aleatório: variação da demanda que não pode ser prevista.

Na Figura 4 são demonstrados 5 padrões básicos da maioria das séries temporais de demanda, cujos os quatro primeiros combinam-se em vários graus para definir o padrão de tempo fundamental para um produto ou serviço. E o padrão aleatório resulta do acaso, não podendo ser previsto.

A tendência em uma série temporal é um aumento ou uma redução sistemática na média da série ao longo do tempo (RITZMAN; KRAJEWSKI, 2004). Linhas de tendência são os pontos de partida comuns no desenvolvimento de uma previsão. Essas linhas de tendência são ajustadas para os efeitos sazonais, os elementos cíclicos e quaisquer outros eventos inesperados que possam influenciar a previsão final (JACOBS; CHASE, 2009).

Figura 4 – Padrões básicos das séries temporais



Fonte: Adaptado pelo autor com base em Jacobs, Chase e Aquilano (2006).

Os padrões sazonais são alterações regularmente repetitivas para cima ou para baixo nas medidas da demanda em intervalos inferiores a um ano (horas, dias, semanas, meses ou trimestres). Nesse contexto, os intervalos de tempo são denominados período sazonal (RITZMAN; KRAJEWSKI, 2004).

Jacobs e Chase (2009) constam que os fatores cíclicos são mais difíceis de determinar porque o período de tempo pode ser desconhecido ou a causa do ciclo pode não ser considerada. A influência cíclica na demanda poderá vir de ocorrências como eleições, guerra, condições econômicas ou pressões sociológicas.

As variações aleatórias são causadas por eventualidades. Estatisticamente, quando todas as conhecidas da demanda (média, tendência, sazonalidade, cíclicas e de auto correlação) são subtraídas da demanda total, o que resta é a porção não explicada da demanda. Caso não se consiga identificar a causa deste restante, presume-se que este seja um evento puramente aleatório (JACOS; CHASE, 2009).

Depois de realizada pesquisa sobre previsão de demanda e séries temporais, nos capítulos anteriores. Nos próximos subcapítulos se inicia o estudo e demonstração dos modelos de previsão escolhidos para este estudo.

2.3 Método de médias móveis

O conjunto de modelos que estamos denominando genericamente de métodos das médias possui algumas peculiaridades dignas de nota (MOREIRA, 2008):

a) a previsão é sempre obtida pela média que leva em conta valores reais anteriores da demanda;

b) ao contrário do que acontece com as regressões, só se pode prever um período a frente, ainda que seja possível realizar adaptações para se obter um maior número de previsões futuras;

c) as médias móveis, o que significa que, a cada nova previsão, são abandonadas (ou mais fracamente ponderados) os valores mais antigos da demanda real e incorporados os novos.

Os métodos a serem analisados em separados na sequência são: (i) método de média móvel simples, (ii) método de média móvel ponderada e, (iii) método de média móvel exponencial ponderada.

2.3.1 Média móvel simples (MMS)

O método da média móvel simples é empregado para estimar a média de uma série temporal de demanda, sendo assim, eliminando os efeitos da flutuação aleatória. Ele é de grande utilidade quando a demanda não possui influências sazonais ou tendência acentuadas. A aplicação de um modelo de média móvel envolve simplesmente calcular a demanda média para os n períodos de tempo mais recentes e adotá-la como a previsão para o próximo período de tempo. Para o período a seguir, após a demanda ser conhecida, a demanda mais antiga obtida da média anterior é substituída pela demanda mais recente e a média é recalculada. Desse modo, as n demandas mais recentes, e a média ‘move-se’ de período a período (RITZMAN; KRAJEWSKI, 2004).

$$F_t = \frac{A_{t-1} + A_{t-2} + A_{t-3} \dots + A_{t-n}}{n} \quad (1)$$

Onde:

F_t = Previsão para o período vindouro

n = Número de períodos da média

A_{t-1} = Ocorrência real no período passado

$A_{t-2}, A_{t-3}, A_{t-n}$ = Ocorrências reais de dois períodos passados, três períodos passados, e assim por diante até n períodos atrás.

Para Jacobs, Chase e Aquilano (2006), é importante selecionar o melhor período para a média móvel, pois existem efeitos conflitantes dentro da série temporal. Quanto mais longo for o período da média móvel, mais os elementos aleatórios serão suavizados (o que pode ser desejável em muitos casos). Mas, se houver uma tendência nos dados – seja aumentando ou diminuindo – a média móvel tem a característica adversa de retardamento da tendência. Assim sendo, embora um período mais curto produza mais oscilações, há um seguimento mais próximo da tendência. Inversamente, um tempo mais longo proporciona uma resposta mais suavizada, mais retarda a tendência.

Como regra geral, a média móvel simples pode ser um método eficiente quando a demanda é estacionária, ou seja, quando ela varia em torno de um valor médio. Para demandas crescentes ou decrescentes ao longo do tempo, a tendência é que a previsão fornecida pela MMS esteja sempre atrasada em relação aos valores reais. Assim, se a demanda é crescente, as previsões darão valores cada vez menores em relação aos valores reais. Além disso, o método não é muito eficiente para acompanhar as variações sazonais, podendo mesmo acobertá-las quase que completamente (MOREIRA, 2008). Há dois inconvenientes da abordagem de previsão por média móvel. Primeiro, em sua forma básica, atribui peso igual a todos os n períodos prévios usados nos cálculos (embora isso possa ser resolvido atribuindo pesos diferentes a cada um dos n períodos). Segundo, e mais importante, não se utiliza de dados fora dos n períodos com os quais é calculada a média móvel. Esses dois problemas são resolvidos por suavização exponencial, que também é mais fácil de calcular (SLACK; CHAMBERS; JOHNSTON, 2009).

2.3.2 Média móvel ponderada (MMP)

A média móvel ponderada tem em comum com a MMS a característica de observar n valores reais anteriores da demanda para a composição média. Diferente da MMS, os valores recebem pesos diferentes, geralmente apresentando maior importância dada aos valores mais recentes da demanda. A vantagem da MMP sobre a MMS é que os valores mais recentes da série histórica, que podem revelar alguma tendência, recebem uma importância maior (MOREIRA, 2008).

A fórmula para cálculo da média móvel ponderada é dada na Equação 2 (JACOBS; CHASE, 2009):

$$F_t = w_1 A_{t-1} + w_2 A_{t-2} + \dots + w_n A_{t-n} \quad (2)$$

Onde:

w_1 = Peso a ser atribuído à ocorrência real para o período $t-1$;

w_2 = Peso a ser atribuído à ocorrência real para o período $t-2$;

w_n = Peso a ser atribuído à ocorrência real para o período $t-n$;

n = Número total de períodos da previsão.

Como regra geral, o passado mais recente é o indicador mais importante do que se esperar no futuro e, portanto, deve receber pesos mais altos. A receita do mês passado ou a capacidade da fábrica, por exemplo, seria uma estimativa melhor para o mês vindouro do que a receita ou a capacidade fabril de vários meses atrás (JACOBS; CHASE, 2009).

2.3.3 Média móvel exponencial ponderada simples (MMEP)

O modelo da média móvel exponencialmente ponderada é mais sofisticado e também mais utilizado que os anteriores. Tal como na MMS e na MMP, a previsão tem capacidade de um período imediatamente à frente. Há adaptações possíveis, para se realizar a previsão mais períodos a frente (MOREIRA, 2008).

O método da suavização exponencial é um método sofisticado de média móvel ponderada que calcula a média de uma série temporal atribuindo às demandas recentes maior peso do que às demandas iniciais. É o método formal de previsão mais frequentemente utilizado, por causa de sua simplicidade de uso e do menor número de dados necessários para apoiá-lo. Diferentemente do método da média móvel ponderada, que requer n períodos de demanda passada e n pesos, a suavização exponencial requer somente três tipos de dados: a previsão do último período, a demanda para esse período e um parâmetro de aproximação alfa (α), que tem um valor entre 0 e 1,0. Para obter uma previsão com suavização exponencial, simplesmente calculamos a média ponderada da demanda mais recente e a previsão obtida no último período. A equação para uma única previsão por suavização exponencial é (RITZMAN; KRAJEWSKI, 2004):

$$F_t = F_{t-1} + \alpha(A_{t-1} - F_{t-1}) \quad (3)$$

Onde:

F_t = A previsão exponencialmente suavizada para o período t ;

F_{t-1} = A previsão exponencialmente suavizada feita para o período anterior;

A_{t-1} = A demanda real no período anterior;

α = O coeficiente de resposta almeja ou constante de suavização.

O motivo de ser chamada de média ponderada exponencial é que cada incremento no passado é diminuído por $(1-\alpha)$, exemplificado pelo Quadro 3. Se α é 0,05, por exemplo, os pesos para os vários períodos seriam: (α é definido abaixo) (JACOBS; CHASE; AQUILANO, 2006):

Quadro 3 – Ponderação de alfa

	Ponderando em $\alpha = 0,05$
Ponderada mais recente = $\alpha(1-\alpha)^0$	0,0500
Dados de um período anterior = $\alpha(1-\alpha)^1$	0,0475
Dados de dois períodos anteriores = $\alpha(1-\alpha)^2$	0,0451
Dados de três períodos anteriores = $\alpha(1-\alpha)^3$	0,0429

Fonte: Jacobs e Chase (2009).

As técnicas da média móvel exponencial tornaram-se bem aceitas por seis razões (JACOBS; CHASE; AQUILANO, 2006): (i) os métodos exponenciais são surpreendentemente precisos; (ii) a formulação de um modelo exponencial é relativamente fácil; (iii) o usuário consegue entender como o modelo funciona; (iv) é preciso pouca computação para usar o modelo; (v) as necessidades de armazenamento em computadores são pequenas pelo seu limite de dados históricos; e, (vi) os testes de precisão, para saber quão bem o modelo está se saindo, são fáceis de implementar.

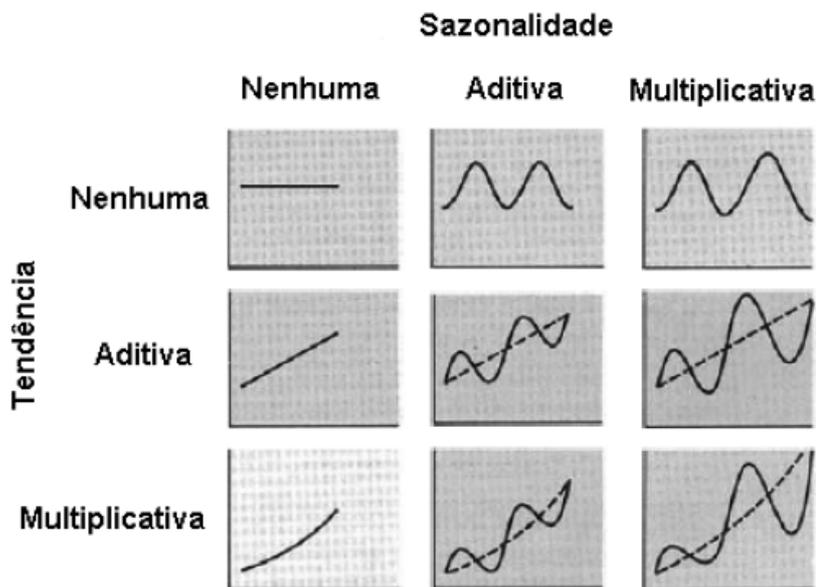
2.4 Suavização exponencial (SE)

Uma classe de métodos de previsão, que busca tratar as causas de flutuações em séries temporais, é a das suavizações. Técnicas específicas desse tipo assumem que os valores extremos da série representam a aleatoriedade e, assim, por meio da suavização desses extremos, pode-se identificar os padrões básicos (MORETTIN; TOLOI, 2006).

Nos subcapítulos 2.4.1, e 2.4.2, serão apresentados dois métodos utilizados em suavização exponencial. A suavização exponencial de Holt (SEH), a qual modela a tendência da série; e suavização exponencial sazonal de *Holt-Winters* (SEHW), no qual existem dois tipos de procedimentos cuja utilização depende das características da série considerada, série sazonal multiplicativa e série sazonal aditiva; que são baseadas em três equações com constantes de suavização diferentes, que são relacionadas a uma das componentes do padrão da série: nível, tendência e sazonalidade (MORETTIN; TOLOI, 2006).

A primeira coluna da Figura 5 ilustra a forma gráfica de um fenômeno sem tendência ou com tendência (aditiva ou multiplicativa). A primeira linha da mesma figura ilustra a forma gráfica de um fenômeno sem sazonalidade ou com sazonalidade (aditiva ou multiplicativa). As nove combinações possíveis por tipo de tendência e sazonalidade são ilustradas a seguir (FELICIANO, 2009).

Figura 5 – Tipo de tendência e sazonalidade



Fonte: Feliciano (2009).

Para Feliciano, (2009) a sazonalidade aditiva trata amplitudes (picos) de séries históricas aproximadamente constantes ao longo do tempo. A sazonalidade é multiplicativa se a magnitude da sazonalidade aumenta de forma proporcional com o nível médio da série de

tempo. O tipo de tendência é difícil de se avaliar e, em muitos casos, não é esperado que determinado tipo de tendência persista.

Quando os padrões de tendência e sazonalidade não são significantes, se utiliza da suavização exponencial simples (BALLOU, 2005). Caso contrário, aplica-se o Modelo de Holt a séries não sazonais e com tendência e o Modelo de *Holt-Winters* aditivo para séries sazonais, e modelo multiplicativo séries sazonais e com tendência (AFONSO; FILHO; NOVAES, 2011).

2.4.1 Suavização exponencial de Holt (SEH)

O método de suavização exponencial simples, pelo método de médias, demonstrado no capítulo anterior, apresenta tendência linear positiva (ou negativa), fornece previsões que subestimam (ou superestimam) continuamente os valores reais. Para controlar este erro sistemático, um dos métodos aplicáveis é a SEH. Esse método é similar; a diferença é que em vez de suavizar só o nível, ele utiliza uma nova constante de suavização para modelar a tendência da série (MORETTIN; TOLOI, 2006).

$$L_t = \alpha + (1 - \alpha)(L_{t-1} + T_{t-1}) \quad (4)$$

$$T_t = \beta (L_t - L_{t-1}) + (1 - \beta) T_{t-1} \quad (5)$$

$$\hat{y}_{t+k} = L_t + kT_t \quad (6)$$

Onde:

L_t = a componente de nível;

T_t = a componente de tendência;

L_{t-1} = estimador do nível da série para o período $t - 1$;

T_{t-1} = estimador da tendência da série para o período $t - 1$;

\hat{y}_{t+k} = a previsão realizada no período t ;

k = número de períodos a serem considerado na análise;

α = a constante de suavização da componente de nível (Lt), onde $0 \leq \alpha \leq 1$;

β = a constante de suavização da componente de tendência (Tt); onde $0 \leq \alpha \leq 1$.

2.4.2 Suavização exponencial sazonal de *Holt-Winters* (SEHW)

Os modelos de *Holt-Winters* descrevem melhor aqueles dados em que se pode notar a existência de uma tendência linear, além de componente de sazonalidade (PELLEGRINI; FOGLIATTO, 2001). Técnicas de suavização oferecem uma forma de remover ou pelo menos reduzir flutuações de curto prazo voláteis de uma série temporal. Isso pode ser útil, pois muitas vezes é mais fácil diferenciar tendências e padrões cíclicos e analisar visualmente uma série suavizada. O ajustamento sazonal é uma forma especial de suavização: ele remove as oscilações sazonais da série, em vez das flutuações irregulares de curto prazo (PINDYCK; RUBINFELD, 2004).

As vantagens são semelhantes ao método de Holt, sendo que os métodos de *Holt-Winters* são adequados à análise de séries com padrão de comportamento mais geral. As desvantagens são as dificuldades em encontrar os valores mais apropriados das constantes de suavização e a impossibilidade e/ou dificuldade de estudar as propriedades estatísticas, tais como média e variância de previsão e, conseqüentemente, construção de um intervalo de confiança (MORETTIN; TOLOI, 2006).

2.4.2.1 Suavização exponencial sazonal de *Holt-Winters* aditivo (SEHWA)

O método de previsão *Holt-Winters* aditivo: é indicado para situações nas quais as amplitudes da variação sazonal se mantem constante, ou seja, a diferença entre o maior e o menor ponto na série histórica permanece constante com o passar do tempo (SEYBOTH et al., 2015).

A série sazonal aditiva é expressa pelas seguintes equações:

$$L_t = \alpha(y_t - S_{t-s}) + (1 - \alpha)(L_{t-1} + T_{t-1}) \quad (7)$$

$$T_t = \beta(L_t - L_{t-1}) + (1 - \beta)T_{t-1} \quad (8)$$

$$S_t = \gamma(y_t - L_t) + (1 - \gamma)S_{t-s} \quad (9)$$

$$\hat{y}_{t+k} = L_t + kT_t + S_{t-s+k} \quad (10)$$

Onde:

L_t = a componente de nível;

T_t = a componente de tendência;

S_t = a componente de sazonalidade;

L_{t-1} = estimador do nível da série para o período $t - 1$;

T_{t-1} = estimador da tendência da série para o período $t - 1$;

S_{t-s} = estimador da sazonalidade da série para o período $t - s$;

S_{t-s+k} = estimador da sazonalidade da série para o período $t - s + k$;

\hat{y}_{t+k} = a previsão realizada no período t ;

y_t = valor observado na série temporal para o período t ;

k = número de períodos a serem considerado na análise;

α = a constante de suavização da componente de nível (L_t), onde $0 \leq \alpha \leq 1$;

β = a constante de suavização da componente de tendência (T_t); onde $0 \leq \alpha \leq 1$;

γ = a constante de suavização da componente de sazonalidade (S_t), onde $0 \leq \alpha \leq 1$.

2.4.2.2 Suavização exponencial sazonal de *Holt-Winters* multiplicativo (SEHWM)

O método de previsão *Holt-Winters* multiplicativo é utilizado para situações em que a amplitude da variação sazonal é crescente com o tempo, ou seja, a diferença entre o maior e o menor ponto de demanda nos ciclos aumenta com o passar do tempo (SEYBOTH et al., 2015).

A série sazonal multiplicativa é expressa pelas seguintes equações:

$$L_t = \alpha \left(\frac{y_t}{S_{t-s}} \right) + (1 - \alpha)(L_{t-1} + T_{t-1}) \quad (11)$$

$$T_t = \beta (L_t - L_{t-1}) + (1 - \beta) T_{t-1} \quad (12)$$

$$S_t = \gamma \left(\frac{Z_t}{L_t} \right) + (1 - \gamma)S_{t-s} \quad (13)$$

$$\hat{y}_{t+k} = (L_t + kT_t)S_{t-s+k} \quad (14)$$

Onde os seguintes símbolos são válidos para todas as equações de *Holt-Winters*:

L_t = a componente de nível;

T_t = a componente de tendência;

S_t = a componente de sazonalidade;

L_{t-1} = estimador do nível da série para o período $t - 1$;

T_{t-1} = estimador da tendência da série para o período $t - 1$;

S_{t-s} = estimador da sazonalidade da série para o período $t - s$;

S_{t-s+k} = estimador da sazonalidade da série para o período $t - s + k$;

\hat{y}_{t+k} = a previsão realizada no período t ;

y_t = valor observado na série temporal para o período t ;

k = número de períodos a serem considerado na análise;

α = a constante de suavização da componente de nível (Lt), onde $0 \leq \alpha \leq 1$;

β = a constante de suavização da componente de tendência (Tt); onde $0 \leq \alpha \leq 1$;

γ = a constante de suavização da componente de sazonalidade (St), onde $0 \leq \alpha \leq 1$.

2.5 Metodologia de *Box-Jenkins* ou ARIMA

A abordagem *Box-Jenkins* é uma das metodologias mais usadas para a análise de dados em séries de tempo. Ela é popular em consequência de sua generalidade; ela pode lidar com qualquer série, estacionária ou não, com ou sem elementos sazonais, e tem programas de computador bem documentados. Talvez seja o último fator que contribua mais para a sua popularidade. Embora *Box-Jenkins* não sejam nem os percursores nem os colaboradores mais importantes no campo dos modelos de previsão, eles popularizaram esses métodos e os tornaram acessíveis (MADDALA, 2003).

Os modelos de *Box-Jenkins*, genericamente conhecidos por *Auto Regressive Integrated Moving Averages* (ARIMA) e na literatura em português por Autorregressivos Integrados de Médias Móveis, são modelos matemáticos que visam encontrar o comportamento da correlação seriada ou auto correlação entre os valores da série temporal, e tomando como base esse comportamento realizar previsões futuras. Se essa estrutura de correlação for bem modelada, os resultados serão com boas previsões (CONSUL; WERNER, 2010).

A relação temporal estudada por *Box-Jenkins* é representada formalmente por um conjunto de processos estocásticos, por envolverem apenas uma série de tempo, sendo classificados como modelos uni variados (VASCONCELLOS; ALVES, 2000). Estes modelos capturam a correlação em séries ou a auto correlação que existe entre os valores da série temporal analisada e, fundamentado neste comportamento, obtém previsões do futuro. Para que gere boas previsões, a estrutura de correlação deve ser bem modelada (WERNER; RIBEIRO, 2003).

Os modelos propostos por *Box-Jenkins* (ARIMA) são modelos matemáticos construídos por meio de um processo iterativo, que tem o objetivo de identificar o comportamento do auto

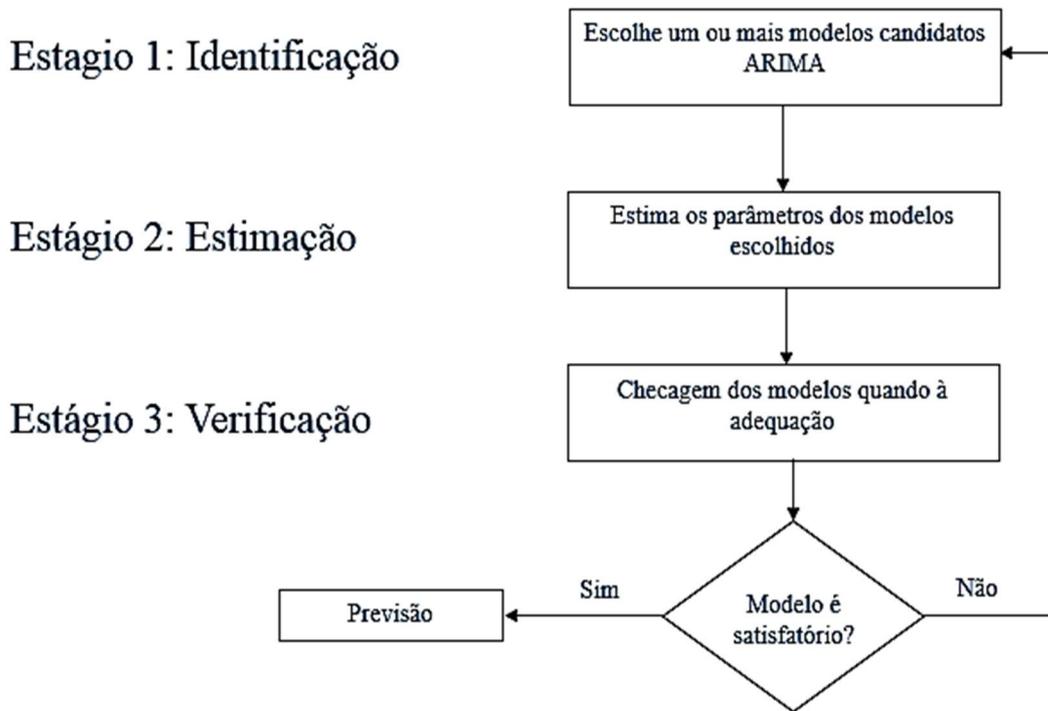
correlação entre os valores da série temporal (BALLOU, 2005). Parte-se da ideia que os valores da série temporal são dependentes (PELLEGRINI; FOGLIATTO, 2001). Através da combinação de termos de autor regressão (AR), integração (I) e médias móveis (MA), o método procura encontrar modelos capazes de representar a série temporal, possibilitando, previsões adequadas em relação aos próximos valores da sequência (CONSUL; WERNER, 2010). Os modelos autorregressivos são expressos como uma soma finita de valores ponderados prévios da série, enquanto que os modelos de média móvel fazem a regressão dos valores utilizando os erros passados. Por vezes, a utilização somente de termos autorregressivos ou de média móvel não é suficiente para encontrar o modelo mais adequado. Assim, se faz necessária a inclusão de ambos no modelo a ser analisado. Caso o modelo proposto não seja adequado, é possível repetir o ciclo, iniciando novamente a fase de identificação, até se identificar o modelo que melhor se ajusta aos dados da série (MORETTIN; TOLOI, 2006). Obtido a modelagem ideal, se pode iniciar a realização de previsões (WERNER; RIBEIRO, 2003).

Segundo Fava (2000), os modelos ARIMA são resultantes da combinação de três componentes denominados “filtros”: o componente autorregressivo (AR), o filtro de integração (I) e o componente de médias móveis (MA). Uma série pode ser modelada pelos três filtros ou apenas um subconjunto deles, resultando em vários modelos abordados.

Segundo Morettin e Tolo (2006), a construção dos modelos *Box-Jenkins* é um ciclo iterativo, no qual a escolha do modelo é realizada com base nos próprios dados.

Box-Jenkins apud OLIVEIRA (2012), formalizam a teoria da utilização de componentes autorregressivos e de médias móveis na modelagem de séries temporais se utilizando de duas concepções básicas na criação de sua metodologia de construção de modelos: a parcimônia sendo, a utilização do menor número possível de parâmetros para se obter uma representação adequada do fenômeno em estudo e a iteratividade, que é a informação empírica sendo analisada teoricamente e o resultado deste estágio é confrontado com a prática sucessiva vezes, até que o modelo obtido seja satisfatório.

A determinação do modelo para a metodologia de *Box-Jenkins*, seguiu os seguintes passos, onde, na Figura 6, apresenta-se o fluxograma do ciclo iterativo de *Box-Jenkins*:

Figura 6 – Metodologia de *Box-Jenkins*

Fonte: Girardi, Camargo e Motta (2013).

Identificação: analisam-se a FAC e FACP, e se tenta identificar o modelo (SANTANA, 2012). Consiste em descobrir qual das versões dos modelos de *Box-Jenkins*, sejam sazonais ou não, descrevem o comportamento da série. A identificação do modelo ocorre pelo comportamento das FAC e das FACP (MORETTIN; TOLOI, 2006).

Estimação: os modelos ajustados são comparados utilizando alguns critérios, como o da parcimônia. Uma das formas de melhorar o grau de ajustamento desse modelo aos dados da série temporal é incluir defasagens adicionais nos processos AR (p), MA (q), ARMA (p,q) e ARIMA (p,d,q), ou seja, os parâmetros ϕ se houver um componente autorregressivo, os parâmetros θ se houver o filtro de médias móveis e a variância do ruído branco σ^2 (SANTANA, 2012; VASCONCELLOS; ALVES, 2000).

Verificação: avaliação se o modelo estimado é adequado para descrever o comportamento dos dados (MORETTIN; TOLOI, 2006).

É importante avaliar se o modelo estimado é adequado para descrever o comportamento dos dados. Caso o modelo não seja ideal, o ciclo é repetido, voltando para a fase de identificação

(GIRARDI; CAMARGO; MOTTA, 2013).

As funções de auto correlação (FAC) e auto correlação parcial (FACP) são funções necessárias para verificar se uma série temporal é estacionária ou não, e também, para a determinar a ordem dos modelos de *Box-Jenkins*. Para séries temporais estacionárias, ambos os coeficientes FAC e FACP tendem a zero, enquanto que as séries não estacionárias possuem coeficientes diferentes de zero para diversos períodos de tempo da série temporal (BOX; JENKINS; REINSEL, apud GIRARDI; CAMARGO; MOTTA, 2013). O que será visto no próximo subcapítulo deste item.

Visto características e suas respectivas etapas da metodologia de *Box-Jenkins*, as próximas seções fazem o detalhamento das etapas, considerando sua aplicação a série temporal.

2.5.1 Função de auto correlação simples e função de auto correlação parcial

A auto correlação é uma medida de dependência entre observações da mesma série separadas por um específico intervalo chamado retardo (SANTANA, 2012).

Para identificar um modelo, são empregadas as FAC e FACP estimadas a partir da amostra disponível. Através da comparação gráfica e visual destas funções com os comportamentos esperados teóricos, se obtém uma conclusão sobre a ordem do modelo a ser utilizado. Ressalta-se que, como requisito indispensável para o traçado das funções FAC e FACP, se tenha a condição de estacionária da série. Em outras palavras, a determinação dos gráficos FAC e FACP deve ser feita sobre séries cujos momentos estatísticos (média e variância) sejam invariantes no tempo. Por tanto, a série histórica de dados precisa passar por uma análise prévia e, se for o caso, por transformações numéricas para torná-las estacionárias (DETZEL et al., 2011).

Primeiramente se faz a preparação dos dados para atingir a estacionariedade, Makridakis et al. *apud* BALTAR (2009), sugere a utilização dos seguintes procedimentos: projeção dos dados em gráficos para verificar a existência de algum padrão; ajustes como deflacionar ou logaritimizá-los, estabilizando a variância; usar a FAC e FACP para verificar a existência de algum padrão nos dados da série, apresentado pelo Quadro 4; diferenciação dos dados para obter

estacionariedade; examinar os FAC e FACP para identificar potenciais modelos, podendo ter ajuda de *softwares* especialistas.

Quadro 4 – Comportamento de FAC e FACP nos modelos AR, MA, ARMA

	AR	MA	ARMA
Comportamento FAC	Decai exponencialmente	Corte brusco após a defasagem q	Decai exponencialmente após a defasagem q
Comportamento FACP	Corte brusco após a defasagem p	Decai exponencialmente	Decai exponencialmente após a defasagem p

Fonte: Vasconcellos e Alves (2000).

Dada uma série y_t , como se sabe se ela foi gerada por um processo AR, MA, ARMA ou ARIMA? Se for um modelo AR, qual o valor de p , ou seja, qual a ordem do modelo? Se for um ARIMA, qual o valor de p , de d e de q ? Enfim o processo de identificação consiste em estimar quais dos filtros AR, MA, ARMA compõem o processo gerador da série, bom como quais são suas respectivas ordens (VASCONCELLOS; ALVES, 2000).

O coeficiente de auto correlação ou correlação serial de ordem k , ou seja, a relação entre y_t e y_{t-k} é dado por:

$$\rho_K = \frac{Cov(y_t, y_{t-k})}{V(y_t)} = \frac{\gamma_k}{\gamma_0} \quad (15)$$

O coeficiente de auto correlação ρ_K geralmente envolve parâmetros desconhecidos. Na prática, é necessário trabalhar com o coeficiente de auto correlação “amostral” r_K expresso por (VASCONCELOS; ALVES, 2000):

$$r_k = \frac{\sum_{t=k+1}^n (y_t - \bar{y})(y_{t-k} - \bar{y})}{\sum_{t=1}^n (y_t - \bar{y})^2} \quad (16)$$

Onde n é o número de observações da série y_t .

Também existe a possibilidade de testar se os k primeiros coeficientes de auto correlação são conjuntamente iguais a zero. Nesse caso, utiliza-se o teste *Ljung-Box* (TLB) cuja estatística é dada por (VASCONCELOS; ALVES, 2000):

$$Q(K) = n(n+2) \sum_{k=1}^K \frac{r_k^2}{n-k} \quad (17)$$

$Q(K)$ tem distribuição χ^2 com K graus de liberdade. Se $Q(K) > \chi_k^2$, rejeita-se a hipótese de que os K primeiros coeficientes de auto correlação são nulos.

O coeficiente de FACP de ordem k , usualmente representado por ϕ_{kk} , mede a correlação entre y_t e y_{t-k} depois que a influência de $y_{t-1}, y_{t-2}, \dots, y_{t-k+1}$ sobre y_t foi descontada (VASCONCELOS; ALVES, 2000).

O coeficiente de $\phi_{jj}, j=1,2,\dots$, é dado pelo último coeficiente, β_{jj} , de cada uma das auto regressões a seguir:

$$y_t = \beta_{11}y_{t-1} + \varepsilon_t \rightarrow \phi_{11} = \beta_{11} \quad (18)$$

$$y_t = \beta_{11}y_{t-1} + \beta_{22}y_{t-2} + \varepsilon_t \rightarrow \phi_{22} = \beta_{22} \quad (19)$$

$$y_t = \beta_{k1}y_{t-1} + \beta_{k2}y_{t-2} + \dots + \beta_{kk}y_{t-k} + \varepsilon_t \rightarrow \phi_{kk} = \beta_{kk} \quad (20)$$

Os valores de ϕ_{jj} podem ser obtidos a partir da solução do sistema de equações de Yule-Walker para sucessivos valores de j :

$$\rho_1 = \phi_1 + \phi_2\rho_1 + \dots + \phi_k\rho_{k-1} \quad (21)$$

$$\rho_2 = \phi_1\rho_1 + \phi_2 + \dots + \phi_k\rho_{k-2} \rightarrow \phi_{jj} = \phi_j, j = 1, 2, \dots \quad (22)$$

$$\rho_k = \phi_1\rho_{k-1} + \phi_2\rho_{k-2} + \dots + \phi_k \quad (23)$$

A sequência de pares (j, ϕ_{jj}) constitui a FACP.

2.5.2 Métodos estacionários

Modelos estacionários são processos que apresentam equilíbrio ao longo do tempo. Um processo é considerado fracamente estacionário se sua média e variância se mantêm constantes ao longo do tempo e a função de auto covariância depende apenas da defasagem entre os instantes de tempo. Um processo é fortemente estacionário se todos os momentos conjuntos são invariantes a translações no tempo (WERNER; RIBEIRO, 2003).

2.5.2.1 Modelo autorregressivo (AR)

Em um modelo autorregressivo, a série de dados históricos y_t é descrita por seus valores passados regredidos e pelo seu ruído aleatório ε_t (WERNER; RIBEIRO, 2003). A versão mais simples de um modelo AR é o modelo em que y_t depende somente de y_{t-p} e de ε_t . Diz-se, nesse caso, que o modelo é autorregressivo de ordem p , o que se indica compactamente por AR (p). A representação algébrica desse modelo é a seguinte (VASCONCELLOS; ALVES, 2000):

$$y_t = \phi y_{t-p} + \varepsilon_t \quad (24)$$

Onde ϕ é um parâmetro e $E(\varepsilon_t) = 0$; $E(\varepsilon_t^2) = \sigma^2$; $E(\varepsilon_t \varepsilon_s) = 0$ para $t \neq s$

Se tratando de um modelo fracamente estacionário, a variância de y_t (γ_0) deve ser constante e as autocovariâncias (γ_k) devem ser independentes de t .

2.5.2.2 Modelo de médias móveis (MA)

Em um modelo de médias móveis (do inglês *moving average*), a série y_t resulta da combinação dos ruídos brancos ε_t do período atual com aqueles ocorridos em períodos anteriores. Assim, um modelo de médias móveis de ordem MA (q) é dado por (WERNER; RIBEIRO, 2003; VASCONCELLOS; ALVES, 2000):

$$y_t = \varepsilon_t - \theta\varepsilon_{t-q} \quad (25)$$

Onde θ é um parâmetro.

2.5.2.3 Modelo autorregressivo de médias móveis (ARMA)

Em alguns casos, se faz necessário utilizar um grande número de parâmetros em modelos puramente AR ou puramente MA. Nesses casos, se torna vantajoso misturar os componentes de um modelo AR com os componentes de um modelo MA, gerando assim, um modelo ARMA. O modelo exigirá um número menor de termos, sendo a combinação dos dois anteriores: y_t é descrito por seus valores passados e pelos choques aleatórios corrente e passados. O modelo ARMA (p,q) , dado pela equação 26, é a especificação mais simples que um processo dessa natureza pode apresentar (WERNER; RIBEIRO, 2003; VASCONCELLOS, ALVES, 2000):

$$y_t = \theta y_{t-p} + \varepsilon_t - \theta\varepsilon_{t-q} \quad (26)$$

2.5.3 Métodos não estacionários

Assim como a maioria dos métodos de análise estatística de séries de tempos supõe que esta seja estacionária, será necessário transformá-las caso ainda não sejam. Segundo Morettin e Tolo (2006), a transformação mais comum consiste em tomar diferenças sucessivas da série original até obter uma série estacionária (WERNER; RIBEIRO, 2003).

Por exemplo, se y_t é não estacionária, mas $x_t = \Delta y_t = y_t - y_{t-p}$ é estacionária, y_t é dita integrada de ordem p . Se y_t precisar de duas diferenças para ser estacionarizada, ou seja, se $z_t = \Delta^2 y_t = \Delta(\Delta y_t) = \Delta(y_t - y_{t-p})$ é estacionária, então y_t é integrada de ordem 2 (VASCONCELLOS; ALVES, 2000).

2.5.3.1 Modelo autorregressivo integrado de médias móveis (ARIMA)

O modelo aplicado a séries não estacionárias homogêneas pode ser genericamente formulado da seguinte maneira: se y_t tornar-se estacionária após a aplicação de d diferenças e a série resultante for representada por um modelo ARMA (p,q) , diz-se que y_t é descrita por um modelo ARIMA (p,d,q) representado por (VASCONCELLOS; ALVES, 2000):

$$w_t = \phi w_{t-p} + \dots + \phi_p w_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-d} - \dots - \theta_q \varepsilon_{t-q} \quad (27)$$

Onde $w_t = \Delta^2 y_t$.

Alternativamente, utilizando o operador de defasagem, tem-se:

$$(1 - B)^d \phi(B) y_t = \theta(B) \varepsilon_t \quad (28)$$

Nesse caso, $(p - B)^d \phi(b) = 0$ apresenta d raízes sobre o círculo unitário (d raízes unitárias) e p raízes fora do círculo unitário.

2.5.3.2 Modelo sazonal autorregressivo integrado de médias móveis (SARIMA)

Quando a periodicidade da série é inferior a um ano (séries mensais e trimestrais, por exemplo), outro tipo de correlação serial passa a ter importância: a correlação entre os instantes de tempo distantes entre si por s ou múltiplos de s , onde s é o número de observações contidas em um ano. Um exemplo disso é a série mensal de vendas no varejo. Essa série costuma apresentar um grande pico nos meses de dezembro, em decorrência do Natal. Assim, a correlação entre as vendas de dezembro nos vários anos deve ser alta e, provavelmente, maior do que a correlação entre vendas de novembro e dezembro do mesmo ano (VASCONCELLOS; ALVES, 2000):

O modelo sazonal apresentado a seguir considera as observações consecutivas correlacionadas. A incorporação, a esses modelos, da correlação entre instantes de tempo sucessivos redundando no modelo sazonal multiplicativo geral denominado SARIMA $(p,d,q) \times (P,D,Q)_s$, cuja equação é (VASCONCELLOS; ALVES, 2000):

$$\phi(B)\phi(B^s)\Delta^d\Delta_s^D y_t = \theta(B)\theta(B^s)\varepsilon_t \quad (29)$$

A combinação sob a forma multiplicativa é a mais utilizada embora outras formas sejam possíveis (VASCONCELLOS; ALVES, 2000).

Após a demonstração dos modelos a serem utilizados no presente estudo, a Seção 2.6 apresenta os critérios de avaliação que serão utilizados para verificação dos resultados dos modelos.

2.6 Critérios de avaliação

O emprego do modelo a ser utilizado na previsão de valores futuros depende principalmente do comportamento da série temporal a que se analisa. É necessário que seja feita a soma dos erros gerados por cada modelo e, conseqüentemente, a escolha do melhor modelo de acordo como menor erro; onde z_t são os valores reais e \hat{z}_t os valores previstos. Para isso, utilizam-se diferentes formas de cálculo como critérios de escolha (PELLEGRINI; FOGLIATTO, 2001).

A importância de vários critérios de avaliação de métodos de previsão foi comparada usando a pesquisa de Mentzer e Kahn (1995), com 186 respondentes e o estudo atualizado em 2006, com 86 respondentes, os critérios mais utilizados para avaliação de métodos de previsão são o MAPE, mostrado na equação 31, e o MAE mostrado na equação 30, que obtiveram na primeira pesquisa (1995) cerca de 75% dos votos e na segunda pesquisa cerca de 65% dos votos (2006) (FELICIANO, 2009), dos quais estes serão nossa base de indicadores para as metodologias em estudo.

$$MAE = \frac{1}{n} \sum_{t=1}^n |e_t| \quad (30)$$

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{e_t}{z_t} \times 100 \right| \quad (31)$$

Onde:

n = o número de medidas;

e = a diferença entre a previsão de demanda e o valor real de cada período; e

z = a demanda real do período.

t = o período de tempo analisado.

Os indicadores citados acima, serão utilizados e apresentados no ajustamento e previsão da demanda, para fins de análise de cada modelo específico. Sendo considerado o indicador de previsão para validação do resultado do método.

O capítulo 2 apresentou o referencial teórico e o desenvolvimento para o estudo. Ele está dividido em cinco assuntos principais e suas variações, que são: (i) previsão de demanda; (ii) séries temporais; (iii) método de médias móveis; (iv) métodos de suavização exponencial; e, (v) métodos ARIMA e suas variações. No capítulo 3 é apresentada a metodologia de pesquisa para a realização do estudo, sendo que o Capítulo 3 está dividido em duas seções: a seção 3.1, que apresenta o planejamento do método; e a seção 3.2, que apresenta a classificação do estudo segundo as regras de metodologia da pesquisa.

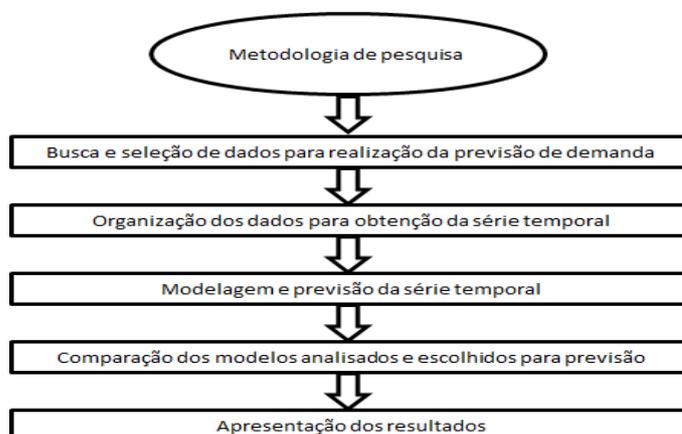
3 METODOLOGIA

No presente capítulo é apresentado de que forma foi conduzida a pesquisa e que procedimento foi adotado para obtenção do comparativo dos métodos apresentados no Capítulo 2. Para isto, o Capítulo 3 está dividido em duas seções: (i) a seção 3.1, que apresenta o método utilizado; e, (ii) a seção 3.2, que aborda a classificação da presente pesquisa.

3.1 Método da pesquisa

Nesta seção é apresentada a metodologia da pesquisa, apresentada pela Figura 7, onde é exposto a forma de como o estudo é conduzido, de maneira geral pode-se ordenar de tal forma:

Figura 7 – Metodologia da pesquisa



Fonte: Elaborado pelo autor (2016).

3.1.1 Dados históricos e a demanda analisada

Os dados para realização do presente estudo foram coletados de uma empresa do ramo de serviços, sendo esta de transporte rodoviário. Esta empresa possui anos de tradição no ramo de atividade que atua, e sendo uma das mais tradicionais e lembradas, quando se fala de transporte no Rio Grande do Sul.

Todas as atividades da Empresa X, e de qualquer empresa de transporte no RS, são controladas pelo DAER (Departamento Autônomo de Estradas de Rodagem), sendo que o DAER exige mensalmente um relatório onde são repassados os números dos serviços executados em todas as linhas que exercem atividade. Portanto, históricos de qualquer que seja a linha prestadora de serviço, se têm acesso ao seu banco de dados, que é armazenado na empresa por forma de sistema operacional. Sendo assim, a demanda analisada já está tabulada e organizada para análise.

A decisão de se analisar a Linha 449 – Porto Alegre – Lajeado, foi feita por a empresa perceber que este serviço se encontra em queda de atividade, que segundo a empresa, todos os outros serviços também apresentam quedas ao longo do tempo, por motivos políticos e econômicos. Por esta razão almeja-se comprovar que realmente esta atividade está em queda.

3.1.2 Modelagem das séries temporais

Conforme apresentado no capítulo 2, as séries temporais serão trabalhadas conforme método particular de cada técnica de previsão de demanda, nem sempre havendo a utilização de toda a série temporal, mas trabalhando com a metodologia que o método propõe.

Para análise do método de médias móveis, foram utilizados os modelos de MMS, MMP, MMEP. O primeiro modelo não necessita de ponderação de valores, ou algum trabalho com a série temporal, somente aplicação a sua respectiva equação, e o segundo e terceiro modelo é necessário a ponderação dos valores de *alfa*, *gama* e *beta*, quando necessário, e fazendo sua ponderação através de *softwares* que auxiliam no melhor valor para respectiva série.

No método de suavização exponencial foram utilizadas suas variantes: SEH, SEHWA e SEHWM. E seguiu-se cronograma do modelo, estimados os parâmetros de cada modelo, após foram modelados cada um dos componentes da série (nível, tendência e sazonalidade), e obtido a modelagem de cada série temporal.

Para o método ARIMA, se constitui no teste de estacionariedade, no caso o teste de *Ljung-Box*, conforme resultado se procede a diferenciação ou não da série temporal. Para séries que apresentam não estacionariedade se realiza tantas diferenças quanto necessárias para que a série atinja a condição estacionária. Na sequência, com base na FAC e FACP, identificam-se modelos para a modelagem da série. E por fim verificado os resíduos da série aplicada ao modelo.

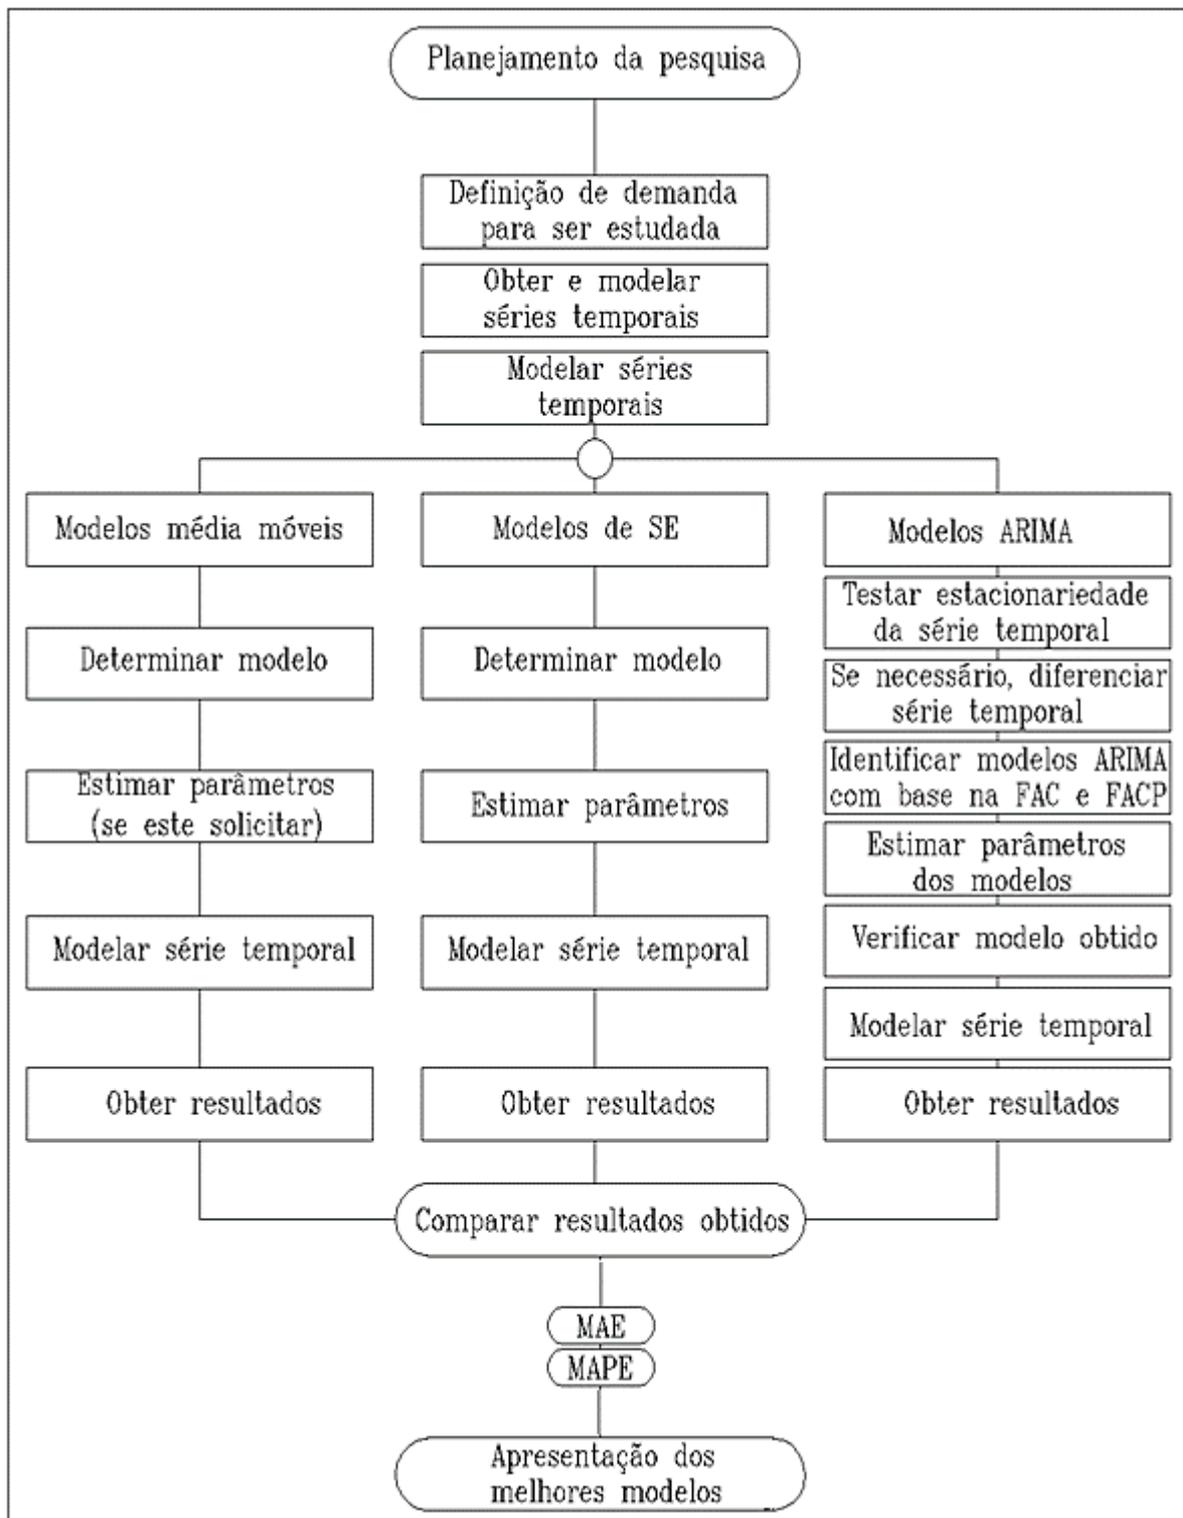
3.1.3 Comparação dos métodos e seus resultados

Conforme apresentado no capítulo 2, as séries temporais serão trabalhadas conforme seu método particular, ou suas peculiaridades, nem sempre se utilizando de toda a série temporal, mas trabalhando com que o método propõe.

A escolha do modelo mais apropriado para a série em estudo é realizada através dos indicadores apresentados no subcapítulo 2.6, tomando para critério de avaliação o indicador da previsão. Sendo assim a comparação de desempenho de cada método será realizada através dos indicadores de previsão (FURTADO, 2007).

Após a comparação dos resultados, será feita a análise dos métodos e se buscará o entendimento de respectivo método ter sido o melhor para tal série temporal, tomando como base de sequenciamento de atividades o fluxograma da Figura 8.

Figura 8 – Planejamento da pesquisa



Fonte: Adaptado pelo autor com base em Jacobs (2011).

3.2 Classificação de pesquisa

Miguel (2012) classifica uma previsão de demanda de produtos de uma empresa por meio de modelos de séries temporais derivados a partir de dados históricos de vendas desses produtos como uma pesquisa quantitativa empírica descritiva. O que será demonstrado a seguir.

3.2.1 A pesquisa quanto aos objetivos

Diante de inúmeras abordagens classificatórias dos propósitos de pesquisa na literatura de metodologia de pesquisa em ciências sociais, ciências sociais aplicadas (Administração) e pesquisas organizacionais, Ganga (2012) demonstra alguns propósitos de pesquisas justificáveis em pesquisas de Engenharia de Produção e Gestão de Operações.

Abordagens de pesquisa descritivas estão muito relacionadas com pesquisas quantitativas, já que se procura descrever ou “quantificar” as características de determinada população ou fenômeno, ou o estabelecimento de relações entre variáveis (GANGA, 2012). Diante deste contexto, o estudo é classificado tendo como objetivo uma abordagem descritiva.

3.2.2 A pesquisa quanto à natureza da abordagem

O estudo tendo objetivos avaliar os resultados, conhecer a eficiência dos métodos aplicados e por ser expresso em números, e indicadores, a sua abordagem é classificada como uma pesquisa quantitativa. Da mesma forma que já foi classificado o tipo de previsão de demanda que será utilizado na monografia, sendo quantitativo.

3.2.3 A pesquisa quanto aos procedimentos técnicos

Pode-se destacar a área de Pesquisa Operacional (PO), uma grande área da Engenharia de Produção e Gestão de Operações, com foco principal na solução de problemas reais envolvendo situações gerenciais de tomada de decisão, através de modelos matemáticos processados computacionalmente (GANGA, 2012). É dentro da Pesquisa Operacional onde se encontra a Modelagem e Simulação, cujo a modelagem é o procedimento técnico ao qual será conduzido o estudo.

Miguel (2012) descreve um modelo como uma representação de uma situação ou realidade, que deve ser suficientemente detalhada para captar elementos essenciais e representar o sistema real; por outro lado, ela deve ser suficientemente simplificada para ser tratável por métodos de análise e resolução conhecidos.

4 MODELAGEM E PREVISÃO DA DEMANDA

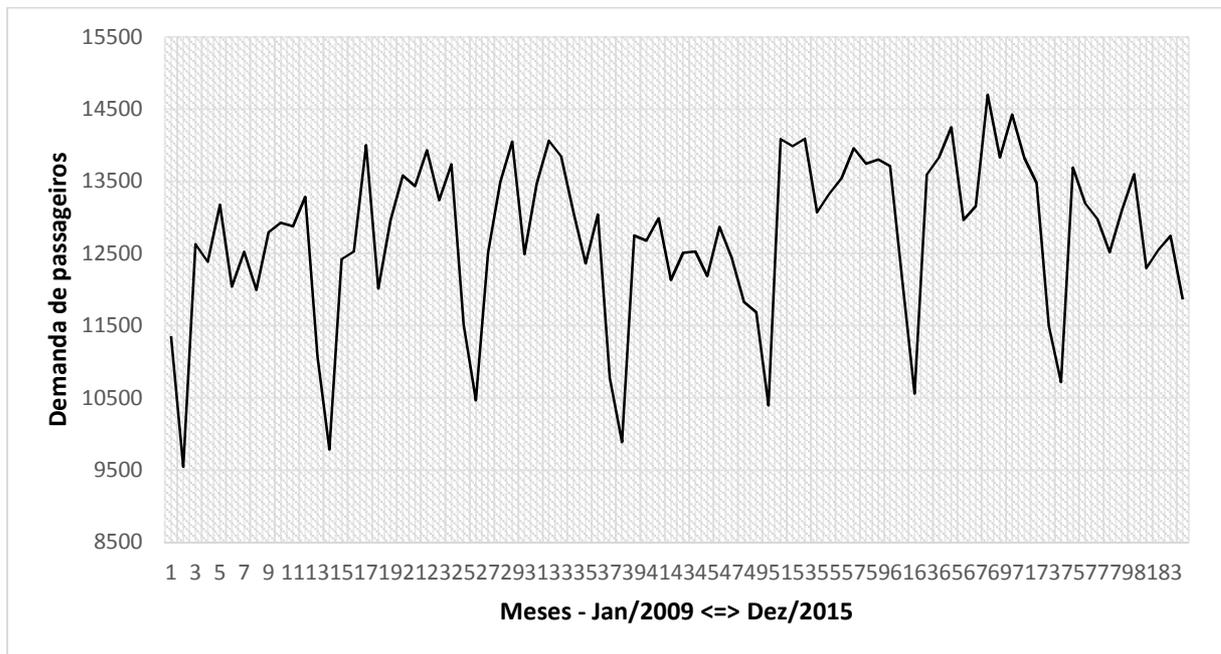
No presente capítulo são apresentadas as modelagens e previsões da série temporal em estudo, conforme os modelos descritos no Capítulo 2. Sendo assim, o Subcapítulo 4.1 apresenta a série temporal e identifica alguma característica que possa influenciar na modelagem da série. E posteriormente, nas Seção 4.2, e seus subcapítulos é realizado a modelagem das metodologias expostas no capítulo 2, apresentados nas Seções 4.2.1, 4.2.2, 4.2.3, tendo como sequência a respectiva modelagem dos métodos de (i) Médias Móveis, (ii) Suavização Exponencial; e, (iii) *Box-Jenkins*. Por fim, na Seção 4.3, são apresentados os resultados dos métodos, realizando análises quanto aos seus resultados.

4.1 Série temporal da demanda de passageiros

A série temporal em estudo é a venda de passagens rodoviárias, sendo as amostras coletadas desde janeiro de 2009, até dezembro de 2015, totalizando 84 amostras disponíveis para ajuste e modelagem. Sendo esta, uma das principais linhas de serviço que a empresa em estudo oferece, mantendo seu serviço constante ao longo do ano, e representando boa parte do seu faturamento.

Através do Gráfico 1 é apresentada a série temporal da demanda histórica de transporte de passageiros na Linha 449, na qual o eixo y representa a venda de passagens; e, o eixo x , representa os meses que aconteceram a coleta de dados da demanda.

Gráfico 1 – Série temporal



Fonte: Elaborado pelo autor (2016).

Se observa na figura um padrão de sazonalidade, e uma constância nos valores de demanda de cada mês, que representa uma sazonalidade a cada ciclo anual do serviço; também se verifica, que a série possa ser estacionária, pois ela se mantém dentro de uma média, não se observando tendência, ou ciclos que fogem da média da série. O que será verificado e analisado por meio dos métodos de previsão de demanda nos próximos subcapítulos.

4.2 Modelagem e previsão da série temporal

A Seção 4.2 apresenta a modelagem e a previsão da série temporal analisada, sendo provisionado os meses de janeiro a junho de 2016, utilizando as metodologias apresentadas no Capítulo 2, do presente estudo. A sequência se dá pelo método de Médias Móveis, Seção 4.2.1; método de Suavização Exponencial, Seção 4.2.2; e, pela metodologia de *Box-Jenkins*, Seção 4.2.3.

4.2.1 Modelagem e previsão utilizando o método de Médias Móveis

A previsão de demanda por meio da técnica de médias móveis, será provisionada um período a frente, pois esta é uma limitação do método, ou seja, a previsão referente ao subcapítulo 4.2.1, fará a modelagem para o mês de janeiro de 2016. No entanto os métodos de avaliação serão os mesmos, comparados aos outros modelos, apenas diferenciando, que neste caso, a previsão será de um período.

Por meio da Tabela 1 é apresentada a modelagem com os modelos de médias móveis, estimação dos parâmetros que foi realizada através do *Microsoft Excel*. O método de média móvel simples foi provisionada e ajustada com duas, quatro e oito médias, e os parâmetros dos demais modelos realizados através do complemento Solver do *Microsoft Excel*, o qual ajusta o parâmetro de acordo com a série temporal em análise.

Tabela 1 – Modelagem da série temporal utilizando os modelos de MM

Modelo	Parâmetros	MAE _a	MAPE _a	MAE _p	MAPE _p
MMS	2 períodos	927,79	7,52	2231,00	22,15
	4 períodos	844,31	6,89	70921,75	22,76
	8 períodos	799,73	6,55	67177,50	26,16
MMP	α : 0,98 β : 0,01	1127,24	9,07	2487,37	24,70
MMEP	α : 0,24	857,35	7,04	2504,70	24,87

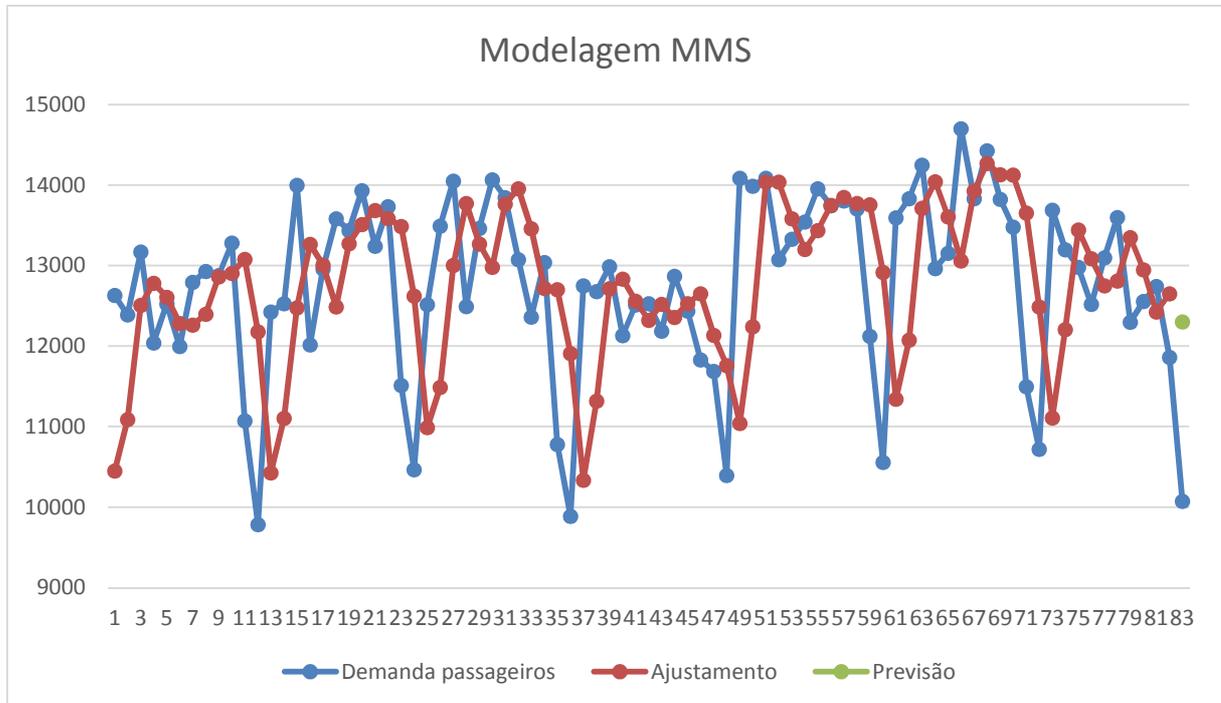
Fonte: Elaborado pelo autor (2016).

Pode se observar altos valores de ajustamento da série, que o MAPE de ajustamento foi de 7,52%, e ainda mais consideráveis os valores de previsão da série, obtendo um MAPE de previsão de 22,15%, para o modelo de média móvel simples. Como os métodos de médias móveis são indicados para previsões onde as componentes de tendência e sazonalidade são inexistentes ou desprezíveis, e séries constantes ao longo do tempo, seria justificável os valores altos dos indicadores, pois a série em estudo é sazonal.

No Gráfico 2 é apresentado o gráfico com o melhor modelo entre as médias móveis, a modelagem com média móvel simples de dois períodos, levando em consideração sempre o

MAPE de previsão, que no caso foi de 22,15, o qual fica nítido, que o método de médias móveis não acompanha a série quanto a sazonalidade.

Gráfico 2 – Modelagem da série temporal utilizando o modelo de MM



Fonte: Elaborado pelo autor (2016).

A considerável diferença entre o ajuste e a previsão dos métodos se dá, pois, quanto maior o número de períodos utilizados para ajustamento, que é o caso, menor a sensibilidade do modelo as variações, levando com que os indicadores se distorçam, porque, em algum momento o método foi mais eficaz ou não. E quando se dá a previsão, caso a demanda se eleve ou tome outra tendência, o modelo passa a refletir a média apenas daquele momento, que foi o ocorrido no caso em estudo.

4.2.2 Modelagem e previsão utilizando o método de Suavização Exponencial

O presente subcapítulo apresenta a modelagem utilizando o método de Suavização Exponencial, utilizando os modelos *Holt*, *Holt-Winters* Aditivo e *Holt-Winters* Multiplicativo.

O ajustamento do método, a previsão, e os parâmetros de estimação, foram realizados através do *Microsoft Excel*, apresentados na Tabela 2.

Tabela 2 – Modelagem da série temporal utilizando os modelos de SE

Modelo	Parâmetros	MAE _a	MAPE _a	MAE _p	MAPE _p
SEH	α : 0,81 β : 0,13	950,71	7,63	1257,70	11,27
SEHWA	α : 0,24 β : 0,20 γ : 0,51	383,62	3,01	339,43	3,06
SEHWM	α : 0,24 β : 0,63 γ : 0,76	409,55	3,19	263,70	2,47

Fonte: Elaborado pelo autor (2016).

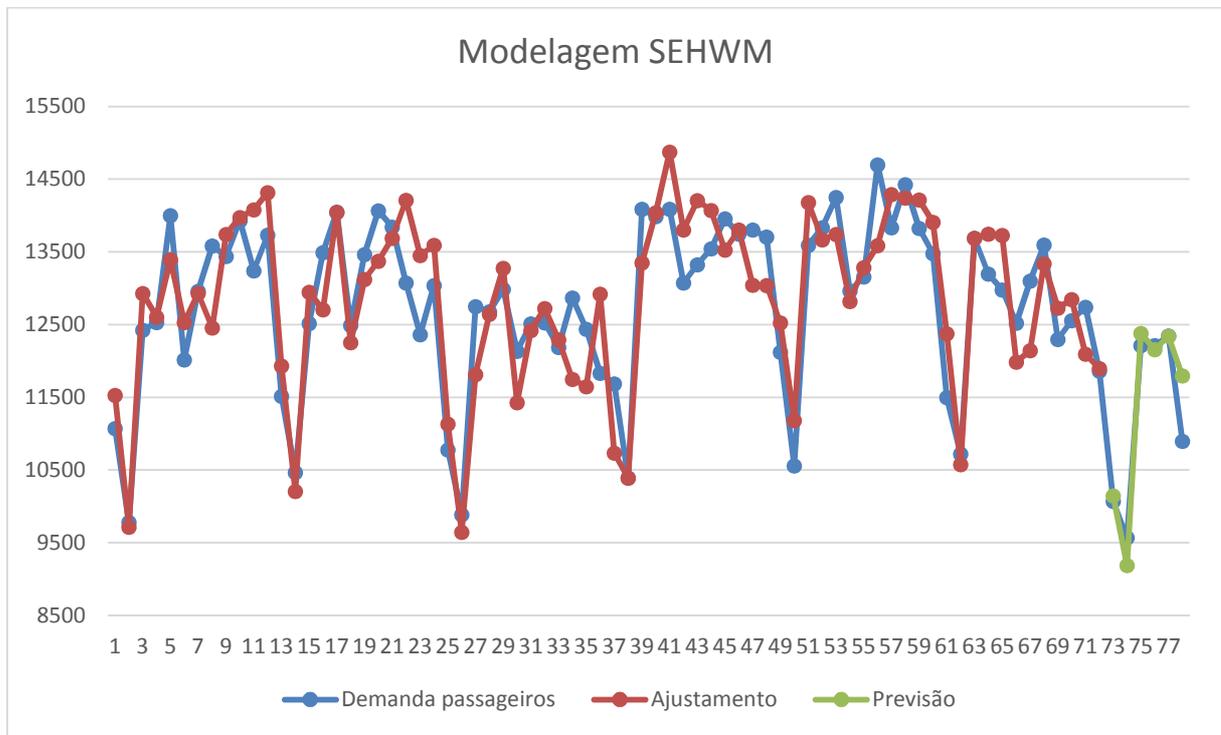
Observa-se uma melhora significativa em relação aos métodos de médias móveis, principalmente os modelos de Holt Winters aditivo e multiplicativo, dos quais são indicados para utilização com séries que possuem sazonalidade. Verifica-se também uma distorção em relação aos indicadores dos métodos aditivos e multiplicativos, pois em relação ao ajustamento o melhor indicador é o aditivo, e em relação a previsão, o melhor indicador é para o método multiplicativo.

No caso não se verifica multiplicação sazonal na série, mas o indicador para a previsão multiplicativa obteve melhor resultado. Pode se entender que a série no respectivo momento de análise se adequou melhor ao método multiplicativo, mas em uma média geral dos dados, o método aditivo é o que melhor se encaixa na série em estudo.

Outra constatação em relação aos métodos aditivos e multiplicativos, é a pequena diferença entre os indicadores, praticamente menosprezível em termo de análise, mas em termos bibliográficos e históricos, são métodos que se encaixam em séries diferentes, pois a multiplicação em uma série sazonal, faz com que tome outras proporções de análise.

No Gráfico 3 é apresentada a modelagem referente ao modelo de suavização exponencial de *Holt-Winters* multiplicativo, cujo modelo obteve os melhores resultados de previsão, dentre os métodos de suavização exponencial estudados, considerando o menor MAPE de previsão. Se percebe o ajuste sazonal que o modelo exerce sobre a série temporal, sendo seus indicadores satisfatórios.

Gráfico 3 – Modelagem da série temporal utilizando os modelos de SEHWM



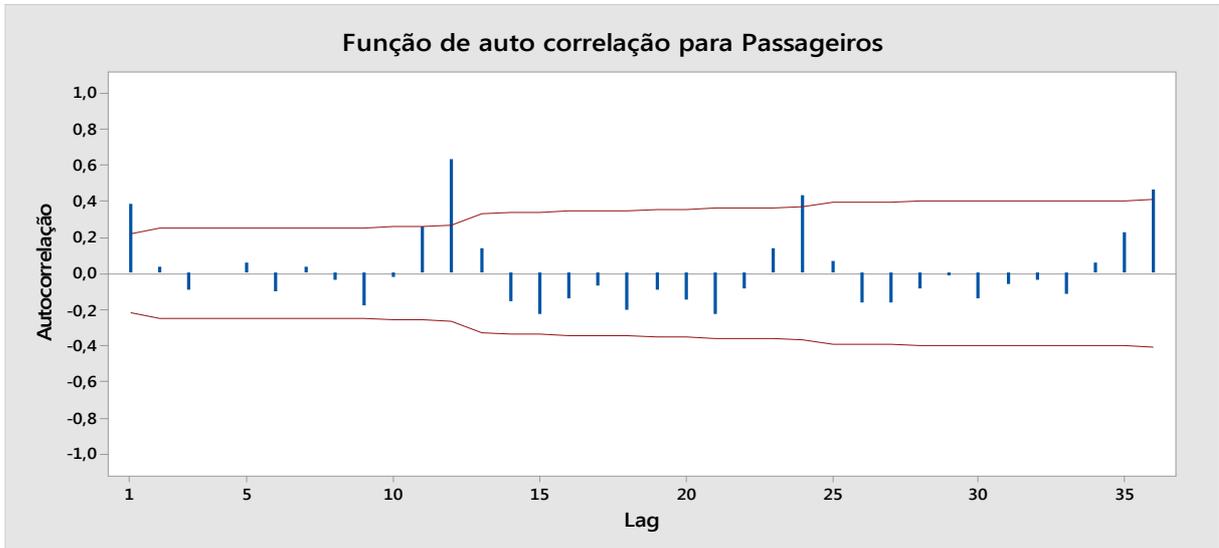
Fonte: Elaborado pelo autor (2016).

4.2.3 Modelagem e previsão utilizando o método de *Box-Jenkins*

O presente capítulo apresenta a modelagem da série temporal utilizando o método de *Box-Jenkins*. A modelagem foi realizada com o *software* Minitab, versão 17. Se iniciando o processo de modelagem, a primeira etapa é a apresentação da função de auto correlação, e auto correlação parcial, aplicado na série temporal em estudo, apresentados no Gráfico 4 e Gráfico 5, respectivamente.

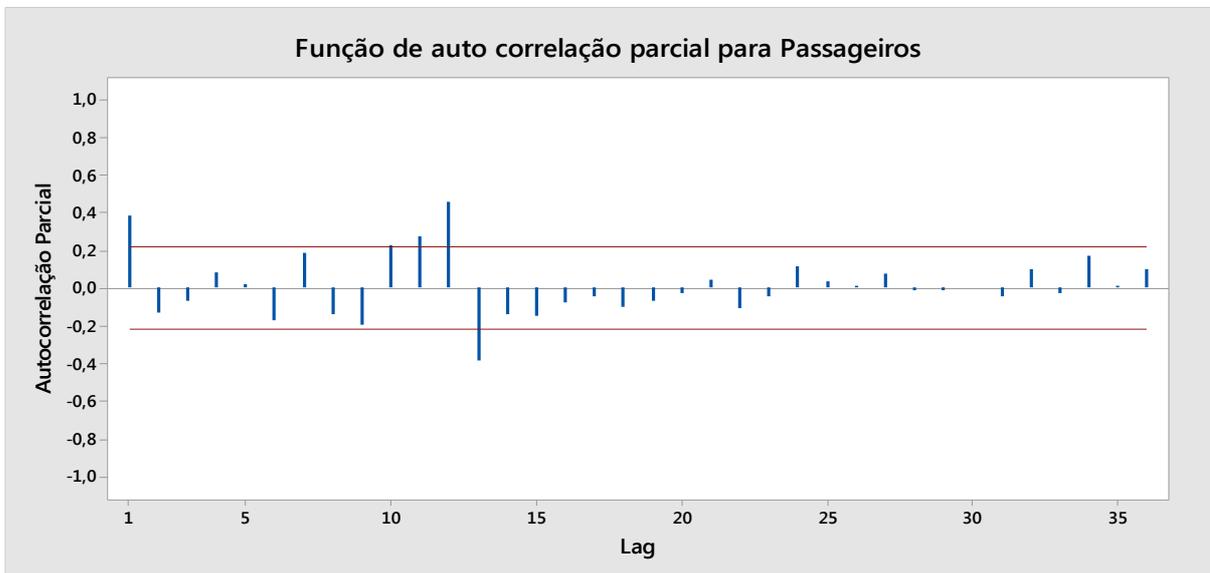
Conforme bibliografia, a condição estacionária da série temporal se indica através da FAC e FACP. Verifica-se visualmente que a série é estacionária, não sendo necessária a aplicação de outros métodos ou técnicas para se constatar a estacionariedade. Demonstrado através dos Gráficos 4 e 5.

Gráfico 4 – Função de Auto Correlação da série temporal



Fonte: Elaborado pelo autor (2016).

Gráfico 5 – Função de Auto Correlação Parcial da série temporal



Fonte: Elaborado pelo autor (2016).

A FAC apresentou um pico na primeira defasagem e uma queda brusca nas demais, representando que é uma série estacionária, após, no lag 12, houve outro pico de defasagem, do qual saiu dos limites de auto correlação, que representa o comportamento sazonal da série, ou seja, um ciclo anual, enquanto que a FACP apresentou os mesmos picos de defasagens fora dos

limites, sendo menosprezível para o critério de estacionariedade, e sim, deixando claro a sazonalidade da série.

Visto que o modelo em estudo é sazonal, serão identificados alguns modelos possíveis para descrever a série temporal (TABELA 3), considerando modelos SARIMA, dos quais tem o ajustamento sazonal da série, e também realizando testes com modelos ARIMA. Serão apresentados os *p-values* dos coeficientes do modelo, o MAE e o MAP, de ajustamento e da previsão.

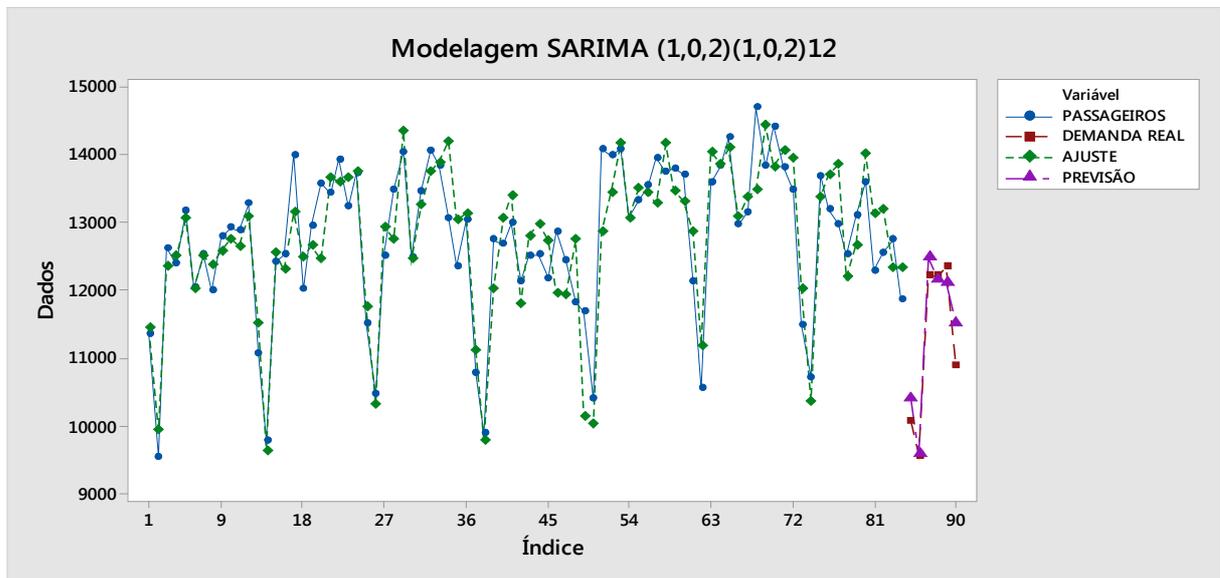
Tabela 3 – Modelagem da série temporal utilizando a metodologia de *Box-Jenkins*

Modelo	<i>p-value</i> dos Coeficientes	MAE _a	MAPE _a	MAE _p	MAPE _p
SARIMA (1,0,1)(1,0,1) ₁₂	$\phi = 0,88992$ $\theta = 0,99876$ $\Phi = 0,43133$ $\Theta = 0,82055$ $\phi = 0,90908$	364,81	2,88	537,18	4,75
SARIMA (1,0,1)(2,0,1) ₁₂	$\theta = 0,98832$ $\phi = 0,00995$ $\Phi = 0,44523$ $\Theta = 0,82808$	362,16	2,86	503,76	4,49
ARIMA (1,0,1)	$\phi = 1,00006$ $\theta = 0,89804$ $\phi = 1,52810$ $\phi = 0,28527$ $\phi = 0,24340$	860,63	7,06	1623,51	15,64
SARIMA (3,0,1)(2,0,1) ₁₂	$\theta = 0,41457$ $\phi = 0,56455$ $\phi = 1,00806$ $\Theta = 0,01680$ $\phi = 0,97836$ $\theta = 0,97694$	397,16	3,12	835,59	7,36
SARIMA (1,0,2)(1,0,2) ₁₂	$\theta = 0,44269$ $\phi = 0,03171$ $\Theta = 0,27320$ $\Theta = 0,19459$ $\phi = 0,90936$ $\theta = 0,99942$	410,49	3,23	251,28	2,26
SARIMA (1,0,1)(1,0,3) ₁₂	$\phi = 0,40789$ $\Theta = 0,05700$ $\Theta = 0,08671$ $\Theta = 0,81473$	396,58	3,10	497,17	4,30

Fonte: Elaborado pelo autor (2016).

Conforme visualizado na Tabela 3, o melhor modelo ajustado à série temporal foi o SARIMA (1,0,2)(1,0,2)₁₂, sendo melhor descrito, por uma constante auto regressiva simples e uma sazonal, e dois termos constantes de média móvel simples, e também duas constantes sazonais.

Gráfico 6 – Modelagem utilizando o modelo SARIMA (1,0,2)(1,0,2)



Fonte: Elaborado pelo autor (2016).

Verifica-se a acurácia do modelo em relação ao ajustamento, e posterior previsão, realizando com satisfação a modelagem, observando que o modelo acompanhou a sazonalidade da série temporal, e realizou uma previsão satisfatória.

4.3 Discussão dos resultados

O presente capítulo apresenta a discussão dos resultados obtidos com a modelagem dos respectivos modelos, realizando análises e comentários necessários quanto aos resultados obtidos no Capítulo 4.

Na Tabela 4 é apresentado os melhores modelos encontrados dentro de cada método. Realizando a análise do MAPE, se nota um desempenho significativo superior para os métodos de *Holt-Winters*, e *Box-Jenkins*, comparados aos métodos de médias móveis, dos quais foram prejudicados, por não serem métodos adequados para a série temporal em análise.

Tabela 4 – Comparação entre os melhores métodos

Modelo	Parâmetros	MAEa	MAPEa	MAEp	MAPEp
MMS	2 períodos	927,7917	7,516107	2231	22,15052
SEHWM	α : 0,24279	409,5521	3,186885	263,6964	2,471456
	β : 0,63187				
	γ : 0,75540				
	ϕ = 0,97836				
	θ = 0,97694				
SARIMA (1,0,2)(1,0,2)12	θ = 0,44269	410,4859	3,225035	251,2839	2,256213
	ϕ = 0,03171				
	Θ = 0,27320				
	Θ = 0,19459				

Fonte: Elaborado pelo autor (2016).

Para os métodos de médias móveis, a média móvel simples foi a obteve melhor resultado, superando os modelos com ponderação de valores. Os resultados foram os esperados, por se tratar de uma série sazonal, não obteve valores de ajustamento e previsão satisfatórios. Sendo o principal fator, por não serem métodos indicados para se trabalhar com séries temporais sazonais.

Para os modelos suavização exponencial, os modelos de *Holt* não se adequaram a série histórica, já os métodos de *Holt-Winters* aditivo e multiplicativo obtiveram melhores resultados, sendo que as diferenças foram mínimas, tanto que para o ajustamento, o modelo aditivo, obteve melhor resultado, e na previsão o modelo multiplicativo foi que obteve melhor resultado. Não foram observadas diferenças na utilização entre este e aquele modelo, tomando por consideração que o pacote computacional utilizado estimou os parâmetros a serem aplicados. Pode se considerar que os dois modelos podem ser aplicados a série, pois os resultados acabaram se invertendo, no caso em específico, haveria necessidade de se prever e ajustar a série em outros períodos, para que se confirmasse qual o melhor modelo.

Para a metodologia de *Box-Jenkins*, se esperava um resultado superior, pois estes foram próximos em relação aos métodos de *Holt-Winters*, uma diferença no MAPE de previsão de 5,58% superior, tanto que o ajustamento do método de *Holt-Winters* tem um melhor resultado, MAPE de ajustamento 10,28% superior, do que o de *Box-Jenkins*. Se pode considerar que a capacidade de previsão e ajustamento destes dois métodos para esta série temporal são muito próximas, pois a diferença de resultados em percentual é baixa, mas em termos de análise, se considera o método de *Box-Jenkins* o melhor para a previsão da série temporal.

$$\phi(B)\phi(B^s)\Delta^d\Delta_s^D y_t = \theta(B)\theta(B^s)\varepsilon_t \quad (32)$$

O modelo SARIMA (1,0,2)(1,0,2)₁₂, dentro da metodologia de *Box-Jenkins* foi aquele que demonstrou ter melhor capacidade de previsão dentre todos os modelos utilizados, a Equação 32 apresenta o modelo algébrico, cujos parâmetros utilizados se encontram na Tabela 4, neste capítulo.

Tabela 5 – Demanda real e previsão

Período	Demanda Real	Previsão
jan/16	10072	10410
fev/16	9571	9579
mar/16	12213	12483
abr/16	12213	12165
mai/16	12345	12115
jun/16	10899	11513

Fonte: Elaborado pelo autor (2016).

Os resultados quantitativos referentes à demanda e previsão dos meses de janeiro de 2016 a junho de 2016 se apresentam por meio da Tabela 5, graficamente apresentado no Gráfico 6, no subcapítulo 4.2.3, no qual é apresentado a previsão para o modelo SARIMA com melhor resultado dentre todos os métodos.

5 CONCLUSÕES

No presente estudo foi modelada e realizada a previsão da demanda de passageiros aplicada a uma série temporal, sendo a previsão realizada para o primeiro semestre de 2016, correspondente ao serviço de transporte de passageiros em uma empresa do setor rodoviário, se utilizando de três metodologias, das quais se utilizam de séries temporais para estudo, com o objetivo de encontrar o melhor método para a previsão da demanda.

A realização deste estudo permite afirmar que tomar decisões com informações armazenadas, comprovadas, validadas e tabuladas, torna o processo de análise, modelagem, e projeções seguros a qualquer empresa ou organização, se fazendo, de ferramentas indispensáveis no processo de decisão ou gestão.

A metodologia de *Box-Jenkins*, bibliograficamente e historicamente estimada como sendo mais precisa, na série temporal em estudo não se justificou, obtendo resultados similares ao método de *Holt-Winters*, 5,58% superior. O método de *Holt-Winters* aproximou seus resultados com o de *Box-Jenkins*, tanto que a série temporal em estudo se moldou melhor ao modelo de *Winters*. Evidenciando que as duas metodologias de modelagem foram capazes de descrever os padrões comportamentais da série estudada, obtendo resultados aceitáveis, próximos aos valores reais observados. Mas deixando claro, que estatisticamente, o melhor método para previsão da série temporal em estudo, é o de *Box-Jenkins*.

O objetivo principal geral e secundários foram alcançados durante o trabalho, sendo o principal, modelar e encontrar o melhor método para previsão da série temporal analisada. Sendo a metodologia de *Box-Jenkins*, o método com os melhores resultados.

Avalia-se então, que o estudo cumpriu o papel a que se propôs, respondendo as questões apresentadas, e atingindo seus objetivos finais.

Por fim, após as conclusões, seguem sugestões para próximos trabalhos relacionados.

Como trabalhos e estudos futuros, existem uma infinidade de possibilidades que podem agregar valor dentro do contexto estudado, principalmente revelando outros resultados e conclusões sobre o tema proposto do trabalho.

Alguma dessas sugestões seriam o estudo de mercado e negócio, buscando encontrar o porquê de a demanda de passageiros ser sazonal. Também analisar e fazer o estudo de previsão de demanda de outras séries de venda de passagens, encontrando o melhor modelo para tal, sendo que na empresa na qual foram coletado os dados, se trabalha com diversas linhas de transporte, com certeza, cada linha com sua particularidade.

Outro estudo que pode ser feito, é de se utilizar outras metodologias para a previsão da mesma série temporal, trabalhando com metodologias que se utilizam de dados históricos para análise, podendo se utilizar métodos mais complexos como o de Redes Neurais, ou métodos de Projeção ou Decomposição, visando sempre a melhor previsão para a série temporal.

Outra análise a ser feita, é do uso quanto a metodologia de *Holt-Winters*, pois os modelos de adição e multiplicação obtiveram resultados semelhantes, mas em conceito são aplicados a séries temporais sazonais diferentes. O estudo seria a verificação de quais dos modelos se adaptam melhor a mesma série temporal, aplicando estes modelos a outros intervalos de tempo.

Outra pesquisa a ser feita, seria o uso de metodologias de regressão multivariada, no qual se poderia tentar achar regressões que melhor expliquem e prevejam a série temporal, usando de outras variáveis para a explicação da demanda de passageiros, entre outras.

REFERÊNCIAS

AFONSO, M. W.; FILHO, R. M. M.; NOVAES, M. L. O. Aplicação de modelos de previsão de demanda em uma farmácia hospitalar. **Relatórios de pesquisa em engenharia de produção**, v. 11, n. 4, p. 9-21, 2011.

BALLOU, Ronald H. **Gerenciamento da cadeia de suprimentos: logística empresarial**. 5. ed.. Porto Alegre: Bookman, 2005.

BALTAR, P. Bruno. **Análise temporal dos preços da commodity cobre usando o modelo *Box-Jenkins***. 2009. 8f. Dissertação (Mestrado em Administração) – Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro, 2009.

CASTRO G. E. J.; NETTO S. M. J. Análise de técnicas de previsão de demanda com enfoque no planejamento da gestão de suprimentos. **Revista Científica FACPED**, n. 4, 2013.

CONSUL, B. Fabrício; WERNER, Liane. **Avaliação de técnicas de previsão de demanda utilizadas por um software de gerenciamento de estoques no setor farmacêutico**. Porto Alegre: UFRGS, 2010.

CORDEIRO, D. M. **Séries temporais - análise quantitativa: teoria e aplicações**. Recife: EDUPE, 2002.

CORRÊA, H. L.; GIANESI, I. G. N.; CAON, M. **Planejamento, programação e controle da produção: MRP II/ERP: conceitos, uso e implantação, base para SAP, oracle applications e outros softwares integrados de gestão**. 5. ed. São Paulo: Atlas, 2009.

DETZEL, M. H. D.; MINE, M. R. M.; SANTOS, B. A.; THOMSEN S. L. **Caderno FAC e FACP**. Curitiba: Instituto de pesquisa científica LACTEC, 2011.

FAVA, V. L. Análise de Séries de Tempo. In: VASCONCELLOS, M. A. S.; ALVES, D. **Manual de econometria: nível intermediário**. São Paulo: Atlas, 2000.

FELICIANO, R. A. **Uma proposta de gerenciamento integrado da demanda e distribuição, utilizando sistemas de apoio à decisão (SAD) com business intelligence (BI)**. 2009. 179 p. Dissertação (Mestrado em Engenharia) – Universidade de São Paulo, São Paulo, 2009.

FURTADO, R. M. **Aplicação de previsão da demanda total nos credenciado Belgo Pronto**. 2007. 27 p. Tese (Doutorado em Engenharia de Produção) – Universidade Federal de Juiz de Fora, Minas gerais, 2007.

GANGA, Gilberto Miller Devós. **Trabalho de conclusão de curso (TCC) na engenharia de produção: um guia prático de conteúdo e forma**. São Paulo: Atlas, 2012.

GIANESI, I. G. N.; CORRÊA, H. L. **Administração estratégica de serviços: operações para satisfação do cliente**. São Paulo: Atlas, 1994.

GIRARDI, G.; CAMARGO, E. M.; MOTTA, E. M. **Previsão de vendas através de modelos integrados: o caso do setor têxtil de uma empresa**. 2013.120f. Dissertação (Mestrado em Administração) – Universidade de Caxias do Sul, 2013.

GODOY, A. S. Pesquisa Qualitativa: tipos fundamentais. **Revista de Administração de Empresas**, São Paulo, v. 35, n. 3, p. 20-29, maio/jun., 1995.

GONÇALVES, M. B.; BEZ, E. T.; NOVAES, A. G. Modelos econométricos aplicados à previsão de demanda por transporte interestadual de passageiros de ônibus no Brasil. **Transportes**, v. XV, n. 1, p. 24-33, 2007.

JACOBS, F. R.; CHASE, R. B. **Administração da produção e de operações: o essencial**. Porto Alegre: Bookman, 2009.

JACOBS, F. R.; CHASE, R. B.; AQUILANO, N. J. **Administração da produção para a vantagem competitiva**. 10. ed. Porto Alegre: Bookman, 2006.

JACOBS, W. **Modelos de suavização exponencial, ARIMA e redes neurais artificiais: um estudo comparativo para a previsão de demanda de produtos**. 2011. 110 p. Monografia (Graduação em Engenharia de Produção) – Centro Universitário UNIVATES, Lajeado, 2011.

JOHNSTON, R.; CLARK, G. **Administração de operações de serviços**. São Paulo: Atlas, 2010.

KOTLER, Philip. **Administração de marketing**. Tradução: Bazán Tecnologia e Linguística. 10. ed. São Paulo: Prentice Hall, 2000.

LUSTOSA, L.; MESQUITA, M. A.; QUELHAS, O.; OLIVEIRA, R. **Planejamento e controle da produção**. Rio de Janeiro: Elsevier, 2008.

MADDALA, G. S. **Introdução à econometria**. 3. ed. Rio de Janeiro: LTC – Livros Técnicos e Científicos, 2003.

MARTINS, Petrônio Garcia; LAUGENI, Fernando P. **Administração da produção**. São Paulo: Saraiva, 2003.

MIGUEL, Paulo Augusto Cauchick (Org.). **Metodologia da pesquisa em engenharia de produção e operações**. Rio de Janeiro: Elsevier/ABEPRO, 2012.

MONKS, J. G. **Administração da produção**. São Paulo: MCGraw-Hill, 1987.

MOREIRA, Daniel Augusto. **Administração da produção e operações**. São Paulo: Pioneira, 2008.

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

OLIVEIRA, S. de. Um estudo em séries temporais na análise da receita nominal de vendas de veículos e motos. **Conexão**, Formiga, v. 7, n. 2, p. 64-73, 2012.

PELLEGRINI, F. R.; FOGLIATTO, F. S. Passos para implantação de sistemas de previsão de demanda: técnicas e estudo de caso. **Prod.** [online], v. 11, n. 1, p. 43-64, 2001.

PINDYCK, R. S.; RUBINFELD, D. L. **Econometria: modelos e previsões**. 4. ed. Rio de Janeiro/RJ: Elsevier, 2004.

RIGGS, L. James. **Administração da produção: planejamento, análise e controle, uma abordagem sistêmica**. São Paulo: Atlas, 1981.

RITZMAN, P. Larry, KRAJEWSKI, J. Lee. **Administração da produção e operações**. São Paulo: Pearson Prentice Hall, 2004.

SANTANA, V. R. Aplicação da metodologia de Bok-Jenkins na previsão da produção de cana-de-açúcar. In: CONGRESSO DE MATEMÁTICA APLICADA E COMPUTACIONAL, **Anais...**, Recife: Universidade Federal Rural de Pernambuco, 2012.

SEYBOTH, K. A. J. et al. Aplicação do modelo *Holt-Winters* para a previsão de demanda de soro de um hospital situado na região oeste do Paraná. In: CONGRESSO BRASILEIRO DE ENGENHARIA DE PRODUÇÃO, 5, **Anais...**, Ponta Grossa: Universidade Tecnológica Federal do Paraná (UTFPR), 2015.

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

TUBINO, Dalvio Ferrari. **Manual de planejamento e controle da produção**. 2. ed. São Paulo: Atlas, 2000.

VASCONCELLOS, M. A. S.; ALVES, D. **Manual de econometria: nível intermediário**. São Paulo: Atlas, 2000.

VERRUCK, F.; BAMPI, E. R.; MILAN S. G. **Previsão de demanda em operação de serviços: um estudo em uma empresa do setor de transportes**. In: SIMPÓSIO DE ADMINISTRAÇÃO DA PRODUÇÃO, LOGÍSTICA E OPERAÇÕES INTERNACIONAIS, **Anais...**, Caxias do Sul: Universidade de Caxias do Sul, 2009.

WERNER, L.; RIBEIRO, J. L. D. Previsão de demanda: uma aplicação dos modelos Box-Jenkins na área de assistência técnica de computadores pessoais. **Revista Gestão & Produção**, v. 10, n. 1, p. 47-67, 2003.

MENTZER, J.; KAHN, K. A framework of logistics research. **Journal of Business Logistics**, v. 16, n. 1, p.231-250, 1995.



UNIVATES

R. Avelino Tallini, 171 | Bairro Universitário | Lajeado | RS | Brasil
CEP 95900.000 | Cx. Postal 155 | Fone: (51) 3714.7000
www.univates.br | 0800 7 07 08 09