

**UNIVERSIDADE DE CAXIAS DO SUL
CURSO DE ENGENHARIA DE PRODUÇÃO**

JULIEN LODI CAMPAGNOLLO

**PROPOSTA DE IMPLEMENTAÇÃO DE MODELOS MATEMÁTICOS DE
PREVISÃO DE DEMANDA PARA O PLANEJAMENTO DE PRODUÇÃO DA
EMPRESA KEKO ACESSÓRIOS S.A**

CAXIAS DO SUL

2017

JULIEN LODI CAMPAGNOLLO

**PROPOSTA DE IMPLEMENTAÇÃO DE MODELOS MATEMÁTICOS DE
PREVISÃO DE DEMANDA PARA O PLANEJAMENTO DE PRODUÇÃO DA
EMPRESA KEKO ACESSÓRIOS S.A**

Trabalho de Conclusão de Curso apresentado ao curso de Engenharia de Produção da Universidade de Caxias do Sul, como requisito parcial à obtenção do grau de Bacharel em Engenharia de Produção.

Orientador Prof. Leandro Luís Corso

CAXIAS DO SUL

2017

JULIEN LODI CAMPAGNOLLO

**PROPOSTA DE IMPLEMENTAÇÃO DE MODELOS MATEMÁTICOS DE
PREVISÃO DE DEMANDA PARA O PLANEJAMENTO DE PRODUÇÃO DA
EMPRESA KEKO ACESSÓRIOS S.A**

Trabalho de Conclusão de Curso apresentado ao curso de Engenharia de Produção da Universidade de Caxias do Sul, como requisito parcial à obtenção do grau de Bacharel em Engenharia de Produção.

Aprovado em

Banca Examinadora

Prof. Dr. Leandro Luís Corso
Universidade de Caxias do Sul – UCS

Prof. Ms. Esequiel Berra de Mello
Universidade de Caxias do Sul – UCS

Prof. Ms. Michele Otobelli Bertéli
Universidade de Caxias do Sul – UCS

Ricardo Bacca
Keko Acessórios S.A.

RESUMO

Com a competitividade cada vez mais presente, as empresas se veem obrigadas a buscarem ferramentas que as auxiliam na tomada de decisão. Considerando que previsões de demanda construídas de maneira incorretas podem pôr em risco o futuro de uma empresa, o presente trabalho analisa os principais modelos matemáticos de séries temporais para prever demanda encontrados na literatura e objetiva aplicá-los em uma empresa do ramo de autopeça para posteriormente compará-los com os atuais modelos de previsão adotados, visando uma melhoria no processo e por consequência redução de custos e otimização dos estoques. Com a definição de um modelo adequado, foi possível propor a implementação do mesmo na empresa Keko Acessórios S.A com o qual se estima redução de custo financeiro de 221.467,13 reais anuais.

Palavras-chave: Previsão de Demanda. Modelos Matemáticos. Séries Temporais. Modelo Adequado.

LISTA DE FIGURAS

Figura 1 – Padrões típicos de demanda.....	16
Figura 2 – Série temporal não estacionária na média.....	26
Figura 3 – Redução da não estacionariedade de uma série temporal após sucessivas diferenciações.....	27
Figura 4 – Sequência de execução do modelo Box-Jenkins.....	29
Figura 5 – Unidade atual da empresa Keko Acessórios S.A em Flores da Cunha.....	35
Figura 6 – Relatório de venda por data tabulado.....	37
Figura 7 – Canais de venda.....	38
Figura 8 – Histórico de vendas.....	39
Figura 9 – Parâmetros SPSS.....	54
Figura 10 – Análise do item 650.02PT.....	56
Figura 11 – Análise do item 101.12FX.....	56
Figura 12 – Transformações da variável dependente.....	58
Figura 13 – Análise do item 071.35PT.....	60
Figura 14 – Análise do item 136.07AZ.....	61
Figura 15 – Análise do item 101.00C7.....	62
Figura 16 – Método <i>Expert Modeler</i> SPSS.....	63
Figura 17 – Parâmetros ARIMA SPSS.....	63

LISTA DE TABELAS

Tabela 1 – Dados históricos 2015.....	44
Tabela 2 – Dados históricos 2016.....	45
Tabela 3 – Exemplo do método de avaliação dos resultados.....	47
Tabela 4 – MAPE MMS x Método atual.....	48
Tabela 5 – Pesos atribuídos aos períodos.....	49
Tabela 6 – Pesos otimizados pelo <i>solver</i>	49
Tabela 7 – MAPE MMP x Método atual.....	50
Tabela 8 – MAPE MMP ajustada x Método atual.....	51
Tabela 9 – MAPE Suavização Exponencial Simples x Método atual.....	52
Tabela 10 – MAPE Modelo de <i>Holt</i> x Método atual.....	54
Tabela 11 – MAPE Modelo de <i>Holt</i> x Método atual.....	57
Tabela 12 – MAPE Modelo de <i>Winters</i> multiplicativo x Método atual.....	59
Tabela 13 – MAPE <i>Box-Jenkins</i> otimizado x Método atual.....	64
Tabela 14 – Configurações ARIMA otimizado.....	65
Tabela 15 – Configurações aplicadas.....	66
Tabela 16 – MAPE <i>Box-Jenkins</i> x Método atual.....	66
Tabela 17 – MAPE <i>Box-Jenkins</i> aleatório x Método atual.....	67
Tabela 18 – Custos mensais e ganhos com o modelo.....	69
Tabela 19 – Resumo MAPE e MAE.....	71

LISTA DE ABREVIATURAS E SIGLAS

ACF	<i>Autocorrelation Function</i>
AR	<i>Autoregressive</i>
ARIMA	<i>Autoregressive Integrated Moving Average</i>
ARMA	<i>Autoregressive Moving Average</i>
CDI	Centro de Desenvolvimento e Inovação
ERP	<i>Enterprise Resource Planning</i>
I	Integração
MA	<i>Moving Average</i>
MAE	Média Absoluta dos Erros
MAPE	Média Absoluta Percentual dos Erros
MM	Média Móvel
MMS	Média Móvel Simples
MMP	Média Móvel Ponderada
OEM	<i>Original Equipment Manufacturer</i>
PACF	<i>Partial Autocorrelation Function</i>
P&A	Peças e Acessórios
POA	Previsão Orçamentária Anual
PCP	Planejamento e Controle da Produção
SPSS	<i>Statistical Package for Social Science</i>
SUV	<i>Sport Utility Vehicle</i>

SUMÁRIO

1	INTRODUÇÃO.....	10
1.1	JUSTIFICATIVA DO ESTÁGIO	11
1.2	OBJETIVOS	12
1.2.1	Objetivo geral.....	13
1.2.2	Objetivos específicos.....	13
1.3	ABORDAGEM E DELIMITAÇÃO	13
2	FUNDAMENTAÇÃO TEÓRICA	15
2.1	SÉRIES TEMPORAIS	15
2.2	MÉDIA MÓVEL.....	17
2.2.1	Média Móvel Simples	17
2.2.2	Média Móvel Ponderada	18
2.3	SUAVIZAÇÃO EXPONENCIAL	18
2.3.1	Suavização exponencial simples	19
2.3.2	Modelo de <i>Holt</i>	19
2.3.3	Modelo de <i>Winters</i>	21
2.4	<i>BOX-JENKINS</i>	23
2.4.1	Modelos estacionários	24
2.4.2	Modelos não estacionários	26
2.4.3	Modelos sazonais	28
2.4.4	Etapas da metodologia <i>Box-Jenkins</i>	28
2.5	ERROS DE PREVISÃO	30
2.6	CUSTO FINANCEIRO.....	32
2.7	CONSIDERAÇÕES DO CAPÍTULO	32
3	PROPOSTA DO TRABALHO	34
3.1	PERFIL DA EMPRESA E AMBIENTE DE ESTÁGIO	34
3.2	CENÁRIO ATUAL.....	36
3.3	ETAPAS DO TRABALHO.....	40
3.3.1	Realizar o levantamento e coleta de dados.....	40
3.3.2	Implementar computacionalmente os modelos.....	40

3.3.3	Analisar os resultados e comparar com o método atualmente utilizados	41
3.3.4	Mensurar os ganhos para a empresa	41
3.3.5	Definir o modelo mais adequado para a empresa	42
3.3.6	Propor a implantação do modelo escolhido	42
3.4	CONSIDERAÇÕES DO CAPÍTULO	43
4	APLICAÇÃO DOS MODELOS DE PREVISÃO DE DEMANDA.....	44
4.1	LEVANTAMENTO E COLETA DE DADOS	44
4.2	IMPLANTAÇÃO, ANÁLISE E COMPARAÇÃO DOS MODELOS	46
4.2.1	Média Móvel Simples	47
4.2.2	Média Móvel Ponderada	49
4.2.3	Suavização Exponencial Simples.....	52
4.2.4	Modelo de <i>Holt</i>	53
4.2.5	Modelo de <i>Winters</i> Multiplicativo	58
4.2.6	Modelo de <i>Winters</i> Aditivo.....	61
4.2.7	<i>Box-Jenkins</i>	62
4.3	MENSURAR OS GANHOS PARA A EMPRESA	69
4.4	DEFINIR O MODELO MAIS ADEQUADO PARA A EMPRESA COM BASE NO ERRO.....	71
4.5	PROPOR A IMPLANTAÇÃO DO MODELO ESCOLHIDO	73
5	CONCLUSÃO.....	74
5.1	SUGESTÕES PARA TRABALHOS FUTUROS	75
	REFERÊNCIAS	76

1 INTRODUÇÃO

As frequentes oscilações na economia global têm gerado instabilidades no mercado consumidor. A tendência é que as empresas busquem cada vez mais adequar seus recursos para otimizarem os custos indiretos de produção e comercialização de seus produtos. Perante a competitividade do mercado atual esse pode ser um fator importante para se manterem fortes no ramo de atuação.

Instabilidade políticas e econômicas assim como crescimento da concorrência internacional podem colocar em risco a saúde financeira da organização. Um método adequado de previsão de demanda engajado com a programação de produção pode ajudar a tornar o planejamento mais próximo da realidade, evitando aumentos excessivos de estoque ou desatendimento ao cliente.

A gestão da demanda pode ser entendida como um conjunto de processos que fazem a interface da empresa com o mercado consumidor. Para alguns negócios engloba o cadastro do pedido, a previsão da demanda, o prazo de entrega, o serviço ao cliente e a distribuição física do produto (SLACK; CHAMBERS; JOHNSTON, 2009).

A previsão de demanda futura é a base para todas as decisões estratégicas e de planejamento em uma cadeia de suprimentos (CHOPRA; MEINDL, 2011). Para Ritzman e Krajewski (2004), uma previsão de demanda precisa, permite aos programadores o melhor aproveitamento da capacidade, reduz o tempo de reação para o cliente e redução de estoque de produtos e insumos.

Uma demanda estável e uniforme pode permitir que uma organização reduza custos e melhore o serviço; a capacidade pode ser melhor utilizada e atingir maiores lucros (SLACK; CHAMBERS; JOHNSTON, 2002).

Uma previsão de demanda refinada, dá subsídios para que a programação de produção seja a mais assertiva possível, conseqüentemente a previsão de utilização de recursos também. Segundo Rocha (1995), com a previsão de demanda o Planejamento e Controle da Produção (PCP) determina quando, onde, com quem e quando produzir. Além de controlar o abastecimento de materiais o PCP também objetiva manter sob domínio os recursos utilizados, quaisquer que sejam eles.

As previsões podem ser obtidas por duas técnicas de previsão, métodos qualitativos e quantitativos. Os métodos qualitativos, onde ocorre pouca disponibilidade de dados históricos

ou escassa relevância para a previsão, recorrem a julgamentos, intuição, pesquisas ou técnicas comparativas a fim de produzir estimativas quantitativas sobre o futuro (BALLOU, 2006).

Segundo Ritzman e Krajewski (2004), os métodos quantitativos subdividem-se em método causal e análise da série temporal. Para o método causal, os dados históricos são utilizados apenas para as variáveis independentes, como campanhas promocionais, condições econômicas e ações dos concorrentes, a fim de prever a demanda.

Já as séries temporais baseiam-se fortemente em eventos históricos, possuem um enfoque estatístico para projetar o tamanho da demanda futura, analisando ainda padrões de tendência e sazonalidade (BERTAGLIA, 2009).

A escolha do método adequado de previsão de demanda, está atrelado ao horizonte de tempo que se deseja obter a previsão. As projeções podem ser feitas para o curto, o médio e o longo prazo (RITZMAN; KRAJEWSKI, 2004).

De acordo com Fleury, Wanke e Figueiredo (2000), planilhas eletrônicas (Excel, Lotus etc.) possibilitam a gerência de empresas a implementar modelos de previsão de venda que subsidiam as atividades de planejamento e controle nos níveis estratégicos, táticos e operacionais.

Neste trabalho, propõe-se aplicar modelos de previsão de demanda os quais serão comparados com os atuais modelos de previsão de demanda adotados na empresa Keko Acessórios S.A para planejamento da produção.

O presente trabalho está estruturado em cinco seções. Na primeira seção estão apresentados a justificativa, os objetivos, a abordagem e delimitação do estudo. A segunda, apresentará uma revisão bibliográfica sobre o tema previsão de demanda e o embasamento teórico utilizado para a fundamentação do trabalho.

Na terceira seção será apresentado o perfil da empresa, a abordagem utilizada na proposta de aplicação de modelos de previsão e a metodologia aplicada para o desenvolvimento do trabalho. A quarta seção explana as etapas do trabalho, assim como ocorreu cada uma delas e os resultados obtidos. E por fim da seção cinco que está constituído das conclusões obtidas com o trabalho e com as aplicações.

1.1 JUSTIFICATIVA DO ESTÁGIO

“O desenvolvimento de técnicas de previsão cada vez mais sofisticadas, paralelamente ao advento de computadores e novas tecnologias de informação, tem levado diversas empresas

a se interessarem mais pelo processo de previsão de vendas” (FLEURY; WANKE; FIGUEIREDO, 2000, p. 210).

A situação econômica dos países pode ser fator importante para a instabilidade das vendas no setor automotivo. O mercado de personalização automotiva em especial não é um item imprescindível para o cliente, mas sim um opcional para embelezar seu veículo, por tanto podem apresentar oscilações de demanda.

A Keko Acessórios S.A atua no mercado de personalização automotiva, e para não ser alvo da concorrência, atua com diferencial de entrega a curto prazo com padrões de qualidades reconhecidos. Para que a ociosidade não afete a política da empresa, uma análise de demanda baseados em modelos matemáticos se faz necessário para auxiliar a programação de produção.

O método atualmente utilizado pode apresentar falhas por estar baseado em um *Forecast* construídos por meio de históricos de curto prazo, possibilitando assim, a omissão de dados importantes como sazonalidades, linhas de tendências de crescimento ou de descontinuidade dos seus produtos.

O inventário contábil da empresa mostra que 34% do estoque está voltado para produtos prontos para comercialização, sendo que desse percentual 20% são de produtos obsoletos ou sem giro nos últimos 2 anos. Análises de tendência podem ajudar a evitar a produção de itens de baixo giro ou que estão em processo de *phase out*.

A utilização de métodos de previsão de demanda, embasados em séries temporais, podem trazer dados para a formação de um planejamento refinado e assertivo, possibilitando a redução dos riscos de não atendimento dos pedidos no prazo e por consequência satisfação do bem mais precioso da empresa, o cliente.

O planejamento pode auxiliar na tomada de decisões, gerando melhor aproveitamento dos recursos e possibilitando ganhos financeiros com a redução do estoque de produtos prontos, melhorando ainda a qualidade do estoque dos produtos visando pedidos futuros.

1.2 OBJETIVOS

A seguir estão apresentados o objetivo geral e os objetivos específicos do trabalho.

1.2.1 Objetivo geral

O presente trabalho tem como objetivo geral propor a implementação de modelos matemáticos de previsão de demanda, para auxiliar na construção do plano mestre de produção da empresa Keko Acessórios S.A.

1.2.2 Objetivos específicos

Visando o atendimento ao objetivo geral do trabalho, foram definidos os seguintes objetivos específicos:

- a) realizar o levantamento e coleta de dados;
- b) implementar computacionalmente os modelos;
- c) analisar os resultados e comparar com o método atualmente utilizados;
- d) mensurar os ganhos para a empresa;
- e) definir o modelo mais adequado para a empresa;
- f) propor a implantação do modelo escolhido.

1.3 ABORDAGEM E DELIMITAÇÃO

O presente trabalho foi desenvolvido nas áreas de planejamento e controle da produção e no comercial da empresa Keko Acessórios S.A, aplicada a família de produtos de Peças e Acessórios (P&A) e *Aftermarket*. A proposta foi estudada e analisada nos dois semestres de 2017, delimitando-se a aplicação de modelos matemáticos para prever demandas futuras e auxiliar na programação de produção.

O estudo deste trabalho propõe a utilização de uma pesquisa aplicada com abordagem quantitativa exploratória, associada a uma pesquisa experimental. Segundo Gil (2010), a pesquisa aplicada, representa a aquisição de conhecimentos e a aplicação em situações específicas.

Na pesquisa exploratória não se trabalha com a relação entre as variáveis, seu objetivo fundamental é descrever ou caracterizar quantitativa ou qualitativamente a natureza delas (KÖCHE, 2012). Segundo Severino (2007), esse tipo de pesquisa busca levantar informações para mapear como se manifesta determinado objeto, delimitando assim um campo de trabalho.

A pesquisa experimental consiste em determinar um objeto de estudo, selecionar as variáveis que seriam capazes de influenciá-los, definir as formas de controle e de observação

dos efeitos que a variável produz no objeto (GIL, 2002). Para Köche (2012), consiste em analisar o problema, construir hipóteses e manipular os possíveis fatores referentes ao fenômeno observado, para avaliar a relação de causa e efeito preditas pelas hipóteses.

Partindo de uma pré-seleção dos modelos existentes na literatura, os modelos que mais se adaptam ao tipo de demanda da empresa e que utilizam dados de eventos históricos para prever as demandas futuras estarão apresentados no capítulo seguinte, sendo eles, modelos de séries temporais, de média móvel, com suavização exponencial e modelos do tipo *Box-Jenkins*. Tais modelos são comumente utilizados em dissertações, como exemplo as dissertações de Pellegrini (2000), Cavalheiro (2003) e Lemos (2006).

2 FUNDAMENTAÇÃO TEÓRICA

Nesse capítulo foram apresentados os modelos matemáticos de previsão de demanda, juntamente com seus conceitos e metodologias que serviram como referência para o desenvolvimento deste trabalho. Nessa abordagem será apresentada metodologias de séries temporais por meio de modelos de média móvel, ponderações exponenciais, padrões sazonais e *Box-Jenkins*, os quais compõem o assunto central do trabalho.

A revisão bibliográfica segue o princípio de proporcionar o entendimento dos modelos apresentados, sua aplicação e objetivos. E por fim auxiliar na avaliação dos modelos e escolha do mais adequado para implementação na empresa em estudo.

2.1 SÉRIES TEMPORAIS

Segundo Ritzman e Krajewski (2004), os modelos de série temporal, que tratam dos padrões horizontal de tendência e sazonal de demanda, utilizam informações de eventos históricos para prever as demandas futuras, se baseiam na hipótese de que o padrão anterior se repetirá no futuro.

Esse método estatístico é uma técnica que retardam mudanças fundamentais da série, uma vez que elas somente serão detectadas após a sua ocorrência. Ballou (2006, p. 245), destaca ainda que:

A natureza quantitativa das séries de tempo incentiva o uso de modelos matemáticos e estatísticos como principal fonte de previsão. A exatidão que se pode alcançar para períodos de tempo de menos de seis meses é em geral muito boa. Esses modelos funcionam bem simplesmente devido à estabilidade inerente às séries de tempo no curto prazo.

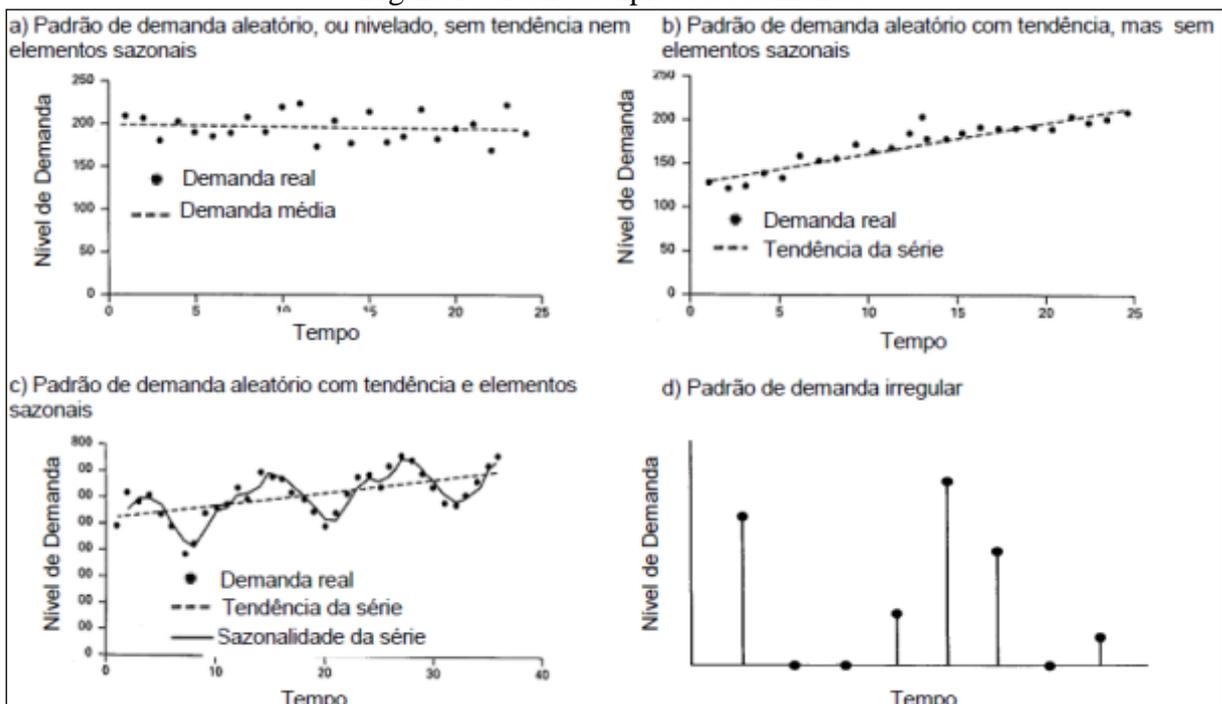
Chopra e Meindl (2011), explicam que esse modelo é mais apropriado quando a demanda não tem variação significativa de um ano para o outro. Completam ainda que por ser um método simples de implementar, pode servir de ponto de partida para a previsão de demanda.

Segundo Corrêa e Corrêa (2004), as séries temporais apresentam três componentes principais: tendência, ciclicidade e aleatoriedade. Enquanto outros autores, como Gaither e Frazier (2002) acrescentam a sazonalidade nessa lista. Os componentes anteriormente descritos estão explanados a seguir:

- a) tendência: conforme Ritzman e Krajewski (2004), é um aumento ou diminuição sistemática da média ao longo do tempo, que precisam ser levadas em conta na hora do cálculo, para que a previsão não fique acima ou abaixo da demanda real;
- b) ciclicidade: são séries que variam ao longo do tempo e que se repetem a cada intervalo específico, por exemplo, vendas no final do mês, e/ou vendas que variam com a estação do ano: inverno/verão (CORRÊA; CORRÊA, 2012);
- c) sazonalidade: Gaither e Frazier (2002) comentam que são flutuações que ocorrem na demanda durante um ano causadas por algum fator externo, como clima, feriados, eventos específicos ou outros fenômenos, e que tendem a se repetir em anos posteriores;
- d) aleatoriedade: são irregulares e imprevisíveis por isso não se encaixam nas outras categorias. No processo de previsão, o objetivo é minimizar a grandeza destes componentes por meio de acompanhamento e prevendo os outros componentes citados anteriormente (BOWERSOX; CLOSS; COOPER, 2007).

A distribuição dos dados da demanda de uma série temporal varia conforme o caso estudado, um dos padrões ilustrados na Figura 1 será tipicamente uma representação aproximada do caso.

Figura 1 – Padrões típicos de demanda



Fonte: Ballou (2001).

Quando há mudanças significativas na taxa de crescimento ou na tendência, o padrão de demanda passa por um ponto crítico. As séries temporais não são suscetível a esses pontos, sendo assim, outras abordagens devem ser integradas para determinar quando é provável que ocorram pontos críticos (BOWERSOX; CLOSS; COOPER, 2007).

De acordo com Ritzman e Krajewski (2004), as séries temporais se apresentam em um padrão horizontal e aleatório, e como o erro aleatório é difícil de prever, estimativas de médias são adotadas para prever a demanda.

2.2 MÉDIA MÓVEL

A Média Móvel (MM) é uma metodologia que utiliza a média dos eventos de períodos anteriores para prever a demanda futura. Em resumo, a média dos n períodos anteriores servirá como previsão para o próximo período.

2.2.1 Média Móvel Simples

Bowersox, Closs e Cooper (2007) afirmam que as Médias Móveis Simples (MMS) usam os dados dos eventos mais recentes para prever a demanda futura, através de uma média dos intervalos anteriores, que podem ser de 1, 3, 4 e 12 períodos. Onde 1 é a previsão baseada no último período e 12 é a previsão baseada nos últimos 12 períodos.

Ballou (2006), acrescenta que as médias podem ser aritméticas ou ponderadas, e o número de pontos é escolhido de tal maneira buscando eliminar o efeito da sazonalidade e da irregularidade. Segundo Bowersox, Closs e Cooper (2007), em termos matemáticos, a MMS é expressa da seguinte forma:

$$F_t = \sum_{i=1}^n S_{t-1}/n \quad (1)$$

Onde:

F_t = previsão por MMS para o intervalo de tempo t ;

S_{t-1} = evento para o intervalo de tempo i ;

n = quantidade total de intervalos de tempo.

Conforme Chopra e Meindl (2011), para calcular a MMS para o próximo período, acrescenta-se a observação mais recente e retira-se a mais antiga. Esta alteração servirá como previsão para o novo período.

2.2.2 Média Móvel Ponderada

A Média Móvel Ponderada (MMP) segue o mesmo conceito da MMS, porém cada demanda histórica tem seu próprio peso, que é multiplicado pelo valor daquele período para formar a demanda do próximo período. A soma de cada peso dos n períodos é igual a um (RITZMAN; KRAJEWSKI, 2004).

Ballou (2006), cita ainda que as observações mais recentes recebem cotações maiores que as observações mais antigas. A MMP é calculada pela seguinte equação:

$$F_t = \frac{\sum_{t=1}^n W_{t-1} S_{t-1}}{\sum W_t} \quad (2)$$

Onde:

F_t = previsão por MMP para o intervalo de tempo t ;

S_{t-1} = evento para o intervalo de tempo i ;

W_{t-1} = pesos atribuídos ao período $t - 1$;

n = quantidade total de intervalos de tempo.

Essa alteração no cálculo da MM permite que a pessoa que está fazendo a previsão de demanda atribua importâncias relativas aos dados de cada período (GAITHER; FRAZIER, 2002).

2.3 SUAVIZAÇÃO EXPONENCIAL

Ritzman e Krajewski (2004) afirma que, a suavização exponencial é um modelo sofisticado de MMP, que atribui pesos maiores as demandas recentes, e é também o modelo de previsão utilizado com mais frequência, devido a sua simplicidade e necessidade de poucos dados para apoiá-lo.

Para Ballou (2006), essa técnica é a melhor em se tratando de previsão a curto prazo. O autor afirma ainda que o modelo se adapta às mudanças fundamentais nos dados de previsão e mostra-se como o mais preciso dos modelos entre os concorrentes do mesmo tipo.

2.3.1 Suavização exponencial simples

Esse modelo é utilizado para prever valores futuros, quando a série temporal média se mantém constante. Segundo Dias (2009), a previsão baseada nesse modelo leva em conta a tendência geral e reduz a relação de valores aleatórios, ou seja, é atribuído parte da diferença entre real e o previsto a uma mudança de tendência e o restante a causas aleatórias.

A suavização exponencial simples pode ser expressa por:

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

Onde:

F_{t+1} = previsão para o intervalo de tempo $t+1$;

S_t = evento para o intervalo de tempo t ;

F_t = previsão calculada para o intervalo de tempo t ;

α = é a constante de amortecimento ($0 \leq \alpha \leq 1$).

O valor de α determina o equilíbrio entre a sensibilidade e a estabilidade das previsões. Adotando valores maiores para a constante, as demandas recentes têm mais relevância, o que torna a previsão mais sensível. Por outro lado, valores menores dão mais estabilidade a previsão, pois trata de forma uniforme as demandas passadas.

2.3.2 Modelo de Holt

Esse modelo, é uma versão corrigida do modelo de suavização exponencial, utilizado quando há uma tendência substancial significativo nos dados, que podem causar erros inaceitáveis na previsão de demanda (BALLOU, 2001).

Segundo Pellegrini (2000), esse modelo emprega duas constantes de suavização α e β , e seus valores podem ser determinado de maneira semelhante a utilizada no modelo de

suavização exponencial simples, ou seja, uma combinação de valores arbitrários que minimizam o erro do previsto em relação ao real.

A previsão de demanda utilizando o modelo *Holt* pode ser obtida por meio de uma combinação de equações. O conjunto das equações do modelo são:

$$P_{t+1} = \alpha S_t + (1 - \alpha) (P_t + T_t) \quad (4)$$

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

$$F_{t+1} = P_{t+1} + T_{t+1} \quad (6)$$

Onde:

F_{t+1} = previsão da tendência corrigida para o intervalo de tempo t+1;

S_t = evento para o intervalo de tempo t;

P_t = previsão inicial para o período t;

T_t = Tendência para o período t;

α = constante de amortecimento ($0 \leq \alpha \leq 1$);

β = constante de tendência ($0 \leq \beta \leq 1$).

As Equações (4) e (5) fazem uma estimativa do nível e da inclinação da série temporal. Já a Equação (6), calcula a previsão da demanda para os próximos períodos (PELLEGRINI, 2000).

O Modelo de *Holt* requer um valor inicial de T para o cálculo da previsão. Quando não se dispõe de dados históricos, considera-se que a tendência inicial é Zero. Por outro lado, quando se tem dados históricos significativos, Pellegrini (2000) sugere o cálculo da declividade média das últimas observações, utilizando a seguinte equação:

$$T_{t-1} = \frac{\sum_t^n (R_{t-1} - R_{t-2})}{n - 1} \quad (7)$$

Onde:

T_{t-1} = tendência para período t-1;

R_{t-1} = evento para o período t-1;

R_{t-2} = evento para o período t-2;
 n = quantidade de períodos.

2.3.3 Modelo de *Winters*

O modelo de *Winters* é uma versão da suavização exponencial que considera as tendências e sazonalidades. Cavalheiro (2003) comenta que o modelo descreve os dados da demanda quando, além de ter um comportamento sazonal também é evidenciado a tendência de forma linear. Ballou (2001) complementa que o modelo tem como objetivo prever o índice da demanda real para a tendência e após dessazonizá-lo para formar a previsão.

Winters (1960 apud LEMOS 2006), o modelo oferece duas abordagens distintas, as quais são identificadas pela forma como varia a amplitude da sazonalidade de acordo com a demanda. São elas aditiva e multiplicativa.

2.3.3.1 Modelo Sazonal Multiplicativo

O modelo multiplicativo de *Winters*, é apropriada para séries temporais onde a amplitude da sazonalidade varia com o passar do tempo, ou seja, varia com o nível da demanda. As equações para este modelo são (BALLOU, 2001):

$$L_t = \alpha \left(\frac{R_t}{S_{t-s}} \right) + (1 - \alpha) (L_{t-1} + T_{t-1}) \quad (8)$$

$$T_t = \beta(L_t - L_{t-1}) + (1 - \beta) T_{t-1} \quad (9)$$

$$S_t = \gamma \left(\frac{R_t}{S_{t-s}} \right) + (1 - \gamma) S_{t-s} \quad (10)$$

$$P_{t+k} = (L_t + kT_t) S_{t-s+k} \quad (11)$$

Onde:

P_{t+k} = previsão para o período t+k;

S_t = previsão inicial para o período t;

T_t = tendência para período t;

S_t = índice sazonal para o período t;

- s = período de tempo para uma estação completa de sazonalidade;
 α = constante de amortecimento ($0 \leq \alpha \leq 1$);
 β = constante de tendência ($0 \leq \beta \leq 1$);
 γ = constante de sazonalidade ($0 \leq \gamma \leq 1$).

Assim como no modelo de *Holt*, o modelo de *Winters* requer um valor inicial para a tendência, o qual pode-se utilizar a Equação (7), anteriormente descrita. Além deste valor, é necessário um valor inicial para o índice sazonal S_{t-s} . Para esta estimativa necessita-se de no mínimo uma estação completa de observações ou s períodos. O cálculo para encontrar o índice sazonal pode ser realizado a partir da seguinte equação (PELLEGRINI, 2000):

$$S_{t-s} = R_{t-1} / P_{t-1} \quad (12)$$

Onde:

- S_{t-s} = índice sazonal para o período t ;
 s = período de tempo para uma estação completa de sazonalidade;
 R_{t-1} = evento para o período $t-1$;
 P_{t-1} = previsão para o período $t-1$.

2.3.3.2 Modelo Sazonal Aditivo

O modelo aditivo de *Winters*, é apropriada para séries temporais onde a amplitude da sazonalidade é constante ao longo do tempo, ou seja, é independente do nível de demanda. As equações para esse modelo são:

$$L_t = \alpha(R_t - S_{t-s}) + (1 - \alpha) (L_{t-1} + T_{t-1}) \quad (13)$$

$$T_t = \beta(L_t - L_{t-1}) + (1 - \beta) T_{t-1} \quad (14)$$

$$S_t = \gamma (R_t - L_t + (1 - \gamma)S_{t-s}) \quad (15)$$

$$P_{t+k} = L_t + kT_t + S_{t-s+k} \quad (16)$$

Onde:

P_{t+k} = previsão para o período $t+k$;

S_t = previsão inicial para o período t ;

T_t = tendência para período t ;

S_t = índice sazonal para o período t ;

s = período de tempo para uma estação completa de sazonalidade;

α = constante de amortecimento ($0 \leq \alpha \leq 1$);

β = constante de tendência ($0 \leq \beta \leq 1$);

γ = constante de sazonalidade ($0 \leq \gamma \leq 1$).

A equação para tendência permanece a mesma utilizada no modelo multiplicativo, Equação (14). Com relação às componentes de sazonalidade, diferencia-se do modelo anterior pois está efetuando operações de soma e subtração, ao invés de multiplicação e divisão. O cálculo dos valores iniciais de índice sazonal S_{t-s} , utilizando a seguinte equação:

$$S_{t-s} = R_{t-1} - P_{t-1} \quad (17)$$

Onde:

S_{t-s} = índice sazonal para o período t ;

s = período de tempo para uma estação completa de sazonalidade;

R_{t-1} = evento para o período $t-1$;

P_{t-1} = previsão para o período $t-1$.

2.4 BOX-JENKINS

Modelos auto-regressivos Integrados de MM, conhecido como *Box-Jenkins* são modelos matemáticos para realizar previsões futura analisando o comportamento da correlação seriada ou a auto-correlação existentes entre os valores da série temporal (WERNER, 2004). Este modelo utiliza algoritmos matemáticos complexos para identificar a forma do modelo matemático mais adequado para a série analisado que quando bem modelados fornecem boas previsões.

Pellegrini (2000), afirma que o modelo, também conhecido como ARIMA (*AutoRegressive Integrated Moving Average*), parte da ideia de que os valores de uma série temporal são altamente dependentes, podendo ser explicados por valores prévios da demanda.

Lemos (2006), explica que o *Box-Jenkins* modela a função de auto-correlação de uma série temporal estacionária com o mínimo de parâmetros possível. A notação geral é expressa da seguinte forma ARIMA $(p, d, q)(P, D, Q)s$, onde (AR) é o termo auto-regressivos, que modelam a dependência de valores atuais com valores passados; (I) é o termo de integração, que remove a tendência tornando a série estacionária; e (MA) é o termo de MM, o qual assume que valores são dependentes de erros de previsão de períodos passados. A seguir estarão detalhadas as demais componentes da notação:

p = ordem máxima de parâmetros de auto-regressão simples;

d = número de diferenciações não sazonais aplicadas para tornar a série temporal estacionária;

q = ordem máxima dos parâmetros de MMS;

P = ordem máxima dos parâmetros de auto-regressão sazonal;

D = número de diferenciações sazonais aplicadas para tornar a série temporal estacionária;

Q = número máximo dos parâmetros de MM sazonal;

s = número de períodos por ciclo sazonal.

Werner (2004) completa ainda que o modelo *Box-Jenkins*, podem ter sua série modelado por três filtros ou ainda por um subconjunto de ambas, resultando em vários modelos que serão explanados a seguir.

2.4.1 Modelos estacionários

O modelo é considerado estacionário quando em todos os momentos a média das variáveis e sua variância se mantém constante, ou seja, o processo está em equilíbrio ao longo da série temporal.

2.4.1.1 Modelos auto regressivos (AR)

Para Lemos (2006), este modelo apresenta uma regressão da variável dependente em função de seus valores passados. Ele é útil na representação de um grande número de séries temporais.

Neste modelo, Werner e Ribeiro (2003), afirmam que a série de dados Y_t históricos é descrita por seus valores passados regredidos e pelo ruído aleatório ε_t . Assim, um modelo AR é dado por (Lemos 2006):

$$Y_t = c + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + \varepsilon_t \quad (18)$$

$$\varepsilon_t = Y_t (1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p) \quad (19)$$

$$\varepsilon_t = \phi(B) Y_t \quad (20)$$

Onde:

c = termo constante;

ϕ_i = coeficiente de auto-regressão do período i ;

ε_t = erro aleatório no período t ;

$\phi(B)$ = polinômio auto-regressivo de ordem p .

2.4.1.2 Modelo de Médias Móveis (MA)

Em um modelo de MM, a série Y_t é resultado da combinação dos ruídos ε do período atual com os ruídos ocorridos em períodos passados (WERNER; RIBEIRO, 2003). Assim, um modelo MA é dado por:

$$Y = c - \theta_1 e_{t-1} + \theta_2 e_{t-2} + \dots + \theta_q e_{t-q} + e_t \quad (21)$$

$$Y_t = \theta(B) e_t \quad (22)$$

Onde:

θ_i = coeficiente de MM do período i ;

$\theta(B)$ = polinômio de MM de ordem q .

2.4.1.3 Modelo auto-regressivos e de média móvel (ARMA)

Esse modelo é uma combinação de características de um processo auto-regressivo (AR) e de um processo de MM (MA). Possível de modelar qualquer série estacionária, o modelo *AutoRegressive Moving Average* (ARMA) (p, q), utiliza menos termos que se os processos AR e MA forem trabalhados separadamente. Lemos (2006) traz as seguintes equações para o modelo:

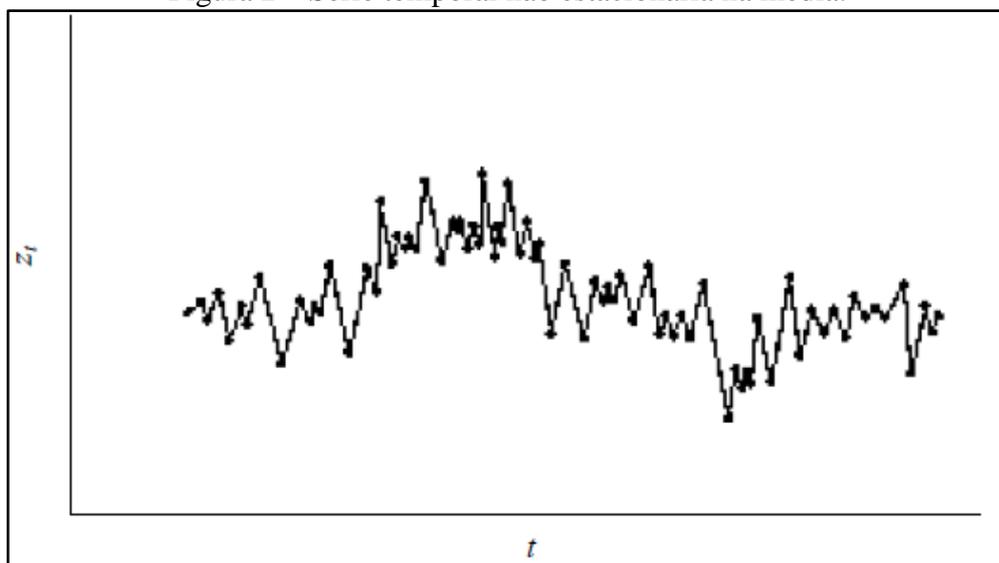
$$Y_t = c + \phi_1 Y_{t-1} + \dots + \phi_p Y_{t-p} + e_t - \theta_1 e_{t-1} - \dots - \theta_q e_{t-q} \quad (23)$$

$$\phi_t(B)Y_t = c + \theta(B)e_t \quad (24)$$

2.4.2 Modelos não estacionários

As séries temporais, nem sempre apresentam uma média constante, ou seja, em nenhum intervalo os dados se repetem conforme as observações de outro intervalo anterior (PELLEGRINI, 2000). Werner (2004), complementa que elas têm média e variância dependentes do tempo. Tais séries são conhecidas como não estacionárias na média, sua distribuição se comporta de acordo com o padrão representado pela Figura 2.

Figura 2 – Série temporal não estacionária na média.



Fonte: Pellegrini (2000).

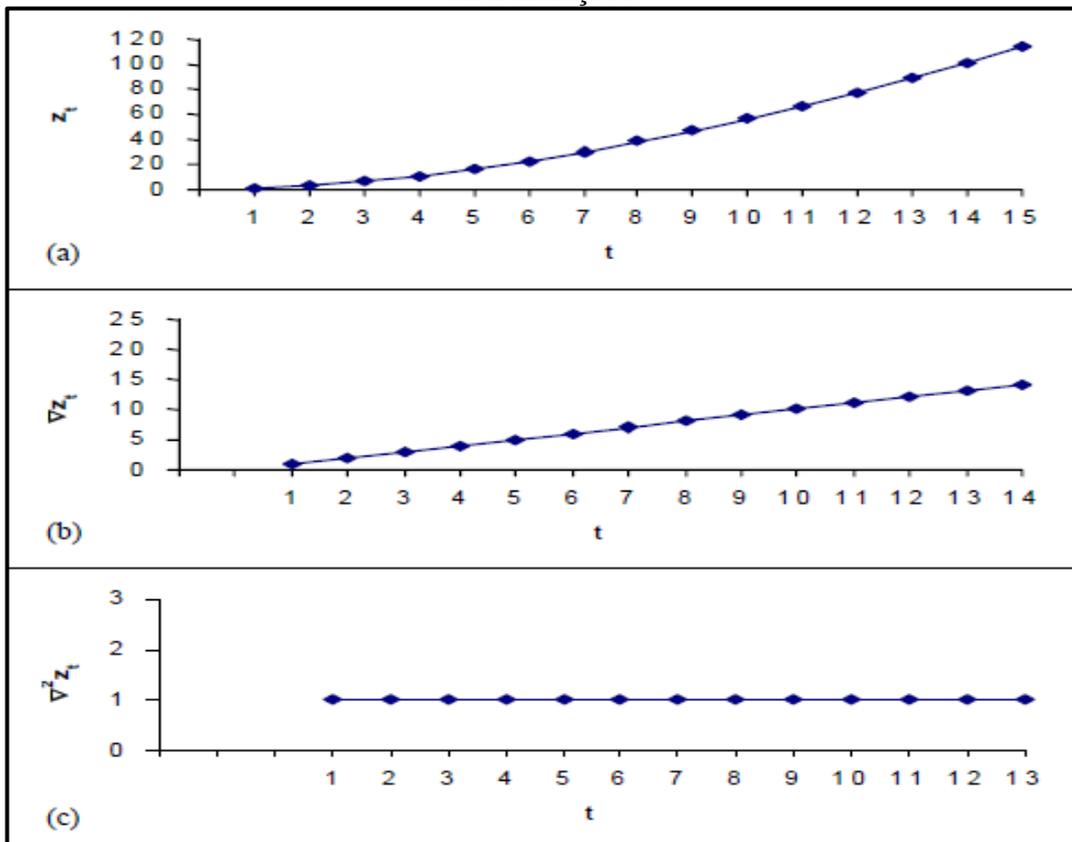
A não estacionariedade de uma série pode ser detectado graficamente, buscando-se os padrões que, Werner e Ribeiro (2003), explicam que esse comportamento implica em dois fatores importantes:

- os dados estão dispostos de maneira a formar uma inclinação e não estão em torno de uma linha horizontal ao longo do tempo.
- as variações dos dados não se mantêm constantes, ocorrem flutuações ascendentes e descendentes ao longo do tempo, indicando a alteração da variância.

2.4.2.1 Modelos auto-regressivos integrados de médias móveis (ARIMA)

A maioria dos procedimentos de análise estatística envolvendo séries temporais, pressupõe que os dados sejam estacionários em relação a sua média e variância (WERNER, 2004). Nos casos de modelos não estacionários, se faz necessários torná-las estacionárias através de diferenciação da média e transformações na variância como pode ser observado na Figura 3.

Figura 3 – Redução da não estacionariedade de uma série temporal após sucessivas diferenciações.



Fonte: Pellegrini (2000).

Na Figura 3(a), tem-se uma série temporal não estacionária. Após a primeira diferenciação, Figura 3(b), nota-se não estacionariedade apenas na média, que é corrigida com a segunda diferenciação conforme Figura 3(c), tornando-se estacionária (PELLEGRINI, 2000).

Werner e Ribeiro (2003), explicam que para situações reais, que necessitam de diferenciação para tornar a série estacionária, uma ou duas diferenças já são suficientes. Para tanto a utilização do modelo ARIMA (p, d, q) se faz necessário:

$$\phi_t(B)(1 - B)^d Y_t = \theta(B)e_t \quad (25)$$

2.4.3 Modelos sazonais

Sazonalidade é um conjunto de movimentos ou flutuações que ocorrem sistematicamente dentro de um período igual ou menor que um ano. As demandas de produtos e serviços quase sempre apresentam uma sazonalidade, que pode não ser regular (CAVALHEIRO, 2003).

Werner (2004), comenta que os modelos *Box-Jenkins* exploram a auto-correlação entre os valores da série em instantes sucessivos. A forma geral para o modelo sazonal auto-regressivo integrado a MM é apresentado por (BOX, JENKINS e REINSEL; 2008):

$$\Phi(B^s)(1 - B^s)^d Y_t = \Theta(B^s)e_t \quad (26)$$

Onde:

s = variável que represento o intervalo de tempo da série sazonal;

$\Phi(B^s)$ = polinômio auto-regressivo sazonal de ordem P ;

$\Theta(B^s)$ = polinômio de MM sazonal de ordem Q .

2.4.4 Etapas da metodologia *Box-Jenkins*

A construção de modelos *Box-Jenkins* é baseada em um ciclo interativo, no qual, segundo Box, Jenkins e Reinsel (2008), a escolha é feita com base nos próprios dados. São três as etapas para construção do modelo (WERNER, RIBEIRO, 2003):

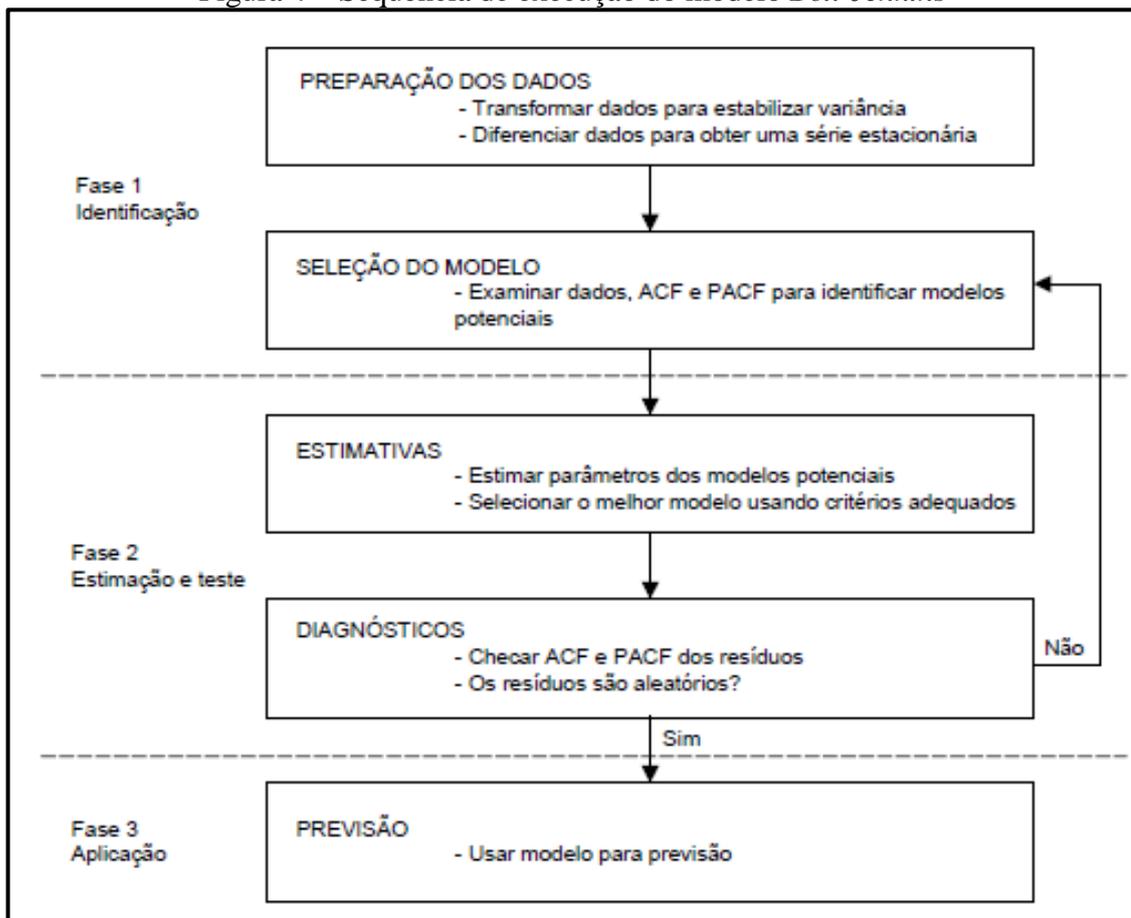
- a) identificação: descobrir, através do comportamento da série, qual dentre as várias versões dos modelos, sazonais ou não descreve os dados. A identificação do

modelo a ser estimado ocorre pelo comportamento das funções de auto-correlações (*AutoCorrelation Function (ACF)*) e das funções de auto-correlações parciais (*Partial AutoCorrelation Function (PACF)*);

- b) estimação: consiste em estimar os parâmetros dos componentes auto-regressivos e os parâmetros dos componentes de MM, além da variância;
- c) verificação: consiste em avaliar se o modelo estimado é adequado para descrever o comportamento dos dados.

Segundo Lemos (2006), as etapas que de fato fazem a operacionalização do modelo *Box-Jenkins* para a modelagem de séries temporais seguem os passos apresentados na Figura 4.

Figura 4 – Sequência de execução do modelo *Box-Jenkins*



Fonte: Lemos (2006).

O modelo *Box-Jenkins* apresenta melhor acurácia, se as correlações históricas forem fortes, homogêneas e estáveis, caso contrário o modelo pode extrapolar correções inadequadas.

A série temporal precisa apresentar o menor erro em relação a outros modelos, e também precisa ser estacionária (LEMOS, 2006).

Segundo Pellegrini (2000), umas das principais ferramentas utilizadas no processo de identificação é a análise analítica e gráfica dos coeficientes de auto-correlação (ACF) e de auto-correlação parcial (PACF), determina se a série é estacionária. O coeficiente de auto-correlação representa a correlação da série temporal com ela mesma:

$$r_k = \frac{\sum_{t=k+1}^n (Y_t - \bar{Y})(Y_{t-k} - \bar{Y})}{\sum_{t=1}^n (Y_{t-k} - \bar{Y})^2} \quad (27)$$

Onde:

r_k = coeficiente de correlação da observação Y_t com a observação Y_{t-k} ;

k = ordem do coeficiente de correlação;

Y_t = demanda observada no período t ;

\bar{Y} = média das observações da série temporal.

Usadas para mensurar o grau de associação entre Y_t e Y_{t-k} , as auto-correlações parciais de ordem k pode ser calculado fazendo a regressão da variável Y_t com as observações da mesma variável em períodos passados (LEMOS, 2006):

$$Y_t = b_0 + b_1 Y_{t-1} + b_2 Y_{t-2} + \dots + b_k Y_{t-k} \quad (28)$$

Onde:

b_k é o coeficiente de regressão múltipla.

Segundo Box, Jenkins e Reinsel (2008), em séries estacionárias os coeficientes ACF e PACF tendem a valores próximos a zero, enquanto séries temporais não estacionárias apresentam coeficientes significativamente diferentes de zero para vários períodos de tempo.

2.5 ERROS DE PREVISÃO

Os cálculos de previsões da demanda de séries temporais estão relacionados a uma média de observações passadas para prever o futuro, mas sabe-se que o futuro não está

espelhado no passado, por esse motivo a previsão pode apresentar erros. O erro de previsão se refere a quão próximo a previsão calculada está da demanda real (BALLOU, 2001).

Os erros se caracterizam em dois tipos, erros aleatórios, que resulta de fatores imprevisíveis, e os erros de viés, que resultam de enganos consistentes, ou ainda de negligenciar ou de não estimar de forma precisa os padrões de demanda da série, como sazonalidade ou tendências (RITZMAN; KRAJEWSKI, 2004).

Para Chopra e Meindl (2003), é importante que se faça a análise de erros para prever se o modelo de previsão adotado está prevendo a demanda de maneira detalhada e sistemática. Ainda segundo o autor, tendo a estimativa dos erros os mesmos devem estar considerados em um plano de contingência para poder tomar as ações corretivas de forma correta.

Ritzman e Krajewski (2004) complementam, que é impossível eliminar todas as formas de erros, os analistas de previsão tentam minimizar o efeito deles escolhendo modelos de previsão adequados. Um formato simples para identificação dos erros é dado por:

$$E_t = R_t - P_t \quad (29)$$

Onde:

E_t = erro de previsão para o período t ;

P_t = previsão para o período t ;

R_t = evento do período t .

Quando a Equação (29) for utilizada para vários períodos de demanda, por apresentar resultado positivos e negativos, a soma dos erros pode ser anulada e não expressar a real situação do problema. Para evitar que essa situação ocorra, Pellegrini (2000) afirma que há diferentes métodos de se calcular os erros ambos auxiliam na escolha do modelo de previsão ideal, os mais utilizados são:

$$MQE = \frac{1}{n} \sum_{t=1}^n e_t^2 \quad (30)$$

$$MAE = \frac{1}{n} \sum_{t=1}^n |e_t| \quad (31)$$

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{e_t}{R_T} \cdot 100 \right| \quad (32)$$

Onde:

MQE = Média do Quadrado dos Erros;

MAE = Média Absoluta dos erros;

MAPE = Média Absoluta Percentual dos Erros;

e_t = erro de previsão para o período t ;

R_T = evento do período t .

2.6 CUSTO FINANCEIRO DE ESTOQUE

Para mensurar os ganhos com a aplicação do modelo adequado, foi analisado o custo financeiro com o estoque, calculando o valor monetário do estoque ao final do período, aplicada a uma taxa de juro mensal considerada como "custo de oportunidade". Segundo Puccini (2011), para o cálculo do valor futuro utiliza-se a fórmula a seguir:

$$FV = PV(1 + i)^n \quad (33)$$

Onde:

FV = Valor futuro;

PV = Valor presente;

i = Taxa de juros mensal;

n = Período médio de estoque, em meses.

O valor presente é dado pelo custo de fabricação ou aquisição daquele determinado item. A diferença entre o valor futuro e o valor presente será o custo financeiro de manter o estoque do item.

2.7 CONSIDERAÇÕES DO CAPÍTULO

Esse capítulo apresentou a fundamentação teórica das técnicas e modelos de previsão de demanda que se mostraram eficientes na resolução do problema em questão. O referencial apresentado possibilitou o entendimento das variáveis pertinentes ao problema e pode-se também observar que a análise dos eventos passados confiáveis, bem como o bom dimensionamento temporal e a interpretação correta das ocorrências como sazonalidade e

tendências são pontos chaves para determinar o melhor modelo a ser utilizado em cada conjunto de dados histórico existente.

Levando em conta que o conteúdo desse capítulo constitui a base teórica que suporta esse trabalho, pode-se concluir que é de suma importância, pois embasam a metodologia proposta para o desenvolvimento e alcance dos objetivos deste trabalho, assim com os parâmetros necessários para obtenção dos resultados.

3 PROPOSTA DO TRABALHO

No presente capítulo estão apresentadas as metodologias atuais de previsão de demanda adotadas na empresa Keko Acessórios S.A, assim como as metodologias propostas a serem implantadas. O objetivo é a redução dos custos do estoque de produtos acabados e o aumento da qualidade deste estoque, visando o atendimento ao cliente e melhoria no prazo de entrega.

Os dados estão voltados à implementação dos modelos para prever as demandas nos canais de venda do P&A e *Aftermarket*, os quais não se tem uma visão futura de vendas sinalizadas pelos clientes, situação essa que ocorre nos canais do *Original Equipment Manufacturer* (OEM), por exemplo.

Os processos foram descritos, na maioria das vezes, a partir de ferramentas do *Enterprise Resource Planning* (ERP) da empresa. Na Keko o sistema de gestão utilizado é o Datasul, *software* brasileiro de uma das maiores empresas da América Latina, a TOTVS.

3.1 PERFIL DA EMPRESA E AMBIENTE DE ESTÁGIO

Com mais de 30 anos no segmento automotivo, fundada pelo Sr. Henry Mantovani com o propósito de oferecer um produto inovador para a época, a Keko Acessórios S.A nasceu como um pequeno empreendimento familiar voltado à fabricação artesanal de acessórios para picapes e veículos *Off-Road*, especialmente *Jeep-Willys*, F1000, D20, C10 e Veraneio.

A criação do produto porta-estepe, idealizado por Henry, foi o que colocou a empresa em evidência e alavancou a sua produção. O espírito empreendedor de Henry desencadeou em seus filhos Leandro e Juliano a vontade de ampliar cada vez mais a empresa, resolveram então apostar no negócio promissor e desafiador que tinha se iniciado.

A Keko ocupa a liderança nacional no segmento de personalização automotiva, oferece produtos inovadores e de vanguarda, que se diferenciam pelo *designer*, qualidade e tecnologia aplicada. A empresa é fornecedora oficial, com projetos OEM, linha de montagem, das grandes montadoras incluindo a Ford, General Motors, Mitsubishi, Toyota, Volkswagen, Honda e Fiat. É reconhecida em 40 países dos 5 continentes atuando no mercado de *aftermarket*, peças de reposição nas lojas de acessórios multimarcas e para exportação, e no mercado de P&A fornecendo peças originais nas concessionárias autorizadas.

O *mix* de produtos da marca para o segmento de leves, picapes e *Sport Utility Vehicle* (SUV) incluem protetores frontais, estribos, santantônios, engates de reboque, bagageiros, capotas marítimas, capas de estepe, protetores de caçamba, entre outros itens.

Grupos de *Kaizen* atuam na melhoria contínua dos processos, com foco na produção enxuta, e disseminando a cultura de melhoria dentro da empresa, buscando sempre a eliminação de todos os tipos de perdas e desperdícios. Visando o crescimento sustentável, atua com práticas e filosofias de respeito ao meio ambiente engajados a um Sistema de Gestão Ambiental.

Atualmente o parque fabril da empresa localiza-se no distrito industrial da cidade de Flores da Cunha, ilustrado na Figura 5, tendo 20,5 mil m² de área construída e 100 mil m² de área total.

Figura 5 – Unidade atual da empresa Keko Acessórios S.A em Flores da Cunha – RS.



Fonte: Keko (2017)

Nesta nova fábrica, o Centro de Desenvolvimento e Inovação (CDI) ocupa um prédio de 800 m² e conta com equipamentos e *softwares* dedicados exclusivamente à pesquisa e desenvolvimento de novas tecnologias, materiais e produtos. A moderna sede própria foi projetada a partir de conceitos de sustentabilidade, ecoeficiência e compromisso social.

3.2 CENÁRIO ATUAL

A Keko Acessórios S.A. aplica uma metodologia para organizar seu negócio prevendo anualmente o consumo de todos os recursos necessários para o ano seguinte. A ferramenta utilizada é a Previsão Orçamentária Anual (POA), nela considera-se uma previsão das vendas mensais embasados em dados históricos, aplicando sobre eles um percentual de aumento esperado.

Essa previsão inicial não tem uma análise detalhada dos eventos históricos, uma etapa posterior é então realizada para ajuste e refinamento dos dados. O *Forecast* é uma revisão do POA, que considera a atual situação da empresa e do mercado para prever a demanda do mês seguinte. Além de dar subsídios a programação de produção, é uma importante ferramenta que auxilia a gestão na tomada de decisão de curto prazo, como contratações e compra de matéria-prima.

A metodologia de programação de produção adotada pela Keko, tem como principal base a carteira de pedidos firmadas pelos clientes para o mês. Em segundo plano, para preencher a capacidade produtivas das linhas, utiliza-se as informações do *Forecast* mensal que servirão para formar um estoque regulador de produtos prontos para atendimento aos pedidos futuros. O nível do estoque regulador é composto por 80% da média dos últimos 6 meses, e o mesmo é revisado a cada 3 meses.

O *Forecast* mensal é fornecido pelo setor comercial onde para sua construção são utilizadas planilhas de Excel e relatórios provenientes do sistema de gestão, e seguem uma rotina de atividades até a concretização do mesmo.

Periodicamente, itens com baixa comercialização são excluídos do catálogo de vendas e inativados do processo, buscando evitar que itens indevidos sejam produzidos. A fase inicial do *Forecast* consiste em atualizar a lista de itens ativos da empresa.

O código de todos os itens que são vendidos pela Keko, ou seja, os itens nível zero da estrutura de produto, iniciam pelo numeral 9. Atualmente a Keko conta com 1106 *part numbers* ativos de venda, destes 696 estão dentro dos canais que compõem a delimitação deste trabalho.

O *Forecast* é desenvolvido a partir da média aritmética de vendas diárias dos últimos 3 meses multiplicado pela quantidade de dias úteis para o mês da previsão, por exemplo, se o mês vigente for o mês de maio, utiliza-se a média de venda diária de fevereiro, março e abril para prever a demanda do mês de junho.

O histórico de vendas é obtido por meio do sistema de gestão da empresa utilizando a tela KEKO56P, onde o único parâmetro a ser ajustado deve ser o período de tempo que se quer obter os dados. O relatório obtido é um arquivo no formato .txt, bloco de notas, onde as informações de cada pedido implantado estão dispostas em linhas. Em cada linha estão todas as informações referentes ao pedido específico, como canal de venda, item, quantidade, cliente entre outros.

Para maior facilidade de computação dos dados os mesmos são tabulados no Excel e ficam dispostos conforme Figura 6. O relatório tabulado, está ordenado por data de implantação do pedido.

Figura 6: Relatório de venda por data tabulado

Cliente	Canal	Código	Descrição	.Un	Qtd. Pedido	Data Impl.
TUNING SC	2	9.101.05.700BR	K672BR Sobrecapa Sto K3 Amarok 10- Branco Cristal	Cj	1	10/03/2017
GM Sorocaba	998	9.136.07.600AZ	94760207 Travessa de Teto Spin 13- (PA)	Cj	2	10/03/2017
GM Sorocaba	998	9.136.07.600AZ	94760207 Travessa de Teto Spin 13- (PA)	Cj	2	10/03/2017
GM Sorocaba	998	9.136.07.600AZ	94760207 Travessa de Teto Spin 13- (PA)	Cj	1	10/03/2017
Amisa Panamb	999	9.275.00.001PR	BH2T/16450/AA/PR Estribo Tubular Ranger CD 13- XL/XLS	Pr	1	10/03/2017
Guimarães Mg	2	9.275.00.610PR	K318ALPR Estribo Integral Ranger CD 13-	Pr	1	10/03/2017
Indiana	999	9.275.03.001PR	BH2T/19D520/AA/ Engate Reboque Ranger 13- (PA)	Cj	4	10/03/2017
E.B.M.	2	9.275.03.003PR	K536PR Engate de Reboque K1 Ranger 12-	CJ	1	10/03/2017
Saga Parque	999	9.275.05.012CP	BH3T/99440A60/ZA/ Santantônio K3 Ranger CS XL/XLS	Cj	2	10/03/2017
Indiana	999	9.275.05.015C8	BH4T/99440A60/AA Santantônio K3 Ranger 13- CS Cinza	Cj	1	10/03/2017
Emerson	2	9.275.05.026CR	K478CR Novo Santantônio K1 Ranger CD 13-	Cj	1	10/03/2017
Emerson	2	9.275.05.026PR	K478PR Novo Santantônio K1 Ranger CD 13-	Cj	1	10/03/2017
BEAUT	901	9.275.12.005FX	KC086FX Capota Marítima All Black Nova Ranger CD 13-	Cj	240	10/03/2017
BEAUT	901	9.275.12.005FX	KC086FX Capota Marítima All Black Nova Ranger CD 13-	Cj	240	10/03/2017
Cimavel	999	9.275.12.008FX	BH2T/99501A42/BA/ Capota Marítima 5' Ranger 13- CD XLT (PA)	Cj	3	10/03/2017
Amisa Panamb	999	9.275.12.008FX	BH2T/99501A42/BA/ Capota Marítima 5' Ranger 13- CD XLT (PA)	Cj	1	10/03/2017

Fonte: Elaborado pelo Autor (2017).

Os clientes da Keko estão classificados de acordo com o mercado de atuação, essa classificação é separada por canal de venda. A Figura 7 ilustra os canais e sua descrição. O mesmo item pode estar alocado em canais diferente, e para a correta análise dos dados, os itens devem ser analisados separadamente em cada canal, pois o mesmo item tem comportamento diferente em cada canal que se analisados juntamente certamente o erro na análise dos dados ocorrerá.

Figura 7: Canais de venda

Canal	Descrição	Canal	Descrição
1	Aftermarket Clientes especiais	965	Volkswagen PA
2	Aftermarket Nacional	966	Volkswagen OM
3	CDI - Desenvolvimento	967	Renault P&A
4	After peças GM	968	Uliana
5	Marketing	969	TAC OM
6	Keko Dist.	970	Nissan OM
444	regional 04	971	GM Tailândia
901	Aftermarket Exportação	972	GM Argentina
902	EGR	973	GM Equador
903	Ferramentais	974	Toyota Mod Center
904	Volkswagen Argentina	975	Mitsubishi OM
920	AGCO América do Sul	976	Mitsubishi Armazem
921	Agrale S.A	977	Toyota Japão
922	SUZUKI	978	TOYOTA USA
929	Citroen Argentina	979	Renault Armazem
930	Ford México	980	Ford Caminhões
931	Ford India	981	Ford Argentina
932	Ford Russia	982	Ford Chile
933	Ford Mod Center SBC	983	Ford Uruguai
940	Guerra OM	984	Ford Mod Center BA
941	Butler OEM	985	GM Colômbia
942	Impls Rods After Nacional	986	GM Chile
943	Librelato OM	987	GM Venezuela
944	Randon OM	988	GM Mexico
945	Facchini OM	989	Renault Reposição
946	Pastre OM	990	Toyota OM
949	Impls Rods After Exportação	991	Toyota Armazem
950	Peugeot Armazem	992	Toyota Argentina
951	Mahindra	993	Nissan Reposição
952	Toyota Tsusho	994	GM Armazem DSH
953	Ford Alemanha	995	Mitsubishi P&A
960	GM OM	996	Fiat P&A
961	Fiat OM	997	Toyota P&A VSD
962	Renault OEM	998	GM P&A DSO
964	Volkswagen Armazem	999	Ford P&A

Fonte: Elaborado pelo Autor (2017).

Os dados históricos tabulados são então agrupados, cada item tem a soma por canal de venda de todos os pedidos cadastrados em cada um dos meses, resultando em uma tabela dinâmica que organiza os dados e facilita a busca de informações.

Essa tabela fica ordenada conforme exemplificado na Figura 8, de forma que cada item tem um número de peças vendidas em cada um dos meses em análise. A soma total das peças vendidas, de cada item, em cada mês é dividida pelo número de dias úteis daquele mês, obtendo assim uma média diária de vendas.

Figura 8: Histórico de vendas

			Total de peças vendidas no mês			Média de venda diária				
			Dias úteis	20	22	20				
Canal	Código	Descrição	Fev	Mar	Abr	Fev	Mar	Abr	Média diária últimos 3 meses	Previsão para o mês de Jun
2	9.860.50.000	KF001 Conjunto Rebitadeira RR410 Manual	4	0	0	0	0	0	0,07	1
2	9.860.50.002	KF003 Rebite com Rosca Cabeça Plana M8x300 Z	7	0	0	0	0	0	0,12	3
2	9.860.50.003	KF004 Ponteira M6 para Rebitadeira RR410	8	0	0	0	0	0	0,13	3
991	9.644.02.700PT	PZV24-07011 Sobre Capa Pára-choque Hilux SW4	2	4	2	0	0	0	0,13	3
991	9.649.00.001CR	PZV15-06011-CR Estribo CR Toyota Hilux CS 05-	1	0	0	0	0	0	0,02	0
991	9.649.02.700PT	PZV24-06011 Sobre Capa Pára-choque Hilux (PA)	14	9	13	1	0	1	0,59	13
991	9.649.05.017CR	PZV18-06018 Santantônio Esportivo Hilux 05- (PA	1	1	1	0	0	0	0,05	1
991	9.649.12.000FX	PZV48-06A13-CB Capota Mar. Flex Hilux CD 05-	13	28	24	1	1	1	1,04	23
991	9.649.12.001FX	PZV48-06A14-SB Capota Mar. Flex Hilux CD 05-	26	23	16	1	1	1	1,05	23
991	9.650.02.700PT	PZV24-06012 Sobre Capa Pára-choque Hilux 12-	92	195	115	5	9	6	6,40	141
991	9.653.02.700PT	PZV24-07012 Sobre Capa Pára-choque SW4 12-	41	29	22	2	1	1	1,49	33
901	9.039.00.001PR	K383PR Estribo Strada 01-	6	11	4	0	1	0	0,33	7
930	9.071.00.000PR	BH2T/16450/BA/PRE Estribo Tubular Ecosport 13-	43	46	34	2	2	2	1,98	44
901	9.071.00.001CR	K820CR Estribo K1 Ecosport 13- Cromo	1	0	0	0	0	0	0,02	0
901	9.071.00.001PR	K820PR Estribo K1 Ecosport 13- Preto	2	2	4	0	0	0	0,13	3
901	9.071.00.605C7	K582C7 Estribo K2 My Way EcoSport 13-	7	6	1	0	0	0	0,22	5
901	9.071.35.701BR	K617BR Capa Estepe Ecosport 13- Branco Ártico	5	17	10	0	1	1	0,51	11
901	9.071.35.701PB	K617PB Capa Estepe Ecosport 13- Preto Ebony	4	5	1	0	0	0	0,16	4
901	9.071.35.701PE	K617PE Capa Estepe Ecosport 13- Prata Enseada	6	0	1	0	0	0	0,12	3
901	9.071.35.701PV	K617PV Capa Estepe Ecosport 13- Prata Riviera	1	1	1	0	0	0	0,05	1
901	9.071.35.701VA	K617VA Capa Estepe Ecosport 13- Verm. Arpoad	1	3	0	0	0	0	0,06	1

Fonte: Elaborado pelo Autor (2017).

Essa média é então analisada individualmente para observar se ao longo dos meses se mantém constante ou tem algum ponto fora da curva. Os pontos identificados como fora da curva são analisados e quando detectados como variações pontuais, por ação de venda, feiras ou promoções, são manipulados reduzindo seu valor de forma aleatória, de acordo com o conhecimento e interpretação do analista de mercado, para tirar possíveis efeitos na média.

Pode-se observar na Figura 8 que os valores de vendas para o item 9.650.02.700PT não se comportam de forma constante, ao analisar detectou-se que no mês de março ocorreu ação pontual de venda, que alavancaram as vendas. Para efeito de análise esse valor é revisado e ajustado aproximando-o de uma venda normal sem ações pontuais.

Com as médias diárias de cada mês revisadas, utilizando a função de média, padrão do *software* Excel, é feito o cálculo da média diária entre os 3 meses em estudo. Essa média é então multiplicada pela quantidade de dias úteis do mês que se quer obter a previsão, o resultado será a previsão para o novo período. Para itens que aparecem em mais que um canal de venda, a soma das previsões de cada canal será a previsão real daquele item.

Fatores externos podem influenciar nas vendas, alguns deles podem ser considerados para minimizar o erro nas previsões. Com isso, uma última validação junto aos gestores

comerciais é feita, para ver qual os fatores que poderão ser considerados naquele mês, como exemplo feiras, aumentos de preços, promoções de venda entre outros.

Em consenso entre a gestão comercial e o analista de mercado, os itens que estarão vinculado a esses fatores específicos recebem um aumento percentual no valor de demanda prevista, concluindo-se o processo de construção do *Forecast*.

3.3 ETAPAS DO TRABALHO

Visando alcançar os objetivos específicos traçados no primeiro capítulo, as etapas serão detalhadas de maneira a estruturar o desenvolvimento dos próximos passos deste trabalho, que se ateve na aplicação prática, dos modelos explanados, na empresa em estudo. As etapas estão a seguir contextualizadas:

3.3.1 Realizar o levantamento e coleta de dados

O levantamento dos dados foi fundamental para montar a base histórica dos eventos passados que serviram para a aplicação dos modelos já mencionados para prever as demandas futuras. Foi o marco inicial do estudo de caso na empresa Keko Acessórios S.A.

Utilizando o sistema de gestão da empresa, Datasul, juntamente com o auxílio da área comercial, os dados de eventos dos últimos dois anos e do primeiro semestre de 2017 foram computados e tabelados em planilhas do *software* Excel para posteriormente seguir com a aplicação dos modelos.

O início dessa fase se deu em março de 2017 e o levantamento dos dados se estendeu até o mês de setembro do mesmo ano, coletando novos eventos mensalmente a cada fechamento, para análise e validação dos modelos.

3.3.2 Implementar computacionalmente os modelos

A utilização de *softwares* computacionais foi essencial para a obtenção dos resultados e atingimento do objetivo geral deste trabalho. Essa etapa consiste em aplicar as equações de cada modelo mencionados no Capítulo 2 sobre os dados coletados. As ferramentas computacionais que foram utilizadas são o *software* Excel e o *software* estatístico *Statistical Package for Social Science* (SPSS).

A aplicação computacional se deu em 30 itens dos 696 contidos nos canais de *Aftermarket* e P&A. Essa delimitação contempla o estudo de 70% do volume de peças faturadas nestes canais.

O período de aplicação dos modelos se deu de julho a outubro de 2017. Esta etapa tem como objetivo obter as previsões de demanda do período de janeiro a agosto de 2017, por meio de cada modelo estudado, para posteriormente validar e comparar os valores com a efetividade das demandas mensais.

3.3.3 Analisar os resultados e comparar com o método atualmente utilizados

A aplicação dos diferentes modelos de previsão de demanda explanados na fundamentação teórica resultará em valores de previsão específicos de cada um deles. Para cada conjunto de dados, um modelo será mais eficiente no retorno do resultado esperado.

Para se chegar ao modelo matemático que atende de maneira satisfatória as necessidades da empresa, é conveniente compará-los entre si e com o atual modelo utilizado. Essa etapa consistiu em avaliar cada um dos resultados obtidos e com o auxílio do *software* Excel aplicando as Equações (30) e (31), calcular o erro de previsão em relação a demanda confirmada e também analisar a diferença em relação ao modelo atual.

O período desta etapa se equipara a etapa dois, uma vez que a análise se deu sobre os resultados dos dados aplicados computacionalmente.

3.3.4 Mensurar os ganhos para a empresa

A construção de um estoque regulador tem a função de manter o equilíbrio entre a produção e a venda, ele supre as demandas futuras. Ter estoque de produtos parados acarreta em diversos custos, como custo de armazenagem, custo do manuseio do estoque, entre outros.

A escolha do modelo adequado, pode reduzir o estoque de produtos indesejados e aumentar o índice de entrega de pedidos, visto que ele estará o mais próximo possível da demanda real. A consequência disso é um estoque mais enxuto e com maior giro, tendo-se um ganho financeiro e de fluxo de caixa para empresa, importante para a sustentabilidade da mesma.

Mensurar esses ganhos se fará importante para justificar investimentos nas ferramentas de previsão, em uma mão de obra especializada nesta área e claro do objetivo deste trabalho.

Essa etapa, realizada em novembro de 2017, contou com o apoio do setor contábil da empresa, que disponibilizou os valores de custos de fabricação dos itens e o preço de venda dos mesmos.

Com essas informações, foi aplicado a Equação (33), buscando-se o custo financeiro provenientes do estoque com o método utilizado atualmente e o custo do estoque com o modelo proposto mais um custo associado a uma possível perda de venda caso a metodologia resulte em valores inferiores a demanda. Com a análise destes custos, obteve-se os ganhos financeiros para a empresa.

3.3.5 Definir o modelo mais adequado para a empresa

Sabe-se que os dados de eventos históricos não se repetirão igualmente no futuro, nesse contexto para atender de maneira satisfatória, o modelo adequado deve apresentar uma previsão que seja o mais próximo possível da realidade, ou seja, da demanda efetiva.

A partir da análise e do cálculo dos erros de previsão, pode-se chegar ao modelo que tem o menor erro, sendo assim o modelo mais adequado. Para cada conjunto de dados, um modelo pode ser o ideal.

A aplicação de um modelo para cada conjunto de dados pode ser demorada. Desta forma, a escolha de um modelo para uma determinada família de produtos pode ser uma opção assertiva, pois além de economizar tempo na construção do *Forecast* ainda obtêm se previsões muito próximas da realidade.

Essa etapa foi realizada após o termino das etapas anteriores, e ocorreu em novembro de 2017, onde definiu-se o melhor modelo a ser utilizado para a empresa na construção do *Forecast*.

3.3.6 Propor a implantação do modelo escolhido

A implantação de uma ferramenta que envolve mudanças de tal magnitude, como a alteração do método de previsão, só se obtém êxito se tiver uma boa fundamentação teórica que defenda a ideia, embasada em dados mensuráveis que justificam a intervenção proposta.

Essa etapa é quando se avalia o resultado de todas as etapas anteriores, se concretiza os objetivos traçados e pôr fim se apresenta a proposta firmada por meio do estudo realizado. A proposta foi apresentada ao final do decorrer deste trabalho, em dezembro de 2017, aos setores comercial e PCP da empresa em estudo, juntamente com as gerências responsáveis pelas áreas citadas.

Com a aprovação do estudo realizado, a metodologia escolhida para prever a demanda foi então firmada. A proposta de aplicação se deu para a construção do *Forecast* de janeiro de 2018, o qual foi desenvolvido em dezembro de 2017.

3.4 CONSIDERAÇÕES DO CAPÍTULO

O presente capítulo buscou expor de maneira clara e objetiva como são os atuais processos de previsão de demanda adotados na empresa Keko Acessórios S.A, buscando a compreensão das dificuldades encontradas e os pontos falhos, passíveis de erros do modelo atual.

A análise do processo atual permitiu perceber que há processos executados de forma manual e, por vezes, com base no conhecimento do analista que está executando o processo. O intuito deste trabalho é justamente propor um método eficiente e sistêmico de se fazer as análises e previsões, e que os dados históricos aplicados ao modelo correto possam fazer as interpretações necessárias e apoiar na tomada de decisão.

As etapas esplanadas neste capítulo estruturaram de forma textual a continuidade do trabalho, assim nortearam de forma organizada o seguimento das atividades em busca do objetivo geral deste trabalho.

(conclusão)

CÓD.	JAN	FEV	MAR	ABR	MAI	JUN	JUL	AGO	SET	OUT	NOV	DEZ
071.35PB	104	65	98	108	63	44	58	72	74	48	54	53
654.03PR	0	0	0	0	0	0	0	0	0	0	0	0
655.05PR	0	0	0	0	0	0	0	0	0	275	299	134
275.00PR	10	12	10	12	8	20	16	11	14	5	22	11
101.00PR	0	0	0	0	0	0	0	0	0	0	26	31
101.00C7	0	0	0	0	0	0	0	0	0	0	24	35
631.00BS	0	0	0	0	0	0	0	0	0	0	0	0
046.05PR	49	67	66	155	53	260	53	55	85	64	69	76
653.02PT	282	99	225	302	208	188	285	167	161	140	58	96
101.03PR	0	0	0	0	0	0	0	0	0	2	27	24
631.00PR	0	0	0	0	0	0	0	0	0	0	0	0
136.07AZ	90	72	64	60	41	34	54	39	34	34	51	65
631.03PR	0	0	0	0	0	0	0	0	0	2	7	7

Fonte: Elaborado pelo autor (2017).

Para o ano de 2016, Tabela 2, pode-se observar que apenas o item 654.03PR apresenta demanda zerada no início do período, os demais itens apresentam demanda ao longo de todo o ano. A demanda de cada item tem um comportamento específico e aleatórios, parte deles apresenta um comportamento homogêneo, alguns com picos pontuais, como pode ser observado para o item 655.12FX, onde no mês de março apresenta uma demanda de 2174 peças acima da média para os outros meses, que é de 1384 peças.

Tabela 2: Dados históricos 2016

(continua)

CÓD.	JAN	FEV	MAR	ABR	MAI	JUN	JUL	AGO	SET	OUT	NOV	DEZ
655.12FX	971	979	2174	1650	1379	1473	1358	1490	1539	1310	1545	1527
655.02PT	581	578	1334	1024	1037	888	668	800	970	759	1038	792
655.05cr	296	292	701	483	488	373	367	498	369	429	458	479
654.02PT	249	417	478	281	322	331	207	287	402	361	376	417
631.05CR	102	118	150	137	375	440	272	392	360	198	221	362
071.35BR	237	240	284	264	253	240	267	324	356	265	221	310
570.00PR	183	186	324	320	299	185	318	251	147	140	177	171
655.03PR	70	131	237	144	146	177	160	128	135	90	106	128
998.51	168	118	104	101	107	46	46	63	83	70	115	190

(conclusão)

CÓD.	JAN	FEV	MAR	ABR	MAI	JUN	JUL	AGO	SET	OUT	NOV	DEZ
650.02PT	203	134	202	154	193	130	162	160	156	112	122	136
101.01C7	96	62	82	81	48	38	25	28	46	71	72	69
275.12FX	28	235	74	16	83	168	128	70	97	59	88	70
101.12FX	78	92	95	83	61	34	21	31	44	86	77	110
631.00PR	66	26	70	34	81	180	46	26	54	47	92	41
275.12FX	36	204	36	37	106	115	97	95	65	99	87	107
071.35PT	32	56	75	61	53	49	48	56	78	49	27	53
226.12FX	444	134	74	98	22	117	86	47	68	45	199	50
071.35PB	49	42	40	33	20	27	28	63	49	42	38	49
654.03PR	0	0	0	0	138	56	31	19	35	25	52	38
655.05PR	96	86	78	64	78	42	32	27	28	23	20	25
275.00PR	23	24	44	15	21	59	59	7	24	15	26	15
101.00PR	48	31	37	26	28	32	20	18	29	28	35	24
101.00C7	30	41	21	43	34	28	18	13	22	36	27	25
631.00BS	1	4	12	5	34	32	41	47	36	48	36	50
046.05PR	48	34	55	29	77	70	53	49	62	36	66	50
653.02PT	69	40	61	61	52	36	28	38	41	26	34	33
101.03PR	55	43	59	55	35	57	22	26	39	22	31	33
631.00PR	5	3	7	12	17	49	23	49	50	50	68	57
136.07AZ	47	45	32	18	31	41	21	54	33	35	24	39
631.03PR	23	14	11	27	13	18	27	32	36	29	32	40

Fonte: Elaborado pelo autor (2017).

Os dados referentes ao período de janeiro de 2017 e agosto de 2017 foram utilizados para comparar as demandas reais com o método atualmente utilizado e também com as previsões obtidas pelas aplicações dos modelos descritos no capítulo 2.

4.2 IMPLANTAÇÃO, ANÁLISE E COMPARAÇÃO DOS MODELOS

Os dados históricos tabulados possibilitaram a aplicação dos modelos apresentados na fundamentação teórica, permitindo a realização de análises e comparações de resultados, com a finalidade de selecionar o modelo de previsão mais indicado para a empresa.

As previsões encontradas em cada mês foram comparadas individualmente com a demanda real. Foram utilizados os cálculos do MAPE, Equação (31), e do MAE, Equação (32) para encontrar os erros médios em cada item. Também foram calculados o MAPE e o MAE

médio por modelo, onde calculou-se para cada mês um erro para todos os itens, após calculou-se uma média de todos os resultados, como mostrado na Tabela 3.

Tabela 3: Exemplo do método de avaliação dos resultados

				MAPE médio modelo	37%	MAE médio modelo	26
Modelo	CÓD.	Realizado janeiro	Previsão janeiro	MAPE janeiro	MAPE médio para 8 meses	MAE janeiro	MAE médio para 8 meses
1	046.05PR	45	60	33%	55%	15	13
1	071.35BR	176	309	76%	44%	133	76
1	071.35PB	37	47	27%	32%	10	15
1	071.35PT	39	56	44%	23%	17	11
1	101.01C7	44	31	30%	32%	13	15

Fonte: Elaborado pelo autor (2017).

Em cada conjunto de modelos de previsão comparados, o modelo que apresentar o menor MAPE estará evidenciado com um asterisco, possibilitando a fácil identificação do melhor modelo.

Para a aplicação computacional dos modelos definiu-se a utilização do *Software* Excel para os modelos de MM e suavização exponencial, e o *Software* SPSS para os modelos de *Holt*, *Winters* e o modelo *Box-Jenkins*.

4.2.1 Média Móvel Simples

O modelo da MMS pode ser obtido considerando diversos intervalos de períodos, para cada período pode-se obter uma previsão específica. Para a avaliação deste modelo, utilizou-se intervalos trimestrais de 3, 6, 9 e 12 períodos. Desta forma se fez clara a interpretação do impacto de cada período sobre a previsão.

Na Tabela 4 estão apresentados os erros médios de previsão obtidos, pode-se observar que para a MMS em todos os intervalos de tempo calculados os erros são inferiores a metodologia atual que apresenta um erro médio de 41%.

Tabela 4: MAPE MMS x Método atual

Código	Método atual	MMS 3m	MMS 6m	MMS 9m	MMS 12m
MAPE	41%	* 36%	* 36%	37%	39%
655.12FX	19%	17%	17%	16%	17%
655.02PT	13%	15%	13%	14%	14%
655.05CR	26%	20%	22%	21%	23%
654.02PT	24%	25%	23%	20%	20%
631.05CR	29%	32%	37%	39%	34%
071.35BR	44%	26%	30%	36%	41%
570.00PR	37%	17%	20%	29%	38%
655.03PR	24%	18%	21%	21%	21%
998.51	40%	40%	35%	30%	32%
650.02PT	17%	16%	19%	24%	30%
101.01C7	36%	36%	39%	37%	42%
275.12FX	47%	40%	42%	52%	50%
101.12FX	63%	54%	54%	40%	46%
631.00PR	22%	32%	26%	29%	31%
275.12FX	56%	43%	59%	63%	67%
071.35PT	23%	19%	18%	15%	15%
226.12FX	140%	78%	90%	101%	112%
071.35PB	32%	31%	26%	21%	23%
654.03PR	34%	41%	30%	35%	25%
655.05PR	53%	96%	72%	58%	70%
275.00PR	28%	24%	31%	34%	33%
101.00PR	64%	51%	52%	50%	52%
101.00C7	32%	35%	32%	30%	33%
631.00BS	77%	68%	60%	60%	58%
046.05PR	55%	46%	54%	63%	68%
653.02PT	14%	23%	20%	19%	24%
101.03PR	44%	36%	36%	43%	47%
631.00PR	58%	47%	53%	50%	44%
136.07AZ	51%	42%	33%	35%	33%
631.03PR	28%	24%	20%	16%	16%

Fonte: Elaborado pelo autor (2017).

Quando analisado individualmente os resultados da MMS, pode-se notar que os resultados para alguns itens não são satisfatórios, como por exemplo para os itens 653.02PT e 631.05CR que apresentam o menor erro na metodologia atual.

4.2.2 Média Móvel Ponderada

Assim como na MMS, a MMP também pode ser calculada para diferentes períodos de tempo. Inicialmente para esse modelo utilizou-se os mesmos períodos já utilizadas para MMS e ponderou-se pesos aleatórios para cada um dos períodos, dando mais importâncias para as demandas mais recentes e menos importância as demandas mais antigas. Na Tabela 5 estão expostos os pesos para cada um dos períodos calculados.

Tabela 5: Pesos atribuídos aos períodos

Meses	Wt-12	Wt-11	Wt-10	Wt-9	Wt-8	Wt-7	Wt-6	Wt-5	Wt-4	Wt-3	Wt-2	Wt-1
12	2%	2%	3%	4%	5%	6%	7%	9%	11%	14%	17%	20%
9				4%	5%	7%	8%	10%	12%	15%	18%	21%
6							10%	12%	15%	18%	21%	24%
3										25%	35%	40%

Fonte: Elaborado pelo autor (2017).

Para que o modelo possa trazer uma previsão mais aproximada da demanda efetiva, deve-se minimizar o erro médio. Como há inúmeras combinações possíveis, se utiliza a otimização para encontrar a melhor delas.

Para a otimização dos dados foi utilizado o Excel, com a utilização da ferramenta *solver*, que testa e retorna a configuração ótima para o menor MAPE. Para esse modelo, a função objetivo utilizada foi a de minimizar o MAPE, considerando as restrições de que os pesos de cada período devem estar entre 0 e 100%, e a soma de todos os pesos não pode ultrapassar o 100%. Os resultados obtidos estão mostrados na Tabela 6.

Tabela 6: Pesos otimizados pelo *solver*

Meses	Wt-12	Wt-11	Wt-10	Wt-9	Wt-8	Wt-7	Wt-6	Wt-5	Wt-4	Wt-3	Wt-2	Wt-1
12	0%	0%	0%	3%	0%	15%	3%	3%	14%	1%	17%	43%
9				5%	0%	9%	9%	2%	17%	0%	15%	44%
6							12%	1%	22%	1%	13%	51%
3										21%	31%	48%

Fonte: Elaborado pelo autor (2017).

A partir dos pesos otimizados pelo *solver*, calcularam-se novas previsões e os erros em relação a demanda real. A Tabela 7 apresenta os erros encontradas com a MMP e MMP otimizada.

Para o modelo otimizado estão apresentados os dados apenas para 9 e 6 meses, pois, para o período de 3 meses o MAPE se manteve em 36% como no modelo não otimizado. Já o período de 12 meses apresentou um MAPE igual ao período de 9 meses otimizado de 34%. Ao analisar a Tabela 6 para 12 meses, observa-se valores zero para os 3 meses mais antigos, Wt-10, Wt-11 e Wt-12, o que permite concluir que não foram representativos para obtenção do melhor MAPE.

Tabela 7: MAPE MMP x Método atual

(continua)

Código	Método atual	MMP 3m	MMP 6m	MMP 9m	MMP 12m	MMP 6m otimizada	MMP 9m otimizada
MAPE	41%	36%	35%	35%	36%	* 34%	* 34%
655.12FX	19%	16%	16%	16%	16%	16%	16%
655.02PT	13%	15%	13%	14%	14%	14%	15%
655.05CR	26%	19%	21%	20%	20%	18%	17%
654.02PT	24%	24%	23%	21%	21%	19%	18%
631.05CR	29%	34%	36%	38%	37%	47%	46%
071.35BR	44%	25%	28%	30%	31%	25%	27%
570.00PR	37%	18%	18%	21%	23%	20%	22%
655.03PR	24%	19%	20%	21%	21%	21%	22%
998.51	40%	39%	35%	32%	32%	28%	26%
650.02PT	17%	16%	18%	21%	22%	21%	22%
101.01C7	36%	35%	37%	36%	37%	34%	34%
275.12FX	47%	40%	40%	46%	45%	35%	40%
101.12FX	63%	50%	51%	44%	45%	37%	34%
631.00PR	22%	33%	28%	30%	31%	33%	32%
275.12FX	56%	40%	54%	54%	55%	42%	46%
071.35PT	23%	18%	18%	15%	15%	19%	17%
226.12FX	140%	74%	84%	91%	94%	71%	74%
071.35PB	32%	31%	27%	24%	24%	25%	25%
654.03PR	34%	40%	33%	34%	32%	31%	33%
655.05PR	53%	96%	75%	67%	69%	79%	71%
275.00PR	28%	23%	28%	29%	28%	24%	23%
101.00PR	64%	53%	52%	50%	51%	53%	51%

(conclusão)

Código	Método atual	MMP 3m	MMP 6m	MMP 9m	MMP 12m	MMP 6m otimizada	MMP 9m otimizada
101.00C7	32%	36%	34%	32%	32%	45%	41%
631.00BS	77%	69%	62%	60%	59%	69%	66%
046.05PR	55%	44%	51%	55%	57%	47%	50%
653.02PT	14%	23%	21%	20%	21%	21%	21%
101.03PR	44%	37%	36%	38%	39%	35%	37%
631.00PR	58%	47%	51%	48%	44%	46%	43%
136.07AZ	51%	41%	35%	35%	35%	34%	34%
631.03PR	28%	24%	21%	18%	18%	22%	20%

Fonte: Elaborado pelo autor (2017).

Na média os ganhos são perceptíveis, mas quando analisado individualmente, pode-se notar que os erros de previsão para alguns itens podem ser considerados elevados, como por exemplo o item 631.05CR, que apresenta um erro de 46% e 47% para os modelos otimizados. Para um melhor resultado, o ideal seria otimizar individualmente cada item, porém não foi realizado neste trabalho.

Com a otimização de forma generalizada, alguns itens podem apresentar erros de previsão elevados. Para testar o impacto na média geral, 5 itens, com maior variação entre o modelo MMP 9m e o modelo MMP 9m otimizado, tiveram os pesos alterados para o modelo MMP 9m e os demais continuaram com o modelo otimizado. Na Tabela 8 pode-se observar que esse ajuste representou um decréscimo de um ponto percentual na média, de 34% para 33%.

Tabela 8: MAPE MMP ajustada x Método atual

Código	Método atual	MMP 6m	MMP 9m	MMP 12m	MMP 6m otimizada	MMP 9m otimizada	MMP 9m ajustada
MAPE	41%	35%	35%	36%	34%	34%	* 33%
631.05CR	29%	36%	38%	37%	47%	46%	38%
631.00PR	22%	28%	30%	31%	33%	32%	30%
655.05PR	53%	75%	67%	69%	79%	71%	67%
101.00C7	32%	34%	32%	32%	45%	41%	32%
631.00BS	77%	62%	60%	59%	69%	66%	60%

Fonte: Elaborado pelo autor (2017).

Os itens listados na Tabela 8, são os que foram ajustados para o modelo MMP 9m para obtenção de uma nova análise a qual se mostrou melhor que as demais, se tornando o melhor resultado entre as MMP.

4.2.3 Suavização Exponencial Simples

Este modelo, diferentemente da MM, baseia-se apenas na previsão e no realizado do último período, e na constante de amortização α . Para o modelamento utilizou-se valores aleatórios para a constante α , sendo eles 0,2, e 0,8. Porém para poder encontrar o melhor valor da constante, novamente se fez necessário a utilização da otimização, buscando-se minimizar o MAPE. A única restrição a ser considerada nesse modelo é que a constante dever estar entre 0 e 1. A aplicação trouxe como valor ideal para a constante o valor de 0,46. Na Tabela 9 estão apresentados os valores de MAPE encontrados para cada um dos valores citados para a constante.

Tabela 9: MAPE Suavização Exponencial Simples x Método atual

(continua)

Código	Método atual	Suavização exponencial simples $\alpha=0,2$	Suavização exponencial simples $\alpha=0,8$	Suavização exponencial simples otimizado $\alpha=0,46$
MAPE	41%	38%	38%	* 36%
655.12FX	19%	18%	21%	16%
655.02PT	13%	13%	18%	14%
655.05CR	26%	22%	18%	19%
654.02PT	24%	20%	24%	21%
631.05CR	29%	37%	49%	42%
071.35BR	44%	40%	21%	27%
570.00PR	37%	28%	22%	22%
655.03PR	24%	19%	24%	21%
998.51	40%	34%	36%	34%
650.02PT	17%	19%	20%	18%
101.01C7	36%	42%	38%	36%
275.12FX	47%	45%	38%	40%
101.12FX	63%	51%	43%	45%
631.00PR	22%	33%	37%	33%
275.12FX	56%	58%	30%	40%
071.35PT	23%	17%	20%	18%

(conclusão)

Código	Método atual	Suavização exponencial simples $\alpha=0,2$	Suavização exponencial simples $\alpha=0,8$	Suavização exponencial simples otimizado $\alpha=0,46$
226.12FX	140%	108%	59%	71%
071.35PB	32%	27%	31%	30%
654.03PR	34%	32%	39%	36%
655.05PR	53%	62%	102%	86%
275.00PR	28%	30%	25%	24%
101.00PR	64%	53%	59%	53%
101.00C7	32%	33%	54%	40%
631.00BS	77%	62%	74%	68%
046.05PR	55%	64%	45%	47%
653.02PT	14%	21%	23%	23%
101.03PR	44%	39%	40%	39%
631.00PR	58%	63%	55%	49%
136.07AZ	51%	34%	36%	37%
631.03PR	28%	23%	25%	24%

Fonte: Elaborado pelo autor (2017).

Da mesma forma que MMP, a otimização aplicada de forma generalizada traz uma melhora na média geral do MAPE, mas individualmente alguns itens podem apresentar erros percentuais elevados. Porém para esse modelo, tem-se um melhor MAPE para cada item, que varia entre os valores adotados para a constante, 30% dos itens tem o melhor MAPE com o valor da constante igual a 0,46. Enquanto os 70% restantes estão distribuídos entre os valores da constante de 0,2 e 0,8. Pode-se concluir que para o melhor MAPE, cada item requer um valor específico para a constante.

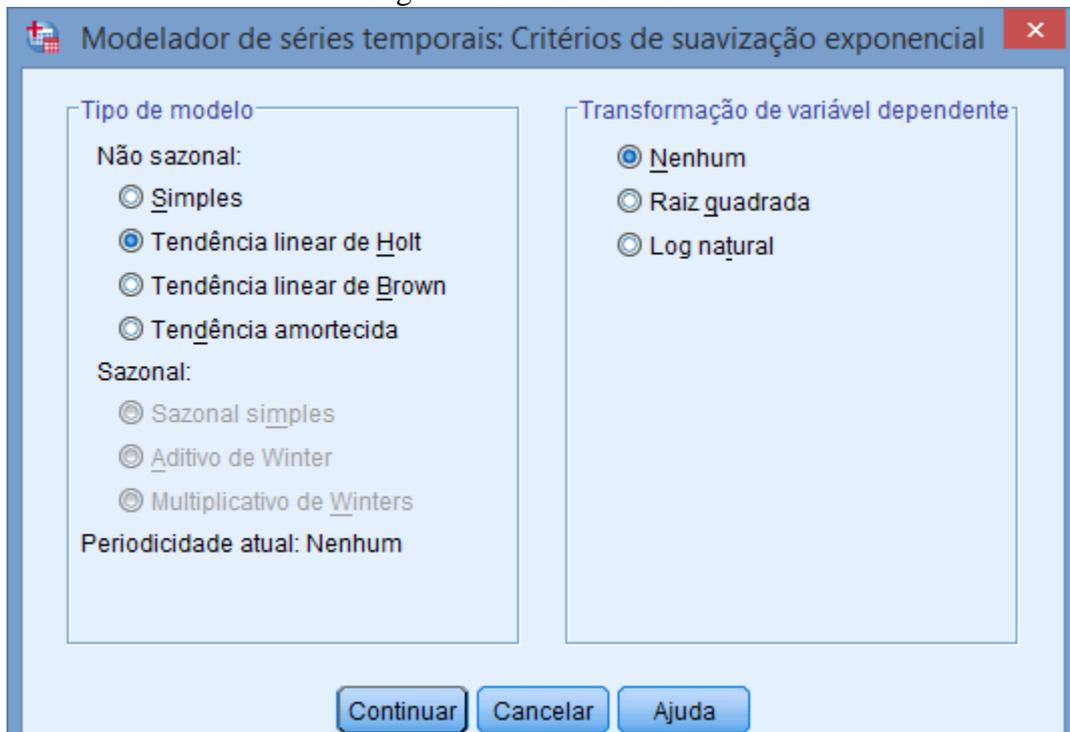
4.2.4 Modelo de *Holt*

O modelo de *Holt* é indicado para aplicação em séries temporais com tendências lineares e nenhuma sazonalidade. Além da constante de amortização α utilizada na suavização exponencial, esse modelo utiliza também uma constante de tendência β . Para melhor obtenção dos resultados, o modelo foi testado utilizando o *Software* SPSS, onde o mesmo já traz os valores da constante de forma a otimizar os resultados do modelo.

A aplicação do modelo no *Software* permite a seleção do modelo de transformação da variável dependente, na Figura 9 pode-se observar as opções possíveis. Para analisar o

comportamento do modelo, o mesmo foi aplicado para os dados com as três possibilidades, Nenhum, Raiz quadrada e Logaritmo natural.

Figura 9: Parâmetros SPSS



Fonte: Software SPSS (2017).

Inicialmente o modelo foi aplicado considerando os dados de janeiro a dezembro de 2016, obtendo-se as previsões de janeiro a agosto de 2017, e após calcularam-se os erros médios das previsões obtidas. Os dados estão apresentados na Tabela 10.

Tabela 10: MAPE Modelo de *Holt* x Método atual

(continua)

Código	Método atual	Modelo de <i>Holt</i>	Modelo de <i>Holt</i> Log	Modelo de <i>Holt</i> Raiz
MAPE	* 41%	61%	117%	79%
655.12FX	19%	22%	27%	24%
655.02PT	13%	14%	18%	15%
655.05CR	26%	40%	52%	47%
654.02PT	24%	29%	34%	32%
631.05CR	29%	65%	155%	85%
071.35BR	44%	71%	76%	76%

(conclusão)

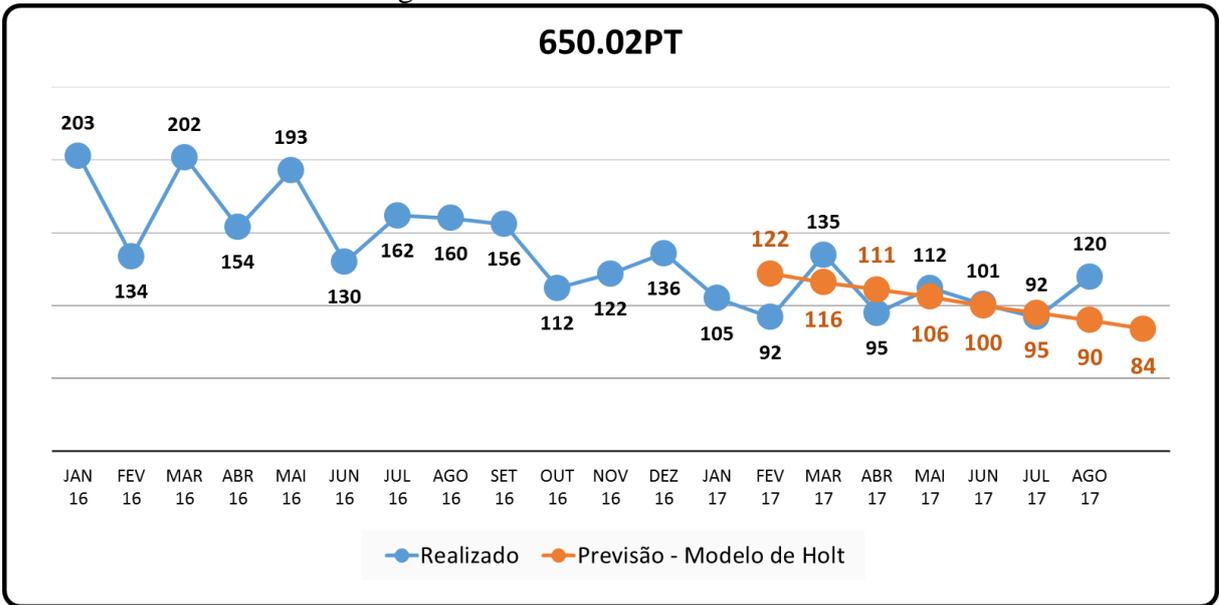
Código	Método atual	Modelo de <i>Holt</i>	Modelo de <i>Holt</i> Log	Modelo de <i>Holt</i> Raiz
570.00PR	37%	18%	18%	19%
655.03PR	24%	17%	20%	18%
998.51	40%	174%	105%	355%
650.02PT	17%	14%	15%	14%
101.01C7	36%	68%	45%	45%
275.12FX	47%	37%	99%	50%
101.12FX	63%	94%	122%	94%
631.00PR	22%	33%	33%	31%
275.12FX	56%	124%	204%	153%
071.35PT	23%	11%	15%	15%
226.12FX	140%	68%	53%	42%
071.35PB	32%	22%	26%	24%
654.03PR	34%	51%	100%	196%
655.05PR	53%	92%	66%	85%
275.00PR	28%	65%	54%	50%
101.00PR	64%	55%	55%	55%
101.00C7	32%	40%	43%	45%
631.00BS	77%	127%	598%	214%
046.05PR	55%	102%	117%	109%
653.02PT	14%	48%	34%	40%
101.03PR	44%	73%	51%	53%
631.00PR	58%	161%	1169%	293%
136.07AZ	51%	48%	31%	32%
631.03PR	28%	40%	84%	61%

Fonte: Elaborado pelo autor (2017).

Analisando os resultados obtidos, pode-se notar um erro médio acima da metodologia utilizada atualmente. Quando analisado individualmente percebesse que alguns itens, os quais tem uma tendência quase linear, tem um menor erro em relação ao modelo atual.

O item 650.02PT, mostrado na Figura 10, tem um comportamento com baixa oscilação no período de cálculo da previsão, não chega a ser linear, como requer o modelo, mas já pode-se perceber uma previsão com um erro médio 3 pontos percentuais menor que o modelo atual e o segundo menor erro em relação aos demais itens analisados.

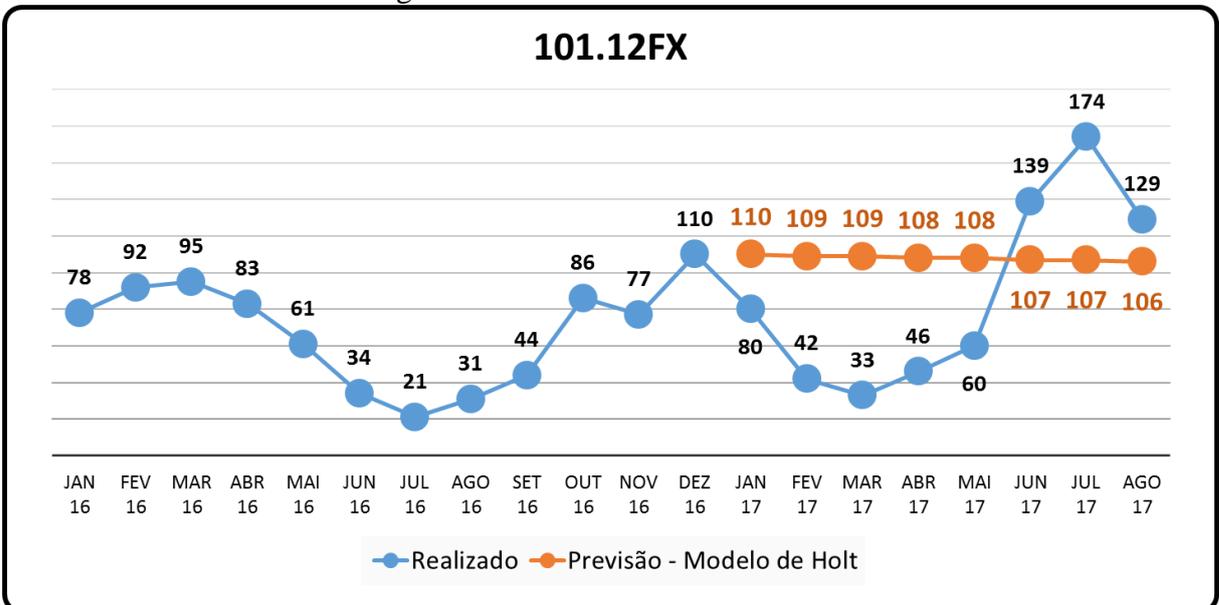
Figura 10: Análise do item 650.02PT



Fonte: Elaborado pelo autor (2017).

Da mesma forma, quando analisado o item 101.12FX, Figura 11, pode-se perceber que a oscilação elevada retorna uma previsão longe da realidade, neste caso apresenta um erro médio de 94% da demanda real, 31 pontos percentuais acima do modelo atual.

Figura 11: Análise do item 101.12FX



Fonte: Elaborado pelo autor (2017).

Com a análise mostrada, é possível concluir que o modelo de Holt apresentou melhores previsões para o item 650.700PT por apresentam tendência e não apresentar sazonalidade,

diferenciando-se do item 101.12FX que não apresenta sazonalidade, nem tendência e obteve previsões mais distantes da média. Para buscar um melhor resultado para o modelo, foi realizado um novo modelamento obtendo-se a previsão de apenas um mês, e a cada novo acontecimento, este foi acrescentado aos dados e calculado o mês posterior. Com esse ajuste obteve-se uma nova previsão, na Tabela 11 estão apresentados os erros médios obtidos.

Tabela 11: MAPE Modelo de *Holt* x Método atual

(continua)

Código	Método atual	Modelo de <i>Holt</i> Modelamento para 8 meses	Modelo de <i>Holt</i> Modelamento mês a mês
MAPE	41%	61%	* 40%
655.12FX	19%	22%	17%
655.02PT	13%	14%	15%
655.05CR	26%	40%	24%
654.02PT	24%	29%	22%
631.05CR	29%	65%	49%
071.35BR	44%	71%	29%
570.00PR	37%	18%	22%
655.03PR	24%	17%	20%
998.51	40%	174%	50%
650.02PT	17%	14%	15%
101.01C7	36%	68%	42%
275.12FX	47%	37%	34%
101.12FX	63%	94%	46%
631.00PR	22%	33%	29%
275.12FX	56%	124%	53%
071.35PT	23%	11%	17%
226.12FX	140%	68%	42%
071.35PB	32%	22%	31%
654.03PR	34%	51%	37%
655.05PR	53%	92%	123%
275.00PR	28%	65%	30%
101.00PR	64%	55%	59%
101.00C7	32%	40%	34%
631.00BS	77%	127%	92%
046.05PR	55%	102%	53%
653.02PT	14%	48%	28%

(conclusão)

Código	Método atual	Modelo de <i>Holt</i> Modelamento para 8 meses	Modelo de <i>Holt</i> Modelamento mês a mês
101.03PR	44%	73%	39%
631.00PR	58%	161%	83%
136.07AZ	51%	48%	36%
631.03PR	28%	40%	27%

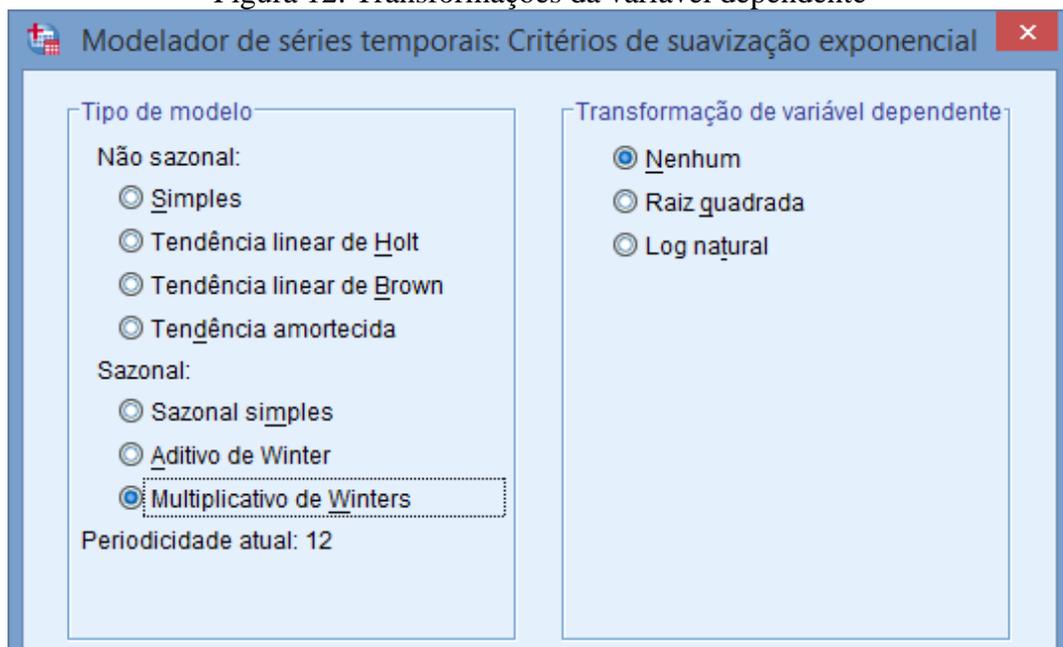
Fonte: Elaborado pelo autor (2017).

Os dados mostram uma melhora em relação a primeira metodologia utilizada, 13 pontos percentuais mais próximos da demanda real, superando em 1% o modelo atual. O que nos permite concluir que quanto maior o intervalo para a previsão calculada pelo modelo de *Holt*, maior serão as incertezas em relação aos resultados obtidos.

4.2.5 Modelo de *Winters* Multiplicativo

Este modelo também permite aplicar as três possibilidades de transformação da variável dependente, na Figura 12 pode-se observar as opções possíveis. Para testar o efeito de cada uma delas foi modelado os dados considerando as três possibilidades, Nenhum, Raiz quadrada e Logaritmo natural.

Figura 12: Transformações da variável dependente



Fonte: Software SPSS (2017).

Os modelos sazonais de *Winters* são utilizados em padrões de demanda que possuam tendência e sazonalidade, sendo o modelo multiplicativo o que calcula as variações sazonais ao longo do tempo. Os modelos de *Winters* utilizam as constantes de amortecimento α , de tendência β e de sazonalidade γ .

Como mencionado anteriormente, 50% dos itens tem demanda apenas no ano de 2016, o que impede o modelo de analisar possíveis sazonalidades nos eventos passados. Esse fato fez com que o modelo de *Winter* aplicado no *software* SPSS retornasse previsões apenas para os itens com demanda nos dois anos analisados.

Para a aplicação com este modelo, o SPSS define os melhores valores para as constantes, sendo eles específicos para cada série de dados. Os resultados obtidos com a aplicação estão apresentados na Tabela 12.

Tabela 12: MAPE Modelo de *Winters* multiplicativo x Método atual

(continua)

Código	Método atual	Multiplicativo de Winters	Multiplicativo de Winters Log	Multiplicativo de Winters Raiz
MAPE	* 41%	57%	77%	70%
655.12FX	19%			
655.02PT	13%			
655.05CR	26%			
654.02PT	24%			
631.05CR	29%			
071.35BR	44%	68%	66%	63%
570.00PR	37%	36%	41%	42%
655.03PR	24%			
998.51	40%	76%	66%	58%
650.02PT	17%	69%	43%	15%
101.01C7	36%	67%	67%	60%
275.12FX	47%	Não calculado	80%	93%
101.12FX	63%	68%	62%	64%
631.00PR	22%	58%	52%	52%
275.12FX	56%	69%	289%	414%
071.35PT	23%	18%	19%	18%
226.12FX	140%			
071.35PB	32%	41%	41%	41%
654.03PR	34%			
655.05PR	53%			

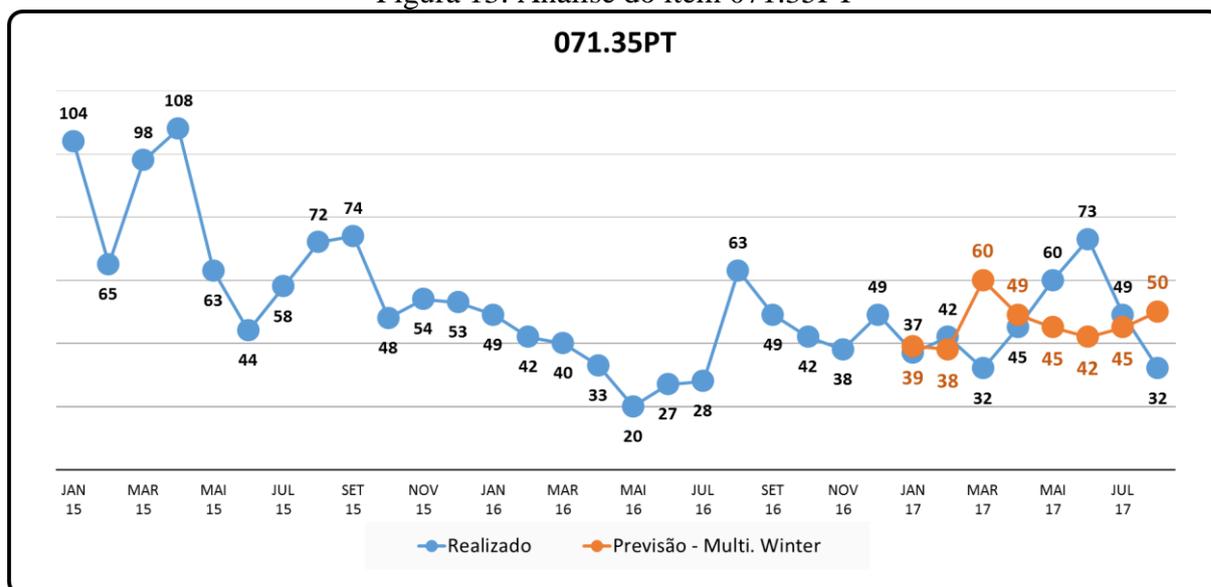
(conclusão)

Código	Método atual	Multiplicativo de Winters	Multiplicativo de Winters Log	Multiplicativo de Winters Raiz
275.00PR	28%	Não calculado	63%	97%
101.00PR	64%			
101.00C7	32%			
631.00BS	77%			
046.05PR	55%	55%	48%	48%
653.02PT	14%	82%	79%	55%
101.03PR	44%			
631.00PR	58%			
136.07AZ	51%	33%	33%	32%
631.03PR	28%			

Fonte: Elaborado pelo autor (2017).

Analisando os erros médios obtidos, pode-se notar que estão acima do modelo atual. Analisando individualmente pode-se perceber que apenas 4 itens tem o erro abaixo do modelo atual. Na Figura 13 e na Figura 14 estão apresentados os dados históricos e a previsão calculada pelo modelo de *Winters* de dois itens que apresentaram os melhores resultados com este modelo.

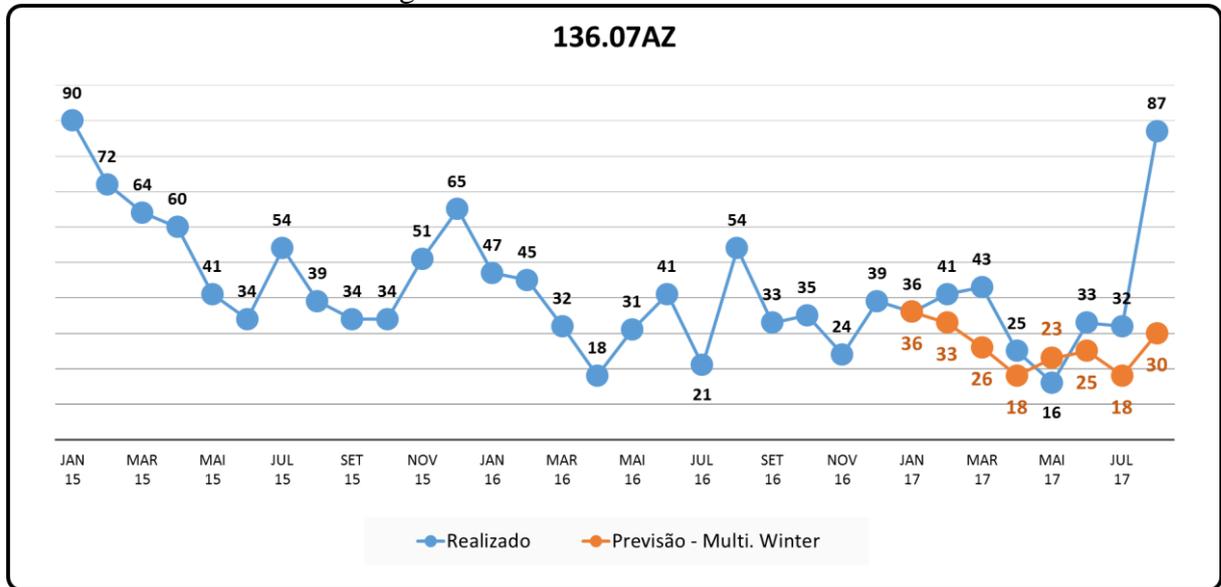
Figura 13: Análise do item 071.35PT



Fonte: Elaborado pelo autor (2017).

O item 071.35PT apresenta o menor erro em relação aos demais itens, 5 pontos percentuais abaixo do modelo atual. Já o item 136.07AZ apresenta o melhor ganho em relação ao modelo atual, um ganho de 18 pontos percentuais.

Figura 14: Análise do item 136.07AZ



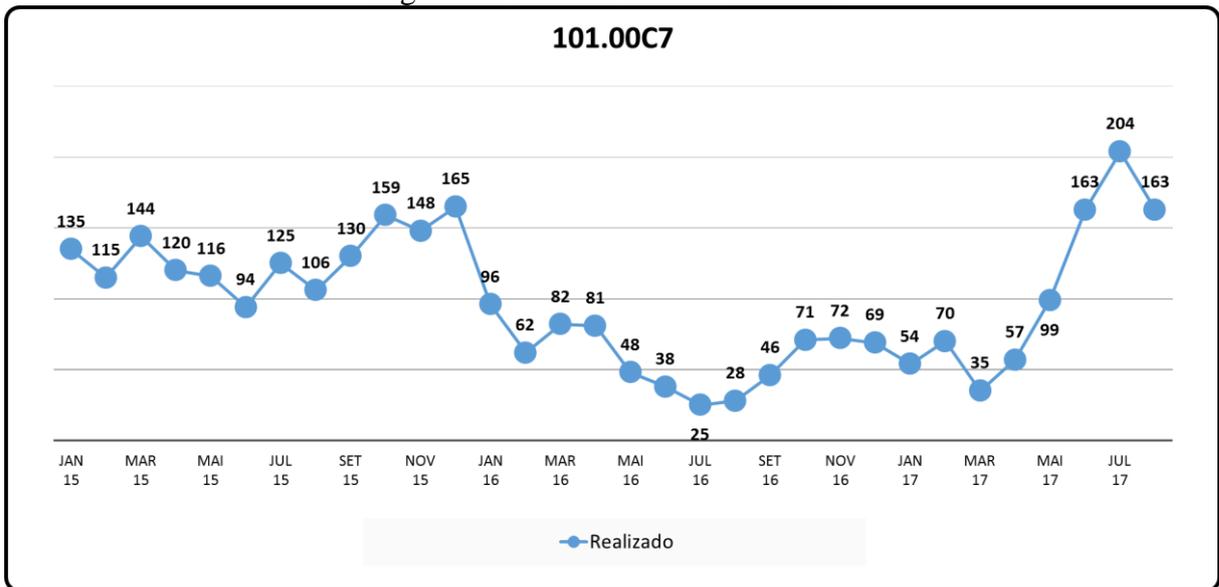
Fonte: Elaborado pelo autor (2017).

Com estes gráficos permite-se observar que, apesar de ter ganhos em relação ao modelo atual, os dois itens não apresentam sazonalidade ao longo do período analisado, isso se repete nos demais itens calculados o que justifica o alto erro das previsões por esse modelo.

4.2.6 Modelo de *Winters* Aditivo

Para o modelo aditivo de *Winters*, que é apropriada para séries temporais onde o ciclo sazonal permanece constante ao longo do tempo, o mesmo não foi apresentado neste trabalho, pois ao analisar os dados foi constatado que esse fato não é evidenciado. Na Figura 15, está demonstrado o comportamento para o item 101.00.c7, que apresentou o menor erro com esse modelo. Pode se observar que o ciclo sazonal apresenta uma variação diferente em cada ano apresentado, assim como para os demais itens esse comportamento se repete.

Figura 15: Análise do item 101.00C7



Fonte: Elaborado pelo autor (2017).

Porém para validar se o modelo não poderia ser um método adequado foram calculadas as previsões e os erros médios, os quais apresentaram variações superiores a 100%, sendo descartado da análise.

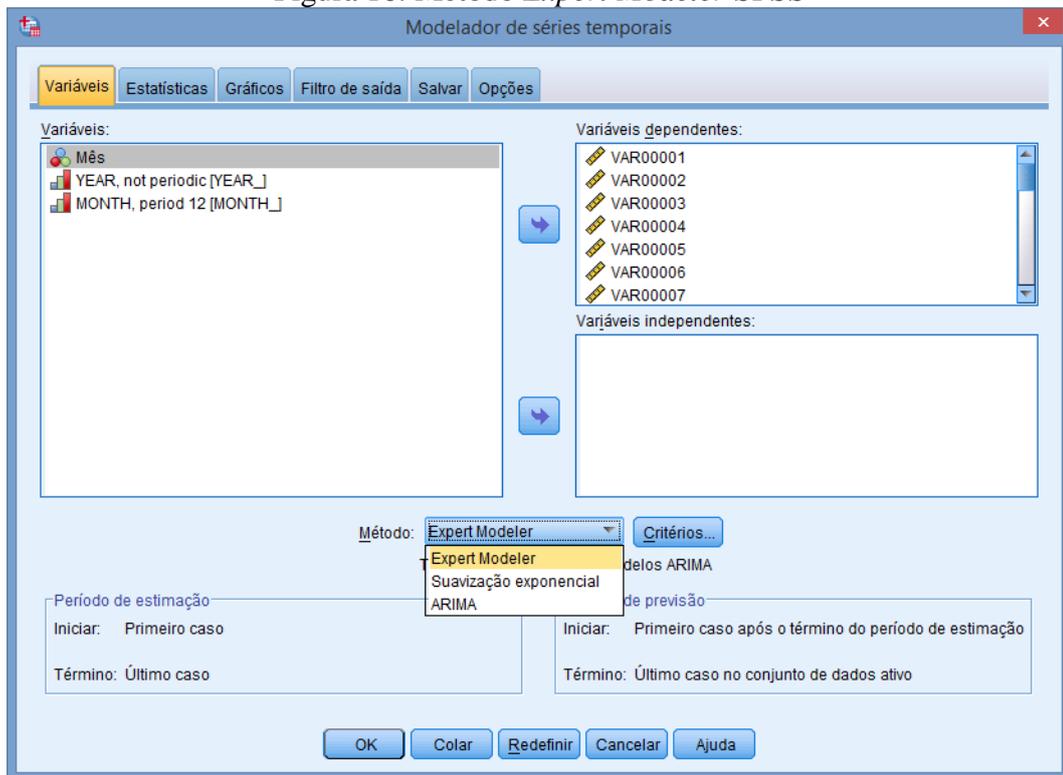
4.2.7 *Box-Jenkins*

Devido ao *Box-Jenkins* utilizar algoritmos complexos para identificar a forma do modelo matemático mais adequado para a série analisada, utilizou-se o SPSS para a aplicação.

Primeiramente aplicou-se o *Software* buscando-se a melhor configuração para o modelo ARIMA (p, d, q) (P, D, Q). Foram feitas três aplicações distintas com as seguintes considerações, todas buscando a previsão de janeiro a agosto de 2017:

- considerando os dados históricos de 2015 e 2016;
- considerando os dados históricos de 2016;
- considerando os dados históricos de um ano de intervalo, ou seja, a cada novo evento, excluiu-se o evento mais antigo, ficando sempre com intervalo de dados de 1 ano.

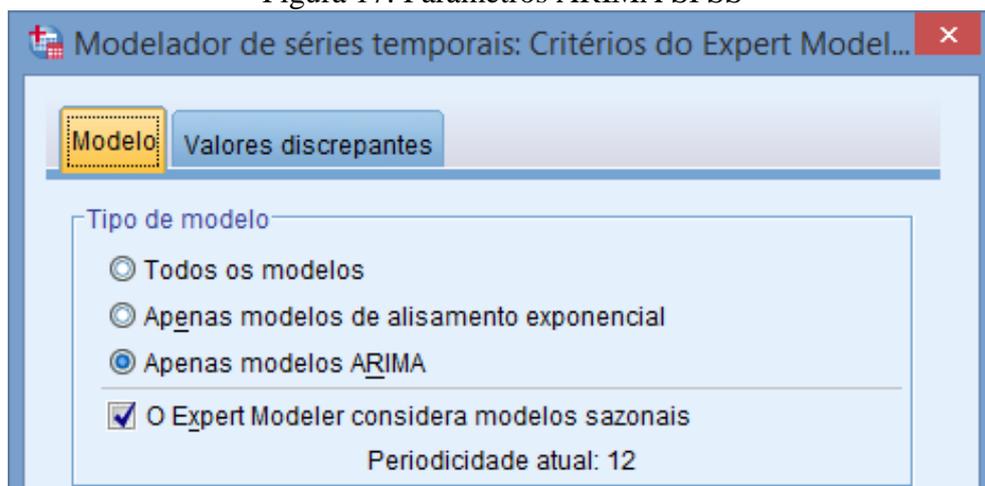
Para obter esse modelo otimizado usou-se o método *Expert Modeler*, encontrado no SPSS como está mostrado na Figura 16.

Figura 16: Método *Expert Modeler* SPSS

Fonte: Software SPSS (2017).

Os parâmetros para se obter a otimização estão ilustrados na Figura 17, onde o critério de modelamento foi utilizado considerando apenas modelos ARIMA.

Figura 17: Parâmetros ARIMA SPSS



Fonte: Software SPSS (2017).

Com os parâmetros mencionados, aplicou-se o método *Expert Modeler* e obteve-se as previsões. Os erros médios para as três situações citadas, estão apresentados na Tabela 13.

Tabela 13: MAPE *Box-Jenkins* otimizado x Método atual

Código	Método atual	<i>Box-Jenkins</i> 2015 e 2016	<i>Box-Jenkins</i> 2016	<i>Box-Jenkins</i> 1 ano
MAPE	41%	40%	37%	* 36%
655.12FX	19%	25%	15%	18%
655.02PT	13%	12%	13%	13%
655.05CR	26%	18%	18%	21%
654.02PT	24%	23%	19%	20%
631.05CR	29%	49%	33%	34%
071.35BR	44%	32%	28%	40%
570.00PR	37%	30%	39%	37%
655.03PR	24%	24%	19%	18%
998.51	40%	36%	30%	33%
650.02PT	17%	28%	29%	27%
101.01C7	36%	37%	33%	39%
275.12FX	47%	44%	42%	50%
101.12FX	63%	39%	46%	55%
631.00PR	22%	19%	23%	23%
275.12FX	56%	58%	60%	44%
071.35PT	23%	19%	15%	15%
226.12FX	140%	67%	101%	86%
071.35PB	32%	31%	23%	23%
654.03PR	34%	35%	39%	26%
655.05PR	53%	113%	34%	39%
275.00PR	28%	28%	34%	29%
101.00PR	64%	59%	55%	56%
101.00C7	32%	49%	34%	36%
631.00BS	77%	78%	83%	58%
046.05PR	55%	70%	68%	69%
653.02PT	14%	29%	24%	21%
101.03PR	44%	41%	46%	56%
631.00PR	58%	55%	60%	49%
136.07AZ	51%	32%	34%	34%
631.03PR	28%	32%	20%	16%

Fonte: Elaborado pelo autor (2017).

O método retornou configurações ótimas para cada série de dados, distintas em cada situação conforme ilustrado na Tabela 14. As diferentes configurações que foram identificadas

entre todos os itens são ARIMA (0, 0, 0,) (0, 0, 0,), ARIMA (0, 1, 0,) (0, 0, 0,), ARIMA (1, 1, 0,) (0, 0, 0,), ARIMA (1, 0, 0,) (0, 0, 0,), ARIMA (0, 2, 0,) (0, 0, 0,) e ARIMA (0, 0, 0,) (0, 1, 1,).

Tabela 14: Configurações ARIMA otimizado

	CÓDIGO	JAN	FEV	MAR	ABR	MAI	JUN	JUL	AGO
<i>Box-Jenkins</i> 2015 e 2016	101.01C7	(1,0,0)	(1,0,0)	(1,0,0)	(1,0,0)	(1,0,0)	(1,0,0)	(0,1,0)	(0,1,0)
<i>Box-Jenkins</i> 2016	101.01C7	(0,1,0)	(0,0,0)	(0,0,0)	(0,0,0)	(0,0,0)	(0,0,0)	(0,1,0)	(0,1,0)
<i>Box-Jenkins</i> 1 ano	101.01C7	(0,1,0)	(0,1,0)	(1,0,0)	(0,0,0)	(0,0,0)	(0,0,0)	(0,1,0)	(0,1,0)
<i>Box-Jenkins</i> 2015 e 2016	101.03PR	(1,1,0)	(1,1,0)	(1,1,0)	(1,1,0)	(1,1,0)	(1,1,0)	(1,1,0)	(1,1,0)
<i>Box-Jenkins</i> 2016	101.03PR	(0,0,0)	(1,1,0)	(0,1,0)	(1,1,0)	(0,0,0)	(0,0,0)	(0,0,0)	(0,0,0)
<i>Box-Jenkins</i> 1 ano	101.03PR	(0,0,0)	(0,0,0)	(0,1,0)	(0,0,0)	(0,0,0)	(0,0,0)	(0,0,0)	(0,0,0)
<i>Box-Jenkins</i> 2015 e 2016	226.12FX	(1,1,0)	(0,1,0)	(1,1,0)	(0,1,0)	(0,1,0)	(0,1,1)	(1,1,0)	(1,0,0)
<i>Box-Jenkins</i> 2016	226.12FX	(0,0,0)	(0,0,0)	(0,0,0)	(0,0,0)	(0,0,0)	(0,0,0)	(0,0,0)	(0,0,0)
<i>Box-Jenkins</i> 1 ano	226.12FX	(0,0,0)	(0,0,0)	(0,0,0)	(0,0,0)	(0,0,0)	(0,0,0)	(0,0,0)	(0,0,0)
<i>Box-Jenkins</i> 2015 e 2016	655.05PR	(0,2,0)	(0,0,1)	(0,1,0)	(0,1,0)	(0,1,0)	(0,1,0)	(0,1,0)	(0,1,0)
<i>Box-Jenkins</i> 2016	655.05PR	(0,2,0)	(0,0,0)	(0,0,0)	(0,0,0)	(0,0,0)	(0,0,0)	(0,0,0)	(0,0,0)
<i>Box-Jenkins</i> 1 ano	655.05PR	(0,2,0)	(0,0,0)	(0,1,0)	(1,0,0)	(0,1,0)	(0,0,0)	(0,0,0)	(0,0,0)

Fonte: Elaborado pelo autor (2017).

As diferentes configurações encontradas no modelamento otimizado foram aplicadas novamente de forma geral para todos os itens, para identificar o impacto delas sobre os dados.

Foram modeladas todas as configurações considerando os dados de 2015 e 2016 (2 anos) e somente sobre 2016 (1 ano). Para ambos os períodos foram consideradas as três possibilidades de transformação da variável dependente, Nenhuma, Raiz quadrada e Logaritmo natural. Na Tabela 15 estão demonstradas todas as aplicações realizadas em cada item, totalizando um total de 36 configurações em cada item.

Tabela 15: Configurações aplicadas

Período	Transformações	Configurações ARIMA					
1 ano	Nenhuma	(1,0,0)	(0,0,0)	(1,1,0)	(0,1,0)	(0,2,0)	(0,1,1)
	Raiz quadrada	(1,0,0)	(0,0,0)	(1,1,0)	(0,1,0)	(0,2,0)	(0,1,1)
	Log natural	(1,0,0)	(0,0,0)	(1,1,0)	(0,1,0)	(0,2,0)	(0,1,1)
2 anos	Nenhuma	(1,0,0)	(0,0,0)	(1,1,0)	(0,1,0)	(0,2,0)	(0,1,1)
	Raiz quadrada	(1,0,0)	(0,0,0)	(1,1,0)	(0,1,0)	(0,2,0)	(0,1,1)
	Log natural	(1,0,0)	(0,0,0)	(1,1,0)	(0,1,0)	(0,2,0)	(0,1,1)

Fonte: Elaborado pelo autor (2017).

Os erros apresentados na Tabela 16 são referentes a previsão que apresentou o menor erro para cada uma das configurações ARIMA.

Tabela 16: MAPE *Box-Jenkins* x Método atual

(continua)

Código	Método atual	(1,0,0) 2 anos	(0,0,0) 1 ano	(1,1,0) 2 anos	(0,1,0) 2 anos	(0,2,0) 2 anos	(0,1,1) 2 anos Raiz
MAPE	41%	28%	36%	29%	* 27%	41%	28%
655.12FX	19%	23%	15%	16%	25%	47%	18%
655.02PT	13%	13%	13%	16%	21%	44%	13%
655.05CR	26%	15%	18%	18%	19%	26%	18%
654.02PT	24%	18%	19%	12%	12%	18%	10%
631.05CR	29%	43%	33%	50%	32%	64%	36%
071.35BR	44%	10%	30%	19%	11%	14%	21%
570.00PR	37%	27%	44%	19%	21%	35%	16%
655.03PR	24%	24%	19%	25%	28%	17%	19%
998.51	40%	35%	34%	35%	36%	50%	35%
650.02PT	17%	23%	38%	25%	28%	39%	15%
101.01C7	36%	38%	42%	41%	40%	51%	40%
275.12FX	47%	35%	42%	39%	37%	46%	41%
101.12FX	63%	41%	49%	41%	40%	46%	39%
631.00PR	22%	25%	23%	36%	43%	95%	27%
275.12FX	56%	41%	56%	30%	23%	34%	29%
071.35PT	23%	18%	15%	17%	21%	42%	16%
226.12FX	140%	53%	101%	49%	41%	57%	52%
071.35PB	32%	29%	23%	30%	30%	38%	29%
654.03PR	34%	38%	33%	44%	40%	68%	29%

(conclusão)

Código	Método atual	(1,0,0) 2 anos	(0,0,0) 1 ano	(1,1,0) 2 anos	(0,1,0) 2 anos	(0,2,0) 2 anos	(0,1,1) 2 anos Raiz
MAPE	41%	28%	36%	29%	* 27%	41%	28%
655.05PR	53%	25%	32%	22%	22%	22%	22%
275.00PR	28%	26%	34%	13%	17%	47%	25%
101.00PR	64%	29%	55%	30%	29%	44%	27%
101.00C7	32%	38%	34%	29%	19%	30%	26%
631.00BS	77%	10%	58%	12%	22%	18%	19%
046.05PR	55%	27%	68%	48%	45%	57%	47%
653.02PT	14%	24%	26%	27%	26%	34%	24%
101.03PR	44%	38%	45%	41%	30%	32%	36%
631.00PR	58%	15%	31%	42%	9%	36%	43%
136.07AZ	51%	36%	34%	39%	33%	51%	34%
631.03PR	28%	26%	18%	18%	15%	14%	28%

Fonte: Elaborado pelo autor (2017).

Seguindo a mesma lógica de aplicação nos modelos otimizados, optou-se por aplicar mais duas configurações, ARIMA (1, 0, 1) (0, 0, 0) e ARIMA (2, 0, 1) (0, 0, 0). Essas duas configurações foram definidas por meio de inúmeras aplicações alternando um dos três valores para as componentes do modelo ARIMA (0,0,0), os valores de cada componente para a qual retornou o menor erro foram agrupados, compondo os modelos as duas configurações aplicados, ou seja, para a componente AR, os dois valores com menor erro foram 1 e 2. Para a componente I o menor erro se obteve com o valor 0 e para a componente MA o valor foi 1. Os resultados obtidos estão apresentados da Tabela 17.

Tabela 17: MAPE *Box-Jenkins* aleatório x Método atual

(continua)

Código	Método atual	(1,0,1) 1 ano	(2,0,1) 1 ano
MAPE	41%	28%	* 26%
655.12FX	19%	14%	15%
655.02PT	13%	11%	12%
655.05CR	26%	14%	9%
654.02PT	24%	17%	16%
631.05CR	29%	35%	36%

(conclusão)

Código	Método atual	(1,0,1) 1 ano	(2,0,1) 1 ano
071.35BR	44%	23%	12%
570.00PR	37%	23%	22%
655.03PR	24%	18%	18%
998.51	40%	32%	29%
650.02PT	17%	20%	17%
101.01C7	36%	41%	40%
275.12FX	47%	51%	37%
101.12FX	63%	29%	18%
631.00PR	22%	28%	29%
275.12FX	56%	28%	27%
071.35PT	23%	19%	17%
226.12FX	140%	49%	50%
071.35PB	32%	23%	19%
654.03PR	34%	33%	30%
655.05PR	53%	24%	25%
275.00PR	28%	26%	27%
101.00PR	64%	48%	47%
101.00C7	32%	24%	24%
631.00BS	77%	15%	8%
046.05PR	55%	52%	54%
653.02PT	14%	19%	22%
101.03PR	44%	39%	40%
631.00PR	58%	46%	44%
136.07AZ	51%	30%	26%
631.03PR	28%	21%	20%

Fonte: Elaborado pelo autor (2017).

Quando se analisou os resultados de todas as configurações aplicadas pelo modelo *Box-Jenkins*, com exceção do modelo ARIMA (0, 2, 0) que apresentou a mesmo erro percentual que o modelo atual, os demais modelos apresentaram redução no erro médio. O modelo que resultou no menor MAPE é ARIMA (2, 0, 1) que apresentou 15 pontos percentuais abaixo do modelo atual.

4.3 MENSURAR OS GANHOS PARA A EMPRESA

Inicialmente foi calculado os erros de previsão, Equação (29), para todos os períodos analisados em cada item. Para valores positivos, ou seja, quando a demanda real foi menor que a previsão do modelo, calculou-se um custo de estoque pela Equação (33), considerando como taxa de juros a taxa Selic de 0,604% ao mês, referente ao dia 19/11/2017.

Os valores negativos, quando a demanda real foi maior que as previsões, foram considerados como uma possível perda de venda. Para esses valores foram analisados de duas maneiras, a primeira forma considerando que não se tem estoque, ou seja, toda a diferença entre a previsão e a demanda foi considerado como perda de venda. A diferença foi multiplicada pelo preço de venda do item em questão.

A segunda análise foi desenvolvida considerando que o estoque estaria composto por 80% da média dos últimos 6 meses, conforme política da empresa. Neste caso teve-se um custo associado a perda de venda apenas para os valores em que a diferença da previsão foi acima do valor do estoque, ou seja, se o erro for de 100 peças, e o estoque médio seria de 90 peças, considerou-se a diferença de 10 peças no cálculo do custo de perda de venda.

Os valores de ganho foram encontrados calculando-se a diferença entre cada modelo aplicado em relação ao método atual. Pode-se perceber na coluna de “ganhos” valores positivos, ou seja, modelos que não são ideais para a aplicação na empresa por apresentarem um custo maior que o método atual, e valores negativos, ou seja, modelos que apresentaram uma redução de custo mensal em relação ao método atual.

Na Tabela 18 estão apresentados os custos mensais médios para cada modelo e os ganhos em relação ao modelo atual, para ambas as considerações citadas.

Tabela 18: Custos mensais e ganhos com o modelo

(continua)

Modelo aplicado	Considerando zero estoque		Considerando estoque de segurança de 80% da média	
	Custo mensal médio (R\$)	Ganho (R\$)	Custo mensal médio (R\$)	Ganho (R\$)
Método atual	213.847,93		22.207,55	
<i>Box-Jenkins</i> (2,0,1) 1 ano	203.217,34	- 10.630,59	3.751,96	- 18.455,59
<i>Box-Jenkins</i> (1,0,1) 1 ano	194.571,78	- 19.276,15	4.371,13	- 17.836,42

(continua)

Modelo aplicado	Considerando zero estoque		Considerando estoque de segurança de 80% da média	
	Custo mensal médio (R\$)	Ganho (R\$)	Custo mensal médio (R\$)	Ganho (R\$)
<i>Box-Jenkins</i> (0,1,1) 2 anos Raiz	228.451,01	14.603,09	6.552,83	- 15.654,72
<i>Box-Jenkins</i> (0,1,0) 2 anos	309.204,67	95.356,74	7.289,82	- 14.917,73
<i>Box-Jenkins</i> (1,1,0) 2 anos	271.699,91	57.851,99	7.862,02	- 14.345,53
<i>Box-Jenkins</i> (1,0,0) 2 anos	303.844,74	89.996,81	8.779,22	- 13.428,33
<i>Box-Jenkins</i> (0,2,0) 2 anos	493.464,18	279.616,25	9.238,37	- 12.969,18
Suavização exponencial simples otimizado $\alpha=0,46$	232.136,00	18.288,07	17.103,61	- 5.103,94
Suavização exponencial simples $\alpha=0,8$	306.716,08	92.868,15	18.138,00	- 4.069,55
Suavização exponencial simples $\alpha=0,2$	214.916,58	1.068,65	19.012,90	- 3.194,65
MMP 9m otimizada	288.095,73	74.247,81	19.457,44	- 2.750,11
MMP 6m otimizada	303.738,96	89.891,03	20.816,04	- 1.391,51
<i>Box-Jenkins</i> otimizado 2015 e 2016	348.316,94	134.469,01	22.239,26	31,71
<i>Holt</i> modelamento mês a mês	314.752,03	100.904,10	22.849,66	642,11
MMP 3m	314.328,42	100.480,49	25.360,86	3.153,31
MMP 9m ajustada	299.100,21	85.252,28	26.876,66	4.669,11
MMP 9m	299.100,21	85.252,28	26.876,66	4.669,11
MM 9m	291.982,67	78.134,75	27.528,17	5.320,62
MMP 12m	294.937,94	81.090,01	27.955,59	5.748,04
<i>Box-Jenkins</i> otimizado 2016	301.221,84	87.373,91	28.362,04	6.154,49
MM 3m	321.634,88	107.786,95	28.761,69	6.554,14
MMP 6m	317.064,17	103.216,24	29.026,48	6.818,93
MM 6m	325.559,79	111.711,86	30.745,54	8.537,99
MM 12m	286.494,03	72.646,11	31.927,10	9.719,55

(conclusão)

Modelo aplicado	Considerando zero estoque		Considerando estoque de segurança de 80% da média	
	Custo mensal médio (R\$)	Ganho (R\$)	Custo mensal médio (R\$)	Ganho (R\$)
<i>Box-Jenkins</i> (0,0,0) 1 ano	331.612,40	117.764,47	33.654,02	11.446,47
<i>Box-Jenkins</i> otimizado 1 ano	278.043,98	64.196,05	34.058,65	11.851,10
Modelo de <i>Holt</i> raiz	179.990,61	33.857,32	35.947,26	13.739,71
<i>Holt</i> modelamento para 8 meses	227.160,56	13.312,63	43.015,19	20.807,64
Multiplicativo de Winters raiz	2.231.399,46	2.017.551,53	492.581,37	470.373,82
Multiplicativo de Winters log	2.256.975,74	2.043.127,81	513.552,14	491.344,59
Multiplicativo de Winters	2.307.792,34	2.093.944,41	515.301,83	493.094,28
Modelo de <i>Holt</i> log	565.551.599,	565.337.751,	565.422.711,	565.400.504,

Fonte: Elaborado pelo autor (2017).

Na análise dos dados, pode-se concluir que se obteve como melhor modelo o *Box-Jenkins* (2,0,1) para 1 ano, com uma redução mensal de R\$ 18.455,59.

4.4 DEFINIR O MODELO MAIS ADEQUADO PARA A EMPRESA COM BASE NO ERRO

A escolha do modelo ideal se fez analisando o MAPE e o MAE médio dos modelos aplicados, buscando-se o modelo que mais se aproxima da demanda real. A Tabela 19 resume os modelos aplicados e os MAPEs e MAEs encontrados.

Tabela 19: Resumo MAPE e MAE

(continua)

Modelo aplicado	MAPE	MAE
Método atual	41%	40
<i>Box-Jenkins</i> (2,0,1) 1 ano	26%	29
<i>Box-Jenkins</i> (0,1,0) 2 anos	27%	38

		(conclusão)
<i>Box-Jenkins</i> (0,1,1) 2 anos Raiz	28%	33
<i>Box-Jenkins</i> (1,0,0) 2 anos	28%	35
<i>Box-Jenkins</i> (1,0,1) 1 ano	28%	31
<i>Box-Jenkins</i> (1,1,0) 2 anos	29%	34
MMP 9m ajustada	35%	36
MMP 9m otimizada	34%	35
MMP 6m otimizada	34%	35
MMP 9m	35%	36
MMP 6m	35%	36
MMP 12m	36%	36
Suavização exponencial simples otimizado $\alpha=0,46$	36%	35
MMP 3m	36%	36
MM 6m	36%	37
MM 3m	36%	37
<i>Box-Jenkins</i> (0,0,0) 1 ano	36%	38
<i>Box-Jenkins</i> otimizado 1 ano	36%	38
MM 9m	37%	37
<i>Box-Jenkins</i> otimizado 2016	37%	36
Suavização exponencial simples $\alpha=0,8$	37%	40
Suavização exponencial simples $\alpha=0,2$	38%	37
MM 12m	39%	39
<i>Holt</i> modelamento mês a mês	40%	40
<i>Box-Jenkins</i> otimizado 2015 e 2016	40%	42
<i>Box-Jenkins</i> (0,2,0) 2 anos	41%	59
Multiplicativo de Winters	57%	148
<i>Holt</i> modelamento para 8 meses	63%	50
Multiplicativo de Winters raiz	70%	148
Multiplicativo de Winters log	77%	127
Modelo de <i>Holt</i> raiz	79%	74
Modelo de <i>Holt</i> log	117%	88

Fonte: Elaborado pelo autor (2017).

A análise dos MAPE, permite-se concluir que o modelo *Box-Jenkins* (2,0,1) para o período de 1 ano é o modelo que apresenta o menor erro em relação a demanda real e também pode-se concluir que se tem um ganho de 15 pontos percentual em relação ao modelo atualmente adotado. Quando se analisa o MAE, identifica-se que o menor valor para o erro está presente no mesmo modelo, *Box-Jenkins* (2,0,1) 1 ano.

4.5 PROPOR A IMPLANTAÇÃO DO MODELO ESCOLHIDO

Por meio das análises definiu-se como o melhor modelo o *Box-Jenkins* (2,0,1) para 1 ano, devido a ser o modelo com menor MAPE e o qual retornará, se aplicado, o maior ganho financeiro para a empresa. Esse modelo foi o mais eficaz na obtenção da previsão para os canais de venda aplicados, P&A e *Aftermarket*. Para outros canais se faz necessário uma nova aplicação e análise dos resultados.

Para implantar de maneira satisfatória o modelo escolhido, se faz necessário a obtenção do *Software* SPSS, assim como a licença de utilização do mesmo. O custo de aquisição do SPSS é de R\$ 14.911,49, e um custo de manutenção de 25% deste valor anualmente, dados fornecidos pela OSB *Softwares*.

Com o SPSS adquirido, a aplicação do modelo pode ser feita de maneira simples e as previsões obtidas rapidamente. Com o histórico de vendas atualizado, basta inserir os dados no *Software*, ajustar os parâmetros de acordo com o modelo e calcular as previsões. A aplicação pode ser estendida para todos os itens dos canais estudados, assim como para outros canais de venda.

A proposta de implementação ocorreu apresentando o estudo realizado aos gestores comerciais e de logística da empresa, propondo a aplicação do modelo para a construção da previsão referente ao mês de janeiro de 2018. Para comprovar a eficácia do modelo proposto, ao final do mês de janeiro será feita nova análise comparando-se com o método atual.

5 CONCLUSÃO

Em um mundo competitivo, a redução de custos é uma necessidade das empresas de grande importância, pois é um fator imprescindível para a sustentabilidade financeira do negócio. Para justificar a implementação de uma nova metodologia de previsão de demanda é necessário que a mesma traga retorno financeiro a empresa.

O estudo realizado possibilitou identificar a importância dos modelos de previsão de demanda como ferramenta para tomada de decisão. Dos modelos aplicados, 76% deles resultaram em erros médios abaixo do modelo atualmente adotado, quando analisado em termos de custo, 12 modelos apresentam uma redução de custo financeiro mensal.

Os modelos MMS, MMP e Suavização exponencial são modelos de simples implementação, podem ser aplicados utilizando o *Software* Excel, sendo uma ferramenta de uso comum nas empresas e não requer investimento.

Já para os modelos mais complexos, como Modelo de *Holt*, Modelo de *Winters* e *Box-Jenkins*, que também podem ser aplicados no Excel, porém com a necessidade da aplicação de programação do *Software* ou então investir em um *software* estatístico, como o SPSS utilizado neste trabalho. As duas possibilidades requerem investimento, o qual deve ser compensado pela utilização do modelo.

Após os modelos serem analisados identificou-se que o modelo *Box-Jenkins* (2,0,1) para 1 ano foi o modelo com o melhor resultado em relação aos demais modelos aplicados e em relação ao modelo atual, que ficou com erro médio 15 pontos percentuais mais baixo que o método atual.

O modelo proposto retornou um erro médio de 26%, que apesar de individualmente os itens apresentarem erros médios que oscilam ultrapassando esse percentual, pode-se perceber analisando os resultados do modelo que 83% dos itens apresentam valores abaixo da média da metodologia atual, que é de 41%. O modelo *Box-Jenkins* (2,0,1) para 1 ano apresentou uma redução de custo mensal de R\$18.455,59 o que resulta em uma redução anual de R\$ 221.467,13.

Além de trazer reduções de custo financeiro, a utilização de um modelo matemático que retorne uma previsão mais acurada, pode implicar em melhorias para outros fatores da empresa. A aquisição de insumos e de matérias-primas, por exemplo, é diretamente influenciada pela previsão de demanda, podendo-se assim ter redução nos gastos com compras desnecessárias. Outro ponto que pode ser beneficiando é a formação do quadro de funcionários, que é definido com base na previsão de demanda para os meses seguintes.

As principais diferenças entre o método atual e o modelo proposto está na maneira de obter as previsões. No método atual utiliza-se o *Software* Excel, já para o modelo proposto se faz necessário a aquisição do *Software* SPSS, onde os históricos de venda são carregados e após aplicar as configurações definidas obtém-se as previsões.

Na metodologia proposta, uma revisão anual das configurações para o modelo *Box-Jenkins* é indicada, para que possam ser otimizadas e sempre se utiliza aquela que traga a melhor previsão possível para o modelo.

Com a definição de um novo modelo de previsão de demanda, que atenda às necessidades da empresa e traga um retorno financeiro, conclui-se que o objetivo geral deste trabalho foi alcançado, e a proposta de implementação do modelo foi então apresentada a empresa.

5.1 SUGESTÕES PARA TRABALHOS FUTUROS

A gama de técnicas de previsão de demanda é bem ampla, neste trabalho foram abordados alguns modelos quantitativos de series temporais aplicados de forma individual. Como sugestão dentre as técnicas aplicadas a utilização do método *Expert Modeler* do SPSS, considerando a opção de otimizar outros modelos não apenas o modelo ARIMA.

Uma opção inteligente seria a combinação de mais que um modelo de previsão para cada família de produtos que melhor se adapte aos dados existentes. Outra sugestão é a de abordar modelos que analisam de forma quantitativa e qualitativa, como o método *Delphi*, que integra os dados históricos com a análise qualitativa de um especialista.

Por fim, como última sugestão, propõe-se a aplicação dos modelos buscando-se outros parâmetros como maior horizonte de previsão ou maior agilidade na construção da previsão, ao invés de enfatizar a acurácia e a redução de custo financeiro.

REFERÊNCIAS

- BALLOU, R. H. **Gerenciamento da cadeia de suprimentos: Planejamento, organização e logística empresarial**. 4. ed. Porto Alegre: Bookman, 2001.
- BALLOU, R. H. **Gerenciamento da cadeia de suprimentos/Logística empresarial**. 5. ed. Porto Alegre: Bookman, 2006. Tradução Raul Rubenich.
- BERTAGLIA, P. R. **Logística e gerenciamento da cadeia de abastecimento**. 2. ed. São Paulo: Saraiva, 2009.
- BOWERSOX, D. J.; CLOSS, D. J.; COOPER, M. B. **Gestão de suprimentos e logística**. Rio de Janeiro: Elsevier, 2007. Tradução de Cláudia Mello Belhassof.
- BOX, G. E. P.; JENKINS, G. M.; REINSEL, G. C. **Time series analysis**. Forecasting and control. 4ª ed. New Jersey: John Wiley and Sons, 2008.
- CASTANHEIRA, N. P. **Métodos quantitativos**. Curitiba: Intersaberes, 2013. Disponível em: <<https://ucsvirtual.ucs.br>>. Acesso em: 15 abr. 2017.
- CAVALHEIRO, D. **Método de previsão de demanda aplicada ao planejamento da produção de indústrias de alimentos**. 2003. 137 f. Dissertação (Mestrado em Engenharia Mecânica) – Universidade Federal Santa Catarina, programa de pós-graduação em Engenharia Mecânica, Florianópolis, 2003. Disponível em: <<https://repositorio.ufsc.br/bitstream/handle/123456789/85516/203135.pdf?sequence=1>>. Acesso em: 12 abr. 2017.
- CHOPRA, S.; MEINDL, P. **Gerenciamento da cadeia de suprimentos: Estratégias, planejamentos e operações**. São Paulo: Prentice Hall, 2003. Tradução de Claudia Freire; revisão técnica Paulo Roberto Leite.
- CHOPRA, S.; MEINDL, P. **Gestão da cadeia de suprimentos: Estratégias, planejamentos e operações**. 4. ed. São Paulo: Pearson Prentice Hall, 2011. Tradução Daniel Vieira; revisão técnica Marilson Alves.
- CORRÊA, H. L.; CORRÊA, C. A. **Administração da produção e operações: Manufatura e serviços: uma abordagem estratégica**. São Paulo: Atlas, 2004.
- CORRÊA, H. L.; CORRÊA, C. A. **Administração da produção e operações: Manufatura e serviços: uma abordagem estratégica**. 3. ed. São Paulo: Atlas, 2012.
- DIAS, M. A. P. **Administração de materiais: uma abordagem logística**. 4. ed. São Paulo: Atlas, 1993. Reimpressão 2009.
- ECONOMIA. **Taxa Selic hoje**. Disponível em: <<http://carteirarica.com.br/taxa-selic/>>. Acesso em 19 nov. 2017.

FLEURY, P. F.; WANKE, P.; FIGUEIREDO, K. F. **Logística empresarial: A perspectiva brasileira**. São Paulo: Atlas, 2000.

GAITHER, N.; FRAZIER, G. **Administração da produção e operações**. 8. ed. São Paulo: Cengage Learning, 2002. Tradução José Carlos Barbosa dos Santos.

GIL, A. C. **Como elaborar projetos de pesquisa**. 4. ed. São Paulo: Atlas, 2002.

GIL, A. C. **Como elaborar projetos de pesquisa**. 5. ed. São Paulo: Atlas, 2010.

IBM. **IBM SPSS Forecasting 24**. Disponível em:

<ftp://public.dhe.ibm.com/software/analytics/spss/documentation/statistics/24.0/pt-BR/client/Manuals/IBM_SPSS_Forecasting.pdf>. Acesso em: 28 set. 2017.

KEKO ACESSÓRIOS. **Sobre**. Disponível em: <<http://www.keko.com.br/sobre/>>. Acesso em: 14 mar. 2017.

KÖCHE, J. C. **Fundamentos da metodologia científica: Teoria da ciência e iniciação a pesquisa**. 31. ed. Petrópolis, Rio de Janeiro: Vozes, 2012.

KRAJEWSKI, L. J.; RITZMAN, L. P.; MALHOTRA, M. K. **Operations management processes and value chains**. 8. ed. New Jersey: Pearson Prentice Hall, 2007.

LE MOS, F. O. **Metodologia para seleção de métodos de previsão de demanda**. 2006. 183 f. Dissertação (Mestrado em Engenharia de Produção) – Universidade Federal do Rio Grande do Sul, programa de pós-graduação em Engenharia de Produção, Porto Alegre, 2006.

Disponível em:

<<http://www.producao.ufrgs.br/arquivos/publicacoes/fernandooliveiralemos.pdf>>. Acesso em: 11 abr. 2017.

PELLEGRINI, F. R. **Metodologia para implementação de sistemas de previsão de demanda**. 2000. 130 f. Dissertação (Mestrado em Engenharia de Produção) – Universidade Federal do Rio Grande do Sul, programa de pós-graduação em Engenharia de Produção, Porto Alegre, 2000. Disponível em:

<<http://www.producao.ufrgs.br/arquivos/publicacoes/Fernando%20R%20Pellegrini.pdf>>. Acesso em: 11 abr. 2017.

PUCCINI, A. L. **Matemática financeira objetiva e aplicada**. 9ª ed. São Paulo: Elsevier, 2011. Disponível em: <https://kupdf.com/download/abelardo-puccini-auth-matem-aacute-tica-financeira-objetiva-e-aplicada-2012_58d872d2dc0d60bc22c3464d_pdf>.

RITZMAN, L. P.; KRAJEWSKI, L. J. **Administração da produção e operações**. São Paulo: Prentice Hall, 2004. Tradução Roberto Galman; Revisão técnica Carlos Eduardo Mariano da Silva.

ROCHA, D. **Fundamentos técnicos da produção**. São Paulo: Makron Books, 1995.

SEVERINO, A. J. **Metodologia do trabalho científico**. 23. ed. São Paulo: Cortez, 2007.

SLACK, N.; CHAMBERS, S.; JOHNSTON, R. **Administração da produção**. 2. ed. São Paulo: Atlas, 2002. Tradução Maria Teresa Corrêa de Oliveira, Fábio Alher; revisão técnica Henrique Luiz Corrêa.

SLACK, N.; CHAMBERS, S.; JOHNSTON, R. **Administração da produção**. 3. ed. São Paulo: Atlas, 2009. Tradução Henrique Luiz Corrêa.

VALLE, A. **A atual situação econômica do Brasil**. Disponível em: <<http://www.empreendedoresweb.com.br/atual-situacao-economica-do-brasil/>>. Acesso em: 27 mar. 2017.

WERNER, L. **Um modelo composto para realizar previsão de demanda através da integração da combinação de previsões e do ajuste baseado em opinião**. 2004. 166 f. Tese (Doutorado em Engenharia de Produção) – Universidade Federal do Rio Grande do Sul, programa de pós-graduação em Engenharia de Produção, Porto Alegre, 2004. Disponível em: <<https://www.lume.ufrgs.br/bitstream/handle/10183/4189/000453479.pdf?sequence=1>>. Acesso em: 11 abr. 2017.

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 e produção. v.10, n.1, p. 47-67, 2003. Disponível em: <<http://www.scielo.br>>. Acesso em: 20 abr. 2017