

UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ
COORDENAÇÃO DE ENGENHARIA DE PRODUÇÃO
CURSO DE GRADUAÇÃO EM ENGENHARIA DE PRODUÇÃO

FLÁVIA SAYURI MIURA

**AVALIAÇÃO, ANÁLISE E PREVISÃO DE DEMANDA POR MEIO DE
MÉTODOS ESTATÍSTICOS EM UMA INDÚSTRIA ALIMENTÍCIA DO
OESTE DO PARANÁ**
TRABALHO DE DIPLOMAÇÃO

MEDIANEIRA

2016

FLÁVIA SAYURI MIURA

**AVALIAÇÃO, ANÁLISE E PREVISÃO DE DEMANDA POR MEIO DE
MÉTODOS ESTATÍSTICOS EM UMA INDÚSTRIA ALIMENTÍCIA DO
OESTE DO PARANÁ**

TRABALHO DE DIPLOMAÇÃO

Trabalho de conclusão de curso apresentado ao Curso de Graduação, em Engenharia de Produção, da Universidade Tecnológica Federal do Paraná, como requisito parcial à obtenção do título de Engenheira de Produção.

Orientador(a): Prof(a). Dr(a). Carla A. P. Schmidt.

Co-orientador: Prof. Dr. José Airton Azevedo dos Santos.

MEDIANEIRA

2016

AGRADECIMENTOS

Agradeço primeiramente a Deus, que se mostrou criador, que foi criativo, que é o centro e o fundamento de tudo em minha vida, por fazer tudo novo, por renovar a cada momento minha força e disposição e pelo discernimento concedido ao longo dessa jornada.

Aos meus pais, irmãos, professores, amigos, a minha orientadora, a meu noivo e todos aqueles que estão ao meu lado nessa jornada, meu sincero agradecimento.

“ lembre-se que as pessoas podem tirar tudo de você, menos o seu conhecimento”.

Albert Einstein.

RESUMO

MIURA, Flávia Sayuri. **Avaliação, análise e previsão de demanda por meio de métodos estatísticos em uma indústria alimentícia do oeste do Paraná.** 2016. 68 f. Trabalho de Conclusão de Curso (Graduação) de Engenharia de Produção apresentado a Universidade Tecnológica Federal do Paraná. Medianeira, 2016.

O presente estudo visa avaliar, analisar e prever a demanda através de técnicas de suavização exponencial e análises estatísticas aplicadas ao conjunto de dados históricos de dois produtos de uma empresa do ramo alimentício situada no oeste do Paraná. Primeiramente buscou por meio de um estudo bibliográfico conhecer alguns métodos utilizados para prever a demanda. A seguir os dados históricos dos produtos foram coletados e avaliados a fim de se obter os produtos de maior representatividade em termos de produção e comercialização para a posterior realização das análises estatísticas. A análise descritiva dos dados contou com o auxílio de um *software* estatístico livre o Gretl. Além disso, a seleção do modelo e previsão de demanda foi realizada por meio de um aplicativo adicionado ao *Excel* o Nnq-statística. Os melhores modelos para os produtos foram o MMM e o MNM, onde o primeiro tudo foi tratado por correções multiplicativas e no segundo apenas a tendência não precisou ser tratado, pois era inexistente. Os modelos foram validados com base em dados reais e as previsões pelos modelos foram satisfatórias.

Palavras-chave: Suavização exponencial; Previsão de demanda; Séries temporais; Curva ABC.

ABSTRACT

MIURA, Flavia Sayuri. **Evaluation, analysis and demand forecasting using statistical methods in a food industry in western Paraná.** 2016. 68 f. Work Completion of course (Graduation) Production Engineering presented the Federal Technological University of Paraná. Medianeira, 2016.

This study aims to evaluate, analyze and forecast demand by exponential smoothing techniques and statistical analysis applied to historical data set of two products of a food company located in western Parana. First sought through a bibliographic study to know some methods used to forecast demand. Following the historical data of the products were collected and evaluated in order to obtain the most representative products in terms of production and marketing for the subsequent completion of the statistical analyzes. The descriptive analysis of the data had the help of a free statistical software the Gretl. In addition, the model selection and demand prediction was performed by an application added to the Excel-Nnq Statistica. The best designs for products were the MMM and the MNM, where the first all was treated by multiplicative corrections and the second only the trend did not need to be treated because it was non-existent. The models were validated based on actual data and forecasts by the models were satisfactory.

Keywords: Exponential Smoothing; demand forecasting; Series time; ABC curve

LISTA DE FIGURAS

Figura 1.- Indicadores econômicos da indústria alimentícia	15
Figura 2 - Gráfico de classificação ABC representando a porcentagem de itens no estoque pela porcentagem de valores que cada item representa.	17
Figura 3.- Etapas do processo de previsão de demanda	20
Figura 4 - Métodos de previsão	23
Figura 5 – Os tipos de curvas e modelos matemáticos de correlação entre variáveis.	28
Figura 6 - A reta de mínimo quadrados	29
Figura 7 - Processo de estimação da regressão múltipla.....	31
Figura 8 - Classificação da Pesquisa	41
Figura 9 - Etapas da resolução de problema em PO	43
Figura 10 - Curva ABC	47
Figura 11 - Histograma sobreposto por curva normal dos dados de venda do produto 1080.	50
Figura 12 – Box-plot dos dados de venda obtidos mensalmente com o produto 1080.	51
Figura 13 - Gráfico do dados de venda do produto 1080 referente aos meses de análise	52
Figura 14 - Índices sazonais do conjunto de dados do produto 1080	52
Figura 15 - Previsto x Realizado	55
Figura 16 - Histograma sobreposto por curva normal dos dados de venda do produto 1070.	57
Figura 17 - Box-plot dos dados de venda obtidos mensalmente com o produto 1080.	58
Figura 18 - Gráfico do dados de venda do produto 1070 referente aos meses de análise	58
Figura 19 - Índices sazonais do conjunto de dados do produto 1070	59
Figura 20 - Previsto x Realizado	61

LISTA DE QUADROS

Quadro 1 - Descrição das Classes ABC.	17
Quadro 2 – Tipos de demanda padrão.....	22
Quadro 3 - Exemplos de aplicação de regressão linear múltipla.....	30
Quadro 4 - Equações dos métodos utilizados nas previsões de suavização exponencial na forma de correção de erro.....	36
Quadro 5 - Modelos de suavização Nnq-estatística	45

LISTA DE SIGLAS

ABIA	Associação Brasileira das Indústrias de Alimentos
AIC	Akaike
PIB	Produto Interno Bruto
MAD	Mean Absolute Deviaton
MSE	Mean Squared Error
MAPE	Mean Absolute Percentage Error
PP	Planejamento da Produção

LISTA DE SÍMBOLOS

α	Constante de suavização para base
β	Constante de suavização para tendência
γ	Constante de suavização para sazonalidade
β_n	Coefficiente desconhecido da regressão
\hat{y}	Regressão múltipla estimada

SUMÁRIO

1 INTRODUÇÃO	11
2 OBJETIVOS	13
2.1 OBJETIVO GERAL	13
2.2 OBJETIVOS ESPECÍFICOS	13
3 REVISÃO DE LITERATURA	14
3.1 O SETOR ALIMENTÍCIO BRASILEIRO	14
3.2 GESTÃO DE ESTOQUES.....	15
3.2.1 Classificação ABC.....	16
3.3 PREVISÃO DE DEMANDA	18
3.3.1 Etapas de um Modelo de Previsão.....	19
3.3.2 Métodos de Previsão.....	21
3.4 MODELOS QUALITATIVOS	23
3.4.1 Método Delfi	24
3.4.2 Pesquisa de Mercado.....	25
3.4.3 Simulação de Cenário	25
3.5 MODELOS QUANTITATIVOS.....	26
3.5.1 Modelos de Correlação e Regressão	26
4.4.1.1 Regressão simples	27
4.4.1.2 Regressão múltipla.....	29
3.5.2 Projeções Baseadas em Séries Temporais.....	31
4.4.2.1 Modelo de médias móveis	32
4.4.2.2 Modelos de suavização exponencial	32
3.6 MEDIDA E CONTROLE DO ERRO	37
4 MATERIAIS E MÉTODOS	40
4.1 A EMPRESA	40
4.2 CLASSIFICAÇÃO DA PESQUISA	40
4.3 COLETA DE DADOS	44
4.4 ANÁLISE DE DADOS.....	44
5 RESULTADOS E DISCUSSÃO	46
5.1 CURVA ABC	46
5.2 ANÁLISE ESTATÍSTICA PARA O PRODUTO 1080.....	48
5.2.1 Análise Descritiva das Vendas	48
5.2.2 Escolha do Método Adequado	51
5.2.3 Previsão Utilizando o Método Escolhido	54
5.3 ANÁLISE ESTATÍSTICA PARA O PRODUTO 1070.....	56
5.3.1 Análise Descritiva das Vendas	56
5.3.2 Escolha do Método Adequado	58
5.3.3 Previsão Utilizando o Método Escolhido	60
6 CONCLUSÃO	63
REFERÊNCIAS	64

1 INTRODUÇÃO

A indústria alimentícia tem uma notável importância na economia brasileira, dados da ABIA - Associação Brasileira das Indústrias de Alimentos (2015) mostram que esse ramo de indústria possui uma participação de 10,2% no Produto Interno Bruto (PIB) e aproximadamente 22,5% na indústria de transformação, com um faturamento líquido de R\$ 525,8 bilhões, sendo o maior empregador na indústria de transformação com cerca de 1,6 milhão de empregos diretos no ano de 2014.

Frente a essa importância do setor alimentício na economia, percebe-se a necessidade de se entender o mercado futuro adotando ferramentas eficientes e eficazes que auxiliem o planejamento estratégico de produção.

Fernandes e Godinho (2010, p.17) ao estudarem a utilidade da previsão afirmam que: “No atual ambiente competitivo é inegável que as previsões têm um papel fundamental, servindo como guia para o planejamento estratégico da produção, finanças e vendas de uma empresa”.

Desta forma, a análise e previsão da demanda podem ser adotadas como ferramentas eficientes no planejamento estratégico, pois permite que a empresa saiba o que seu cliente quer, quando e quanto ele precisa. Esta ferramenta tem ganho espaço nas organizações por proporcionar as empresas uma vantagem competitiva.

A escolha do modelo de previsão que se adeque à demanda dos produtos permitirá menor erro na previsão. Assim esse trabalho tem como finalidade a avaliação, análise e previsão da demanda de dois produtos de uma empresa do ramo alimentício utilizando métodos estatísticos de previsão.

O interesse em contribuir no desempenho da indústria por meio de uma ferramenta que auxilie no planejamento da produção foi estimulado pela importância do setor alimentício no cenário econômico do país e da importância da empresa em estudo no cenário econômico e social do município e região.

“O planejamento da Produção (PP) inicia-se com a gestão de demanda no médio prazo, que tem como principal objetivo conhecer a demanda por meio de previsões” (FERNANDES; GODINHO, 2010, p.10).

Sendo o processo de planejamento a base de toda organização, Tubino (2009) mostra que as previsões exercem um papel fundamental nos processos de

planejamento de sistemas de produção, por meio delas pode-se antever o futuro para conseqüentemente planejar as ações adequadas.

Este trabalho se torna relevante quando procura auxiliar no processo de planejamento de produção e também auxiliar no planejamento do estoque da empresa em estudo. Sua finalidade é melhorar o processo de previsão de demanda existente na empresa através da escolha de um modelo de previsão que atenda os padrões da demanda e que possua o menor erro entre demanda real e demanda prevista, fazendo com que os erros de planejamento e estoques sejam minimizados e que a demanda dos consumidores sejam supridas no momento certo e na quantidade certa.

2 OBJETIVOS

2.1 OBJETIVO GERAL

Avaliar, analisar e prever a demanda de produtos em uma empresa do ramo alimentício.

2.2 OBJETIVOS ESPECÍFICOS

- a) Definir os produtos mais representativos na produção e comercialização da empresa.
- b) Coletar dados de demanda desses produtos.
- c) Aplicar modelos de previsão de demandas futuras aos dois produtos que se mostraram mais representativos.
- d) Realizar uma avaliação dessas previsões com vistas à realidade da empresa.

3 REVISÃO DE LITERATURA

A presente revisão literária abordou alguns conceitos teóricos pertinentes para a elaboração deste trabalho. Inicialmente foi realizada uma abordagem sobre o cenário atual do setor em que a empresa atua para posteriormente apresentar um enfoque especial contendo os conceitos de previsão de demanda e seus métodos de execução.

3.1 O SETOR ALIMENTÍCIO BRASILEIRO

A indústria alimentícia é de suma importância no desenvolvimento do Brasil sendo considerada como uns dos mais importantes setores da economia do país. Para Birchal (2004), a importância do setor alimentício na economia brasileira não se deve somente ao fato de tal setor ser o propulsor da industrialização e representar grande parte das indústrias brasileiras de grande porte, mas sim a diversos acontecimentos ao longo de todo o século XX que evidenciaram a importância e o crescimento desse setor.

De acordo com Cecatto e Belfiore (2015), a expansão da indústria alimentícia brasileira trouxe: aumento da produtividade de matéria-prima e embalagem; aumento da quantidade de operações de distribuição atacadista e varejista. Como consequência desse crescimento hoje as indústrias alimentícias participam ativamente no crescimento econômico do país.

A expressiva participação de 10,2% no PIB, o faturamento líquido de R\$ 525,8 bilhões, e a quantidade de gente empregada neste setor ente outros dados da ABIA comprovam a importância das indústrias alimentícias no crescimento econômico do país. Os dados da ABIA entidade de classe que representa o setor alimentício brasileiro são representados na Figura 1.

INDÚSTRIA DA ALIMENTAÇÃO - PRINCIPAIS INDICADORES ECONÔMICOS

CONCEITO	UNIDADE	FONTE	2008	2009	2010	2011	2012	2013	2014
POPULAÇÃO	Milhões de hab.	IBGE	191,5	193,5	195,5	197,4	199,2	201,0	202,8
1) PIB									
PIB (Preços Correntes)	R\$ Bi	IBGE	3.032	3.239	3.770	4.143	4.403	4.838	5.163
PIB (Preços de 2014)	R\$ Bi		4.535	4.520	4.860	4.993	5.037	5.152	5.163
PIB Var% Real			5,2	-0,3	7,5	2,7	0,9	2,3	0,2
PIB per Capita									
PIB Per Capita (Preços Correntes)	R\$/ano	IBGE	15.830	16.737	19.285	20.988	22.096	24.065	25.452
PIB Per Capita (Preços de 2014)			23.676	23.352	24.861	25.294	25.279	25.630	25.452
PIB Var% Real			4,0	-1,4	6,5	1,7	-0,1	1,4	-0,7
VALOR DA PRODUÇÃO INDUSTRIAL									
Indústria Geral	R\$ Bi	IBGE/PIA/	1.662,1	1.526,5	1.820,1	2.018,8	2.179,6		
Indústria de Transformação	R\$ Bi	CNI	1.607,9	1.440,9	1.696,1	1.907,0	2.082,9	2.273,8	2.331,6
Indústria da Alimentação (Produtos Alimentares + Bebidas)									
Faturamento (líquido de impostos indiretos)	R\$ Bi		269,0	291,6	330,6	383,3	431,9	484,7	525,8
Participação no PIB	%	ABIA	8,9	9,0	8,8	9,3	9,8	10,0	10,2
Participação na Ind. de Transformação	%		16,7	20,2	19,5	20,1	20,7	21,3	22,5
Faturamento (líq. de impostos ind.)	R\$ Bi de 2014		405,2	419,2	448,8	475,1	496,7	517,9	525,8
Indústria de Bebidas									
Faturamento Líquido (líquido de impostos indiretos)	R\$ Bi	ABIA	38,9	45,0	56,0	66,8	78,0	90,1	101,2
Faturamento (líq. de impostos ind.)	R\$ Bi de 2014		58,6	64,7	76,0	82,8	89,7	96,3	101,2
Indústria de Produtos Alimentares									
Faturamento Líquido (líquido de impostos indiretos)	R\$ Bi	ABIA	230,0	246,7	274,6	316,5	353,9	394,6	424,5
Faturamento (líq. de impostos ind.)	R\$ Bi de 2014		346,6	354,6	372,8	392,3	407,0	421,6	424,5
Indústria de Produtos Alimentares - Principais Setores (Faturamento Líquido a Preços Correntes)									
Derivados de Carne			61,0	58,5	66,0	79,1	88,7	100,8	115,6
Benefício de Café, Chá e Cereais			31,1	32,9	35,9	40,6	46,9	52,8	56,9
Açúcares			15,9	30,2	37,7	42,2	41,9	40,9	38,3
Laticínios			26,4	29,0	33,1	38,1	42,2	50,1	55,2
Óleos e Gorduras			32,0	29,0	29,3	34,5	40,9	42,3	44,7
Derivados de Trigo			18,7	18,9	19,9	21,4	23,5	26,8	29,5
Derivados de Frutas e Vegetais			14,8	14,9	15,6	18,2	20,4	23,7	25,5
Diversos (salgadinhos, sorvetes, temperos e leved.)			14,0	15,4	17,7	20,5	24,2	28,7	31,5
Chocolate, Cacau e Balas			9,1	9,9	10,5	11,5	12,4	13,1	13,4
Desidratados e Supergelados (pratos prontos cong., veg. supe)			5,1	5,6	6,5	7,4	9,5	11,3	13,2
Conservas de Pescados			2,0	2,3	2,5	2,9	3,4	4,0	4,6

Figura 1.- Indicadores econômicos da indústria alimentícia
Fonte: ABIA (2015)

Apesar dos índices vistos na Figura 1 serem favoráveis a capacidade de produção ainda precisa melhorar. De acordo com Oliveira e Oliveira (2003, p. 5), “a ocupação média da capacidade instalada coloca em evidência que o setor possui margem para crescer nos próximos anos”.

3.2 GESTÃO DE ESTOQUES

Os estoques representam grande parte dos ativos de uma empresa, por esta razão necessitam de um gerenciamento eficaz. Um bom gerenciamento dos estoques possibilita um aumento na lucratividade, redução de espaços no estoque, entre outros, a gestão de estoque pode ser uma vantagem competitiva de grande importância para a empresa.

“Estoque é qualquer quantidade de produtos ou materiais, sob controle da

empresa, em um estado relativamente ocioso, esperando por seu uso ou venda” (LOVE, 1979 *apud* LUSTOSA et al., 2008, p.77).

A gestão do estoque compreende o processo de controle e monitoramento dos pedidos, do armazenamento e da venda dos produtos que a empresa fabrica ou compra. Através da gestão de estoque eficaz obtêm-se informações de quando, quanto e o que deve ser repostado no estoque ou produzido.

Em outras palavras Corrêa e Corrêa (2012), explicam que é necessário definir quando ressuprir e a quantidade a ser ressuprida, para que o estoque supra a necessidade da demanda

De acordo com Dias (2012), de um modo geral a gestão do estoque é guiada pela previsão do consumo de material ou da demanda, ou seja, por estimativas futuras dos produtos acabados, comercializados e vendidos pela empresa.

3.2.1 Classificação pelo Método ABC

Em todo o tipo de estoque que possua mais de um item armazenado é comum que um ou mais itens tenham maior importância para a empresa do que outros. Neste sentido Slack, Chambers e Johnston (2009), uma maneira comum de classificar os itens em estoque é criar uma lista classificando-os de acordo com suas movimentações de valor.

O método de classificação ABC é uma ferramenta que auxilia na gestão do estoque, tem a finalidade de separar os itens de maior relevância ou impacto para a empresa, ou seja, aqueles que necessitam de uma maior atenção em sua gestão de estoque.

De acordo com Lustosa et al. (2008), por meio da necessidade de se ordenar todos itens do estoque a fim de centralizar grande parte dos esforços na gestão dos mais importantes, uma prática eficiente de administração foi proposta por Vilfredo Pareto, em 1897, conhecida como curva ABC, essa prática propõe que grande parte dos efeitos está ligado a poucas causas.

Dias (2012), explica que as classes ABC podem ser determinadas de acordo com o Quadro 1.

CLASSES	DESCRIÇÃO
A	Pode ser descrita como o conjunto dos itens principais no estoque que exigem do gestor uma atenção especial.
B	Engloba os itens de importância intermediárias que exigem um controle menos rigoroso do que os itens da classe A.
C	Descrita como o conjunto dos itens de menor importância que requerem menor atenção por parte do gestor.

Quadro 1 - Descrição das Classes ABC.

Fonte: Adaptado de Dias, (2012).

A classificação de acordo com a lei de Pareto gera uma curva semelhante ao gráfico da Figura 2.

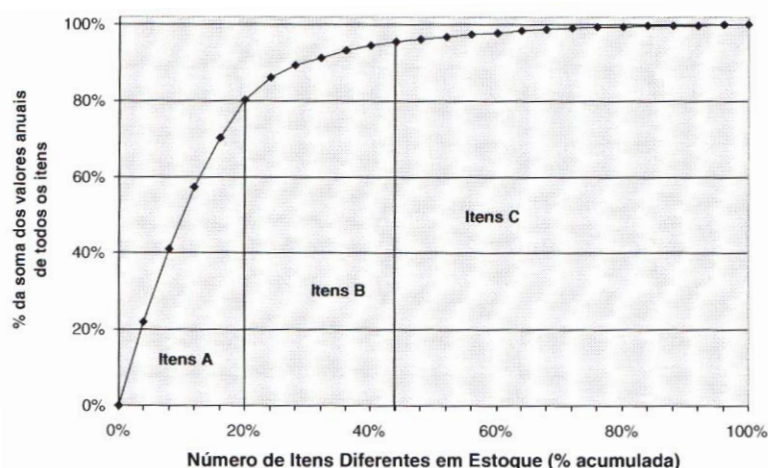


Figura 2 - Gráfico de classificação ABC representando a porcentagem de itens no estoque pela porcentagem de valores que cada item representa.

Fonte: Lustosa et al. (2008 p. 82).

Onde os itens da classe A representam 20% dos itens em estoque e 80% na representatividade em relação a soma de valores. Os itens da classe B representam 30% dos itens em estoque e 10% de representatividade em relação a soma de valores. Já os itens da classe C são aqueles itens de baixo valor que representam grande parte dos itens, cerca de 50% dos itens em estoque e 10% da soma de valores.

“Os itens com movimentação de valor particularmente alto demandam controle cuidadoso, enquanto aqueles com baixas movimentações de valor não precisam ser controlados tão rigorosamente” (SLACK; CHAMBERS E JOHNSTON, 2009, p.377).

Conforme Lustosa et al. (2008), a aplicabilidade da curva ABC não se

restringe apenas na gestão de estoque, é uma ferramenta de grande importância na definição de políticas de vendas, na programação de produção entre outras situações de uma organização.

3.3 PREVISÃO DE DEMANDA

De uma forma geral, todas as organizações elaboram estratégias e utilizam-se de métodos, a fim de se alcançar seus objetivos. Esses métodos e essas estratégias são pautados em previsões, de modo que a previsão de demanda destaca-se entre as demais previsões, sendo crucial na obtenção dos resultados planejados. No sentido de realçar a importância desse tipo de previsão serão citados a seguir conceitos e definições de alguns autores a cerca do tema que é previsão de demanda.

Para Hyndman e Athanasopoulos (2013), previsão é a forma mais exata de prever o futuro por intermédio das informações disponíveis.

De acordo Oliveira (2002), a previsão refere-se ao estudo dos eventos que poderão acontecer no futuro, com base no apontamento de uma série de probabilidades.

Segundo Martins e Laugeni (2005, p. 226),

Previsão é o processo metodológico para determinação de dados futuros baseados em modelos estatísticos, matemático ou econométricos ou ainda em modelos subjetivos apoiados em uma metodologia de trabalho clara e previamente definida.

A previsão desempenha um papel muito importante na empresa, está diretamente integrada com a parte de gestão, pois além de ser uma ferramenta que auxilia na tomada de decisão de qualquer organização, decisões essas sobre a programação, transporte e pessoal, também provê um roteiro para o planejamento estratégico em longo prazo (HYNDMAN; ATHANASOPOULOS, 2013).

“É necessário saber quanto a empresa planeja vender seus produtos ou serviços no futuro, pois essa expectativa é o ponto de partida, direto ou indireto, para praticamente todas as decisões” (MOREIRA, 2011, p. 293).

Entende-se por demanda, segundo Lustosa et al. (2008), o ato de procura

por bens ou serviços por parte do cliente. Sendo que diversos fatores, tanto interno como externo, podem influenciar nessa procura do consumidor.

Analisando a demanda de produtos de consumo no varejo, verifica-se a influência sobre a demanda de fatores comerciais como preço, disponibilidade, oferta de crédito, publicidade, ações da concorrência etc. Essa multiplicidade de fatores combinados, cada qual com sua própria dinâmica, explica a incerteza da demanda e, como consequência, sua dificuldade de previsão (LUSTOSA et al.,2008, p. 50).

Corrêa, Giansesi e Caon (2010), afirmam que é essencial que a empresa aprenda a utilizar as ferramentas disponíveis para prever demandas futuras com precisão. Envolvendo nesse processo dados históricos de venda, informações que expliquem uma variação ou comportamento, modelos matemáticos, fatores internos e externos sobre a demanda, informações necessárias do mercado, sendo capaz de prover uma estimativa da demanda futura.

Neste contexto se torna indispensável que a empresa utilize um método para prever o comportamento da demanda, ou seja, realize uma previsão de demanda para o efeito de planejamento de produção.

Pois segundo, Tubino (2009), o suporte para o planejamento estratégico da produção, bem como para vendas e finanças de qualquer empresa é a previsão de demanda.

De acordo com Lustosa et al. (2008), a previsão de demanda alcança o papel central no processo de planejamento da organização, visto que através delas são tomadas as principais decisões nas áreas financeiras, comerciais e operacionais. Com base nessa informação a eficiência da previsão terá um resultado direto na economia da empresa.

3.3.1 Etapas de um Modelo de Previsão

A elaboração de um processo formal de previsão de demanda tem influência direta no planejamento da empresa, tal processo de previsão consiste no conjunto de ações básicas que devem ser tomadas ao longo da previsão. De acordo com Corrêa e Corrêa (2012), a previsão é o produto de ações envolvendo coleta de dados, análise dos dados, a busca de métodos, o grau de erro da previsão e o seu comportamento padrão.

De acordo com Lustosa et al. (2008), devido a sua dinamicidade o processo de planejamento necessita de revisões constantes de seus planos, para atender essa necessidade do planejamento é preciso uma constante revisão no processo de previsão, para que o mesmo possa atender as expectativas do planejamento e forneça informações atuais. Neste contexto, se torna relevante a formalização do processo de previsão de demanda, visto que o mesmo contribuirá para a melhoria do processo de planejamento e controle da produção.

Tubino (2009), desenvolveu um processo de previsão baseado em 5 etapas, conforme Figura 3.

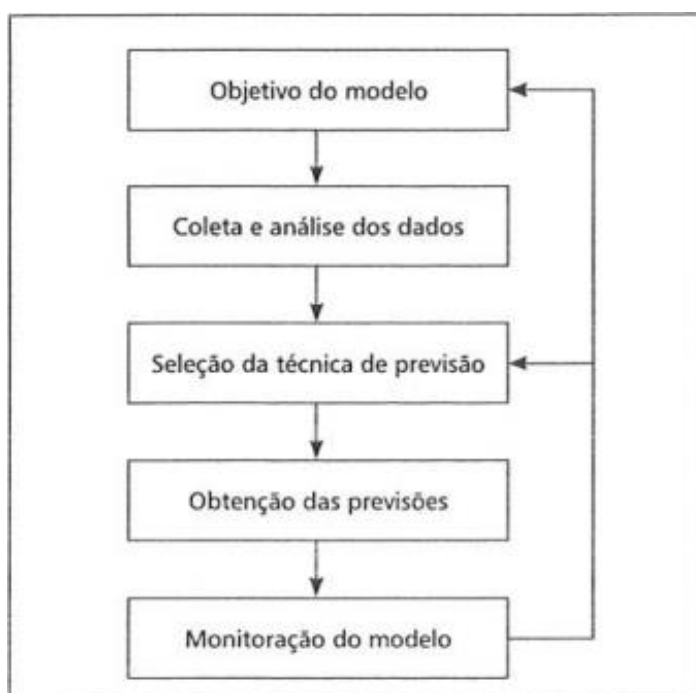


Figura 3.- Etapas do processo de previsão de demanda
Fonte: Tubino (2009).

Onde a etapa inicial de um processo de previsão consiste na identificação dos objetivos da previsão, definindo nesta etapa a finalidade e a abrangência da previsão.

“Um processo formal de previsão de demanda inicia-se com a definição clara do objetivo principal, que está associado à necessidade da previsão da demanda” Lustosa et al. (2008, p.54).

Uma vez que se tenha determinado o objetivo principal da previsão é necessário coletar os dados em que se baseará a previsão, dados como registro de vendas e eventos futuros ou passados, que poderá influenciar na demanda.

Hyndman e Athanasopoulos (2013).

Após coleta e análise dos dados, Tubino (2009) afirma que se pode a partir daí optar pelo modelo de previsão mais pertinente para a situação, levando-se em conta principalmente o custo e a precisão do modelo escolhido, entre outros fatores.

A partir da seleção do modelo adequado, a próxima etapa consiste em gerar previsões para um período determinado da série.

Para Hyndman e Athanasopoulos (2013), assim que for selecionado o modelo de previsão adequado e aplicando os dados coletados neste modelo, obtêm-se parâmetros para a previsão futura da demanda.

Por fim a ultima etapa consiste no monitoramento dos resultados. A partir das projeções geradas pelo modelo e da demanda real do período é possível monitorar a confiabilidade das previsões por meio de medidas de erros.

“À medida que as previsões forem sendo alcançadas pela demanda real, deve-se monitorar a extensão do erro entre a demanda real e a prevista para verificar se a técnica e os parâmetros empregados ainda são válidos” (TUBINO, 2009, p. 17 á 18).

3.3.2 Métodos de Previsão

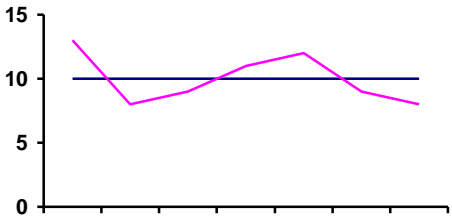
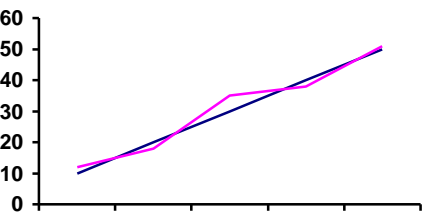
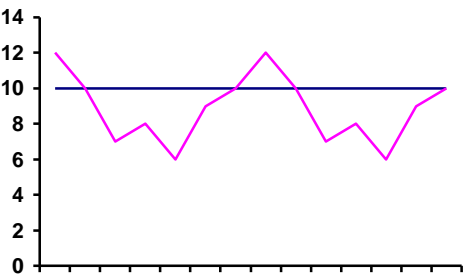
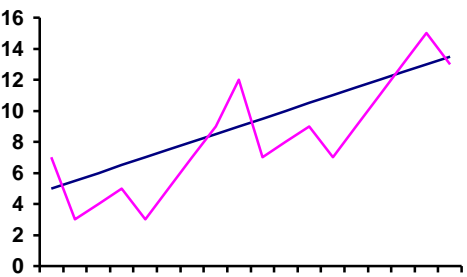
A seleção do método de previsão é uma etapa de suma importância no processo de previsão de demanda, através da escolha do método adequado a demanda, se obterá a previsão dentro de uma certa precisão.

Para Chopra e Meindl (2011), a empresa precisa primeiramente compreender dimensões importantes à previsão, dimensões como área geográfica, grupo de produtos e clientes. Ao analisar cada dimensão a empresa precisará compreender as variações de demanda sofridas entre elas, por meio dessa análise a empresa poderá optar por métodos de previsão adequados a cada dimensão.

De acordo com Martins e Laugeni (2005), para se obter um método de previsão adequado é necessário primeiramente obter informações referentes a demanda dos produtos.

Dessa forma Lustosa et al. (2008), descreve quatro tipos de demanda usadas como padrão, conforme Quadro 2.

Neste mesmo contexto Hyndman e Athanasopoulos (2013), ressaltam que a escolha do método adequado depende muito dos dados disponíveis da demanda. Para esses autores se não houver dados numéricos disponíveis ou se os dados disponíveis não são importantes para a previsão, é recomendável a utilização de métodos qualitativos de previsão. Por outro lado caso haja dados numéricos do passado e que a demanda tem certo padrão é recomendável a utilização de métodos quantitativos.

Demanda	Descrição	Ilustração
Média ou Estacionária	Neste caso as oscilações da demanda giram em torno de um valor constante ao longo do tempo.	
Tendência	As variações de demanda neste caso seguem um padrão de crescimento (ou redução).	
Estacionária sazonal	Neste caso a demanda cresce ou decresce em certos períodos ou ciclos sazonais.	
Tendência e sazonalidade	Neste caso a demanda tem uma tendência ou crescimento ou decréscimo em certos períodos ou ciclos sazonais.	

Quadro 2 – Tipos de demanda padrão

Fonte: Lustosa et al. (2008) adaptado pela pesquisadora.

Ainda segundo Tubino (2009), os métodos de previsões podem ser divididos em dois grupos, sendo eles métodos qualitativos e métodos quantitativos. O método qualitativo é baseado em dados subjetivos, difíceis de representar numericamente. No entanto, os métodos quantitativos são baseados em análise numérica dos dados passados e técnicas de estatística.

Lustosa et al. (2008), citam alguns métodos de previsão de demanda na Figura 4.

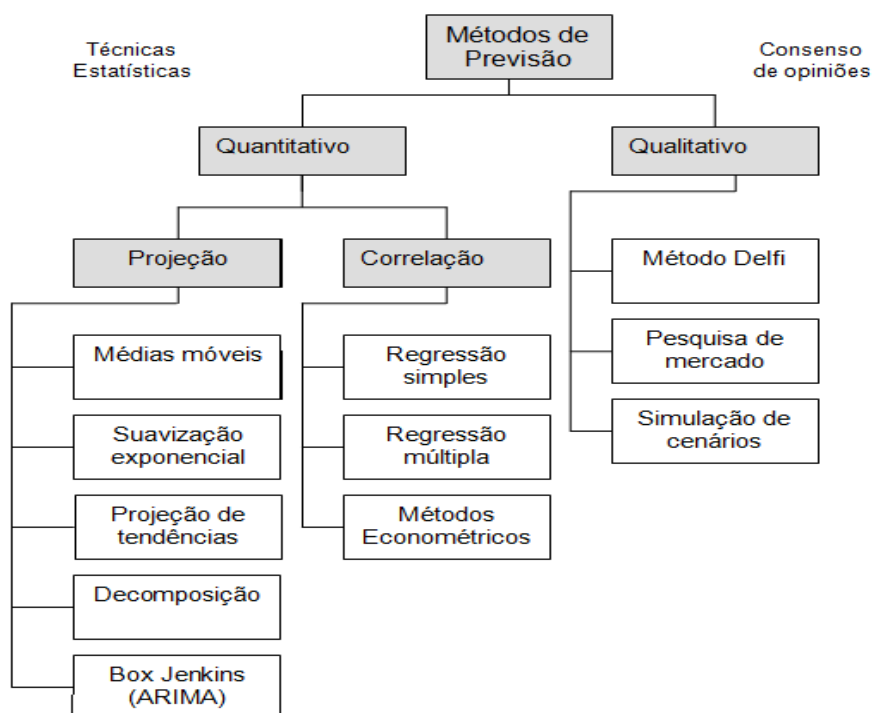


Figura 4 - Métodos de previsão
 Fonte: Lustosa et.al (2008).

Nos tópicos a seguir serão abordados os seguintes modelos qualitativos: o Método Delfi, Pesquisa de Mercado e Simulação de Cenários. Dentro dos modelos quantitativos serão abordadas apenas Médias móveis, Suavização Exponencial, Projeção de Tendências, Regressão Simples e Regressão Múltipla.

3.4 MODELOS QUALITATIVOS

Devido à falta de informações numéricas julga-se que os modelos de

previsões qualitativas se tratam de meramente adivinhações, essa ideia é errônea visto que existem abordagens avançadas em relação a esses modelos, permitindo obter boas previsões sem o uso de dados históricos.

De acordo com Moreira (2011), os métodos de previsão de demanda qualitativos são baseados no julgamento ou opinião de pessoas, que de uma forma direta ou indireta entendam do assunto ou tenham experiência na área do produto.

Segundo Hyndman e Athanasopoulos (2013), esses métodos qualitativos são na realidade comuns e geralmente utilizados. Em casos onde não há disponibilidade de dados históricos ou se tratado de um lançamento de produto ou ainda quando há entrada de novos concorrentes, entre outros, a única opção é a aplicação de modelos qualitativos para prever a demanda.

Hyndman e Athanasopoulos (2013) ressaltam ainda que a qualidade dos métodos qualitativos progrediu ao longo do tempo, essa melhora é o resultado da inserção de abordagens bem estruturadas e organizadas. Visto que os modelos qualitativos são subjetivos e tem limitações, a implementação de abordagens organizadas e bem estruturadas reduzem as limitações dos modelos de previsão qualitativos.

Nas seções seguintes serão apresentados brevemente algumas técnicas de modelos qualitativos mais comuns.

3.4.1 Método Delfi

O método Delfi foi desenvolvido durante a segunda guerra mundial, tendo por finalidade resolver um problema característico da área militar. O nome dado ao método é uma referência ao oráculo de Delfo, que na antiga Grécia previa eventos futuros. (MOREIRA, 2011).

Atualmente o método Delfi é empregado para prever a demanda nas organizações. Tal método consiste em prever a demanda por meio de um consenso entre as pessoas.

Por esse método, algumas pessoas, que são mantidas no anonimato, respondem a um questionário e o entregam ao coordenador, que por sua vez tabula as respostas e as envia de volta aos participantes. Os participantes podem, então, alterar suas respostas, e o processo é repetido até que se obtenha um consenso” (MARTINS; LUGENI, 2005, p 277).

De acordo com Hyndman e Athanasopoulos (2013), o objetivo do método é estabelecer uma previsão de consenso, onde por meio de um grupo de pessoas opinando de uma forma iterativa sobre o assunto consegue-se chegar a um denominador comum. O método consiste na valorização da opinião de um grupo de pessoas, não se baseando somente em uma única pessoa.

Desta forma, Martins e Laugeni (2005, p.277), destacam que “a utilização de tal método tem alcançado bons resultados na identificação de pontos de mudança”.

3.4.2 Pesquisa de Mercado

O método de previsão baseado na pesquisa do mercado consiste na busca de informações no mercado consumidor, ou seja, procura-se avaliar as opiniões do consumidor final.

Moreira (2011) cita que a razão pela qual se opta por escutar a opinião dos consumidores, é que eles são quem definem a demanda. No entanto essa pesquisa não é tão simples, ela necessita de grandes atenções em seu planejamento, bem como de conhecimentos técnicos aperfeiçoados, para poder gerar resultados satisfatórios.

Segundo Lustosa et al. (2008), o método de pesquisa de mercado é aplicável em diversas situações, por meio dele se pode avaliar situações referentes a demanda, a satisfação do cliente, a participação no mercado, a força da marca, o teste de novos produtos, entre outros.

3.4.3 Simulação de Cenário

“Na simulação de cenários, busca-se construir, a partir da opinião de especialistas, diferentes cenários futuros e, para cada um deles, estimar o comportamento das vendas” (LUSTOSA et al. 2008, p. 58).

O objetivo desse método segundo Hyndman e Athanasopoulos (2013), é

gerar previsões baseadas em cenários possíveis. As previsões neste caso, diferentemente das previsões vistas anteriormente, levam em conta todos os possíveis fatores, sendo eles otimistas ou pessimistas, para que por meio desses fatores possa gerar cenários alternativos, classificados em melhor, intermediário e piores casos.

Para Lustosa et al. (2008), por meio desse método é possível planejar a capacidade e decidir por investimentos no médio e longo prazo.

3.5 MODELOS QUANTITATIVOS

Diferentemente do modelo qualitativo visto anteriormente, o modelo quantitativo segundo Tubino (2009), consiste em prever a demanda por meio de dados históricos, utilizando-se de modelos matemáticos para obter a demanda futura.

De acordo com Corrêa e Corrêa (2012), a previsão gerada por esse método é baseada apenas em dados do passado, ou seja, por meio da análise de dados históricos é possível identificar padrões de comportamento e com esses padrões projetar o futuro das demandas.

Os modelos quantitativos de previsão de demanda conforme visto anteriormente na Figura 2, é subdividido em 2 grupos: previsões baseadas em projeções de séries temporais e previsões baseada em correlações. A seguir serão apresentados alguns métodos de previsão baseadas nesses dois grupos.

3.5.1 Modelos de Correlação e Regressão

Este tópico abordará alguns conceitos de previsões baseadas em correlação, onde serão apresentados os modelos de regressão simples e regressão múltipla. As previsões baseadas em correlações procuram prever a demanda futura com base na previsão do comportamento de uma variável independente, uma variável que não esteja relacionada diretamente ao produto, mas que influencie a

demanda futura.

De acordo com Lustosa et al. (2008), o modelo de regressão é baseado no estudo de correlações entre uma variável dependente e uma ou mais variáveis independentes, por meio deste modelo é possível prever as demandas dependentes em função das demandas independentes.

Para entender melhor como funciona esse tipo de previsão pode-se usar como exemplo a previsão da demanda de fraldas geriátricas, esse tipo de demanda não se relaciona somente com dados históricos de produtos, mas pode estar relacionada com a faixa etária da população.

O objetivo das previsões baseadas em correlações e regressão segundo Tubino (2009, p. 30) “consiste em estabelecer uma equação que identifique o efeito da variável de previsão sobre a demanda do produto em análise”.

Tubino (2009) ressalta ainda, que esse tipo de previsão necessita de dois tipos de dados históricos: dados do produto estudado, ou seja, a variável dependente, e dados da variável da previsão, ou seja, a variável independente.

Se o modelo de previsão correlacionar somente uma variável independente a variável dependente este será denominado de regressão simples, já se o modelo correlacionar duas ou mais variáveis independentes a variável dependente este será denominado de regressão múltipla, como será visto a seguir.

3.5.1.1 Regressão simples

“A análise de regressão é o método de construir, a partir dos dados amostrais, uma função matemática que relacione uma variável independente a outra variável que dependa desta” (BRACARENSE, 2012, p. 217).

Neste tipo de método de previsão por regressão a correlação entre as variáveis envolve somente uma variável independente. Tal método busca encontrar um modelo matemático que se ajuste ao comportamento dessas variáveis.

De acordo com Fusco e Sacomano (2007), o comportamento de uma variável dependente em relação a uma variável independente pode se aproximar de vários tipos de curvas e modelos matemáticos: linear, quadrático, cúbico, exponencial, entre outros como representado na Figura 5.

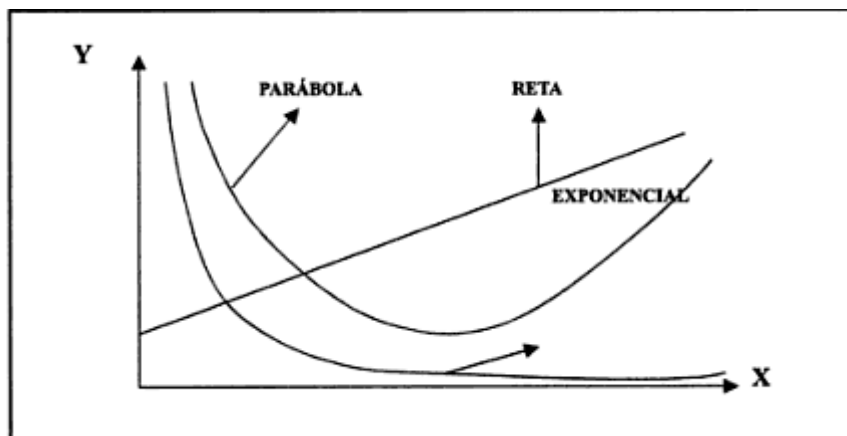


Figura 5 – Os tipos de curvas e modelos matemáticos de correlação entre variáveis.
Fonte: Fusco e Sacomano (2007).

A seguir será apresentado o caso mais simples, e mais comum a regressão linear simples.

De acordo com Martins e Laugeni (2005), esse método consiste em determinar a seguinte Equação (1),

$$Y = a + bX \quad (1)$$

Onde:

Y = previsão de demanda ou variável dependente

a = ponto onde a reta corta o eixo das ordenadas

b = inclinação da reta

X = variável independente da previsão.

Fusco e Sacomano (2007), mostram que a e b podem ser obtidos através da equação (2) e equação (3):

$$b = \frac{n(\sum X.Y) - (\sum X) \cdot (\sum Y)}{n \cdot (\sum X^2) - (\sum X)^2} \quad (2)$$

$$a = \frac{\sum Y - b \cdot (\sum X)}{n} \quad (3)$$

onde :

n = número de pares XY observados.

Para Tubino (2009), o objetivo desse tipo de modelo é encontrar a equação (1) de modo que r (soma dos quadrados dos erros de previsão, representado na figura por β) seja a menor possível. A Figura 6 ilustra essa situação.




Figura 6 - A reta de mínimo quadrados.
Fonte: Tubino (2009).

De acordo com Martins e Laugeni (2005), o coeficiente de determinação r^2 é usado para verificar o nível de ajustamento da reta aos dados, e pode ser calculado através do coeficiente de correlação r , de acordo com a Equação (4):

$$r = \frac{n(\sum XY) - (\sum X)(\sum Y)}{\sqrt{n(\sum X^2) - (\sum X)^2} \cdot \sqrt{n(\sum Y^2) - (\sum Y)^2}} \quad (4)$$

Martins e Laugeni (2005), ainda ressaltam que o valor de r varia entre +1 e -1, sendo recomendável um valor absoluto mínimo de 0,7 para se obter uma boa correlação.

O coeficiente de correlação amostral permite estabelecer estatisticamente o grau de associação linear entre duas variáveis a partir de uma amostra ou conjunto de observações representativas para cada uma delas. Isso significa que o coeficiente de correlação permite estabelecer a força e o sentido de uma possível relação linear entre duas variáveis, a partir de uma amostra representativa (BRACARENSE, 2012, p. 233).

3.5.1.2 Regressão múltipla

O grau de ligação existente entre uma variável dependente e duas ou mais variáveis independentes é denominado correlação múltipla. Similarmente ao método de regressão simples o método de regressão múltiplo busca estabelecer uma equação que se ajuste aos valores da variável dependente dado os valores das variáveis independentes.

De acordo com Barbetta, Reis e Bornia (2010), em um estudo de regressão múltipla, busca-se construir um modelo estatístico-matemático que explique a relação entre variáveis independentes e a variável dependente, para então através

do modelo construído prever a variável dependente em função das variáveis independentes existentes.

“Essa matéria, intitulada análise de regressão múltipla, nos possibilita considerar mais fatores e, desse modo, obter melhores estimativas do que são possíveis com a regressão linear simples” (ANDERSON; SWEENEY; WILLIAMS, 2011, p. 488).

O Quadro 3 apresenta alguns exemplos do uso de regressão linear múltipla de acordo com Barbetta, Reis e Bornia (2010).

<i>Variáveis independentes (X₁, X₂, ..., X_k)</i>	<i>Variável dependente Y</i>
X ₁ = renda (R\$) X ₂ = poupança (R\$) X ₃ = taxa de juros (R\$)	Y = consumo (R\$)
X ₁ = valor do modelo novo (R\$) X ₂ = quilometragem X ₃ = idade do veículo (anos) X ₄ = opcionais	Y = valor de revenda de carro seminovo (R\$)

Quadro 3 - Exemplos de aplicação de regressão linear múltipla
Fonte: Barbetta, Reis e Bornia (2010) adaptado pela pesquisadora.

A equação que expressa como o valor médio da variável dependente (Y) está relacionado às variáveis independentes (X₁, X₂, ... X_p) denomina-se equação de regressão múltipla de acordo com Doane e Seward (2014), pode ser escrita conforme Equação (5):

$$E(y) = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k \quad (5)$$

“Cada coeficiente desconhecido da regressão β_n indica a mudança no valor esperado de Y quando se altera uma unidade em X_n” (DOANE; SEWARD, 2014, p.544).

A regressão múltipla estimada é representada pela Equação (6):

$$\hat{Y} = b_0 + b_1 X_1 + b_2 X_2 + \dots + b_k X_k \quad (6)$$

Utilizando o método dos mínimos quadrados para desenvolver a equação de regressão múltipla estimada Anderson, Sweeney e Williams (2011), mostram na Figura 7, o processo de estimação da regressão múltipla. Sendo que o critério dos mínimos quadrados é representado pela Equação (7):

$$\text{mín } \sum (y_1 - \hat{y}_1)^2 \quad (7)$$

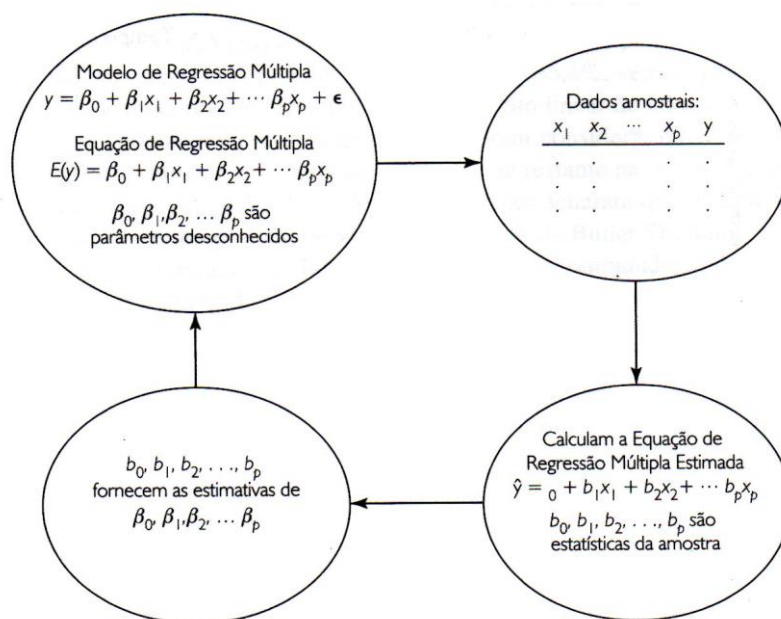


Figura 7 - Processo de estimação da regressão múltipla
 Fonte: Anderson, Sweeney e Williams (2011).

3.5.2 Projeções Baseadas em Séries Temporais

“As previsões baseadas em séries temporais partem do princípio de que a demanda futura será uma projeção dos seus valores passados, não sofrendo influência de outras variáveis” (TUBINO, 2009, p.18).

Nas previsões baseadas em séries temporais a demanda varia somente em função do tempo, ou seja, o tempo é a única variável que influenciará a demanda.

De acordo com Corrêa e Corrêa (2012), os principais componentes desse tipo de modelo são: tendência, sazonalidade e aleatoriedade (variações). O Quadro 2 da página 22 deste trabalho, ilustra a presença desses componentes na demanda.

A presença de tendência em uma série temporal indica a orientação dos dados históricos, ou seja, se os dados estão de forma crescente ou decrescente ao longo do tempo. A sazonalidade indica as variações cíclicas que a série sofre em um período de tempo. Já a presença de aleatoriedade corresponde às variações irregulares na série resultantes de variáveis não previstas no modelo.

“Em função dos fatores que influenciam os dados, a previsão da demanda baseada em séries temporais pode ser subdividida em passos, cada um deles

relacionados ao dimensionamento destes fatores” (TUBINO, 2009, p.19).

A seguir serão apresentados modelos de previsões que abrange cada um desses fatores.

4.4.2.1 Modelo de médias móveis

Os modelos de previsão por meio de médias móveis utilizam dados históricos em um determinado período de tempo t_n para calcular a média dos valores da série temporal para assim prever o instante de tempo t_{n+1} .

Os modelos de médias móveis de acordo com Corrêa e Corrêa (2012) afirmam que a melhor previsão do futuro é fornecida através da média dos n últimos períodos. Neste sentido, Tubino (2009) explica que a simplicidade operacional e facilidade de entendimento é a grande vantagem que esse modelo apresenta.

Partindo desta definição Tubino (2009), Equação (8) pela qual a média móvel pode ser obtida :

$$Mm_n = \frac{\sum_{i=1}^n Di}{n} \quad (8)$$

onde:

Mm_n = média móvel de n períodos;

D_i = demanda ocorrida no período i ;

n = número de períodos;

i = índice do período ($i= 1,2,3,\dots$).

Apesar da simplicidade do modelo aconselha-se o uso do mesmo apenas para demandas que apresentem um comportamento estável.

4.4.2.2 Modelos de suavização exponencial

De acordo com Lustosa et al. (2008), diferentemente dos modelos de médias móveis onde os valores possuem o mesmo peso, os modelos de suavização exponencial utilizam-se uma média ponderada entre os valores, sendo que os

valores mais recentes recebem um maior peso.

A seguir, serão abordados os três tipos de modelos de suavização exponencial: o modelo de suavização exponencial simples; o modelo de suavização exponencial de Holt e o modelo de suavização exponencial de Holt-Winters.

A suavização exponencial simples para Lustosa et al. (2008), é aquela em que a demanda varia em torno de uma base constante. Conforme são incorporados novos dados a demanda base é corrigida.

A Equação (9) define segundo Corrêa e Corrêa (2012), a fórmula básica da suavização exponencial.

$$B_t = \alpha D_t + (1 - \alpha) B_{t-1} \quad (9)$$

onde:

α = é a constante de suavização;

D_t = a demanda do período atual;

$(1 - \alpha)$ = taxa exponencial dos pesos de ponderação dos dados;

B_{t-1} = última previsão.

O valor de α determina equilíbrio entre a sensibilidade das previsões às mudanças na demanda e a estabilidade das previsões. Quanto mais próximo de α estiver de zero, tanto mais as previsões serão amortecidas pelas previsões anteriores (não muito sensíveis, mas mais estáveis) (SLACK, CHAMBERS E JOHNSTON, 2009, p. 178).

De acordo com Tubino (2009), as previsões baseadas em suavização exponencial simples são indicadas para casos onde a demanda é média ou casos onde há pequenos movimentos de tendência. Apesar de sua operação ser de fácil entendimento, fornece apenas previsões para um tempo seguinte, sendo que para tempos futuros utiliza o mesmo valor, assumindo assim uma hipótese de permanência.

No caso da demanda apresentar uma tendência, ou seja, um crescimento ou decrescimento, o modelo de suavização simples demorará a responder essa tendência, fazendo com que a previsão não corresponda com a realidade dos dados.

Em resposta a necessidade de se apresentar uma previsão que corresponda aos fatos, o modelo de suavização exponencial de Holt é um método de previsão de demanda para séries temporais que apresentam a presença de tendência. Hyndman e Athanasopoulos (2013), explicam que em 1957 Holt ampliou o modelo de suavização simples para que o mesmo pudesse ser usado em dados com tendência.

De acordo com Lustosa et al. (2008), adicionou-se ao modelo de suavização exponencial simples uma outra variável que explica o crescimento da demanda de um período para outro. O modelo é expresso pela Equação (10), Equação (11) e Equação (12):

$$F_t(t+k) = B_t + T_t \quad k = 1, 2, \dots \quad (10)$$

$$B_t = \alpha D_t + (1 - \alpha) \cdot (B_{t-1} + T_{t-1}) \quad (11)$$

$$T_t = \beta (B_t + B_{t-1}) + (1 - \beta) \cdot T_{t-1} \quad (12)$$

onde:

α = é a constante de suavização para Base;

D_t = a demanda do período t ;

B_t = base ao final do instante t ;

T_t = tendência ao final do instante t ;

β = constante de suavização para tendência;

$F_t(u)$ = previsão ao final do período t para o período u ($u > t$).

Assim como no método de suavização exponencial simples, é preciso estabelecer os valores das constantes de suavização. Neste sentido de acordo com Tubino (2009), os coeficientes variam de 0 a 1, sendo que quanto maior for o coeficiente mais rápido as previsões evidenciarão as novas tendências, porém quanto menor forem os valores dos coeficientes, menor será a influencia de valores inesperados.

O modelo de suavização exponencial de Holt Winters é uma extensão do modelo de Holt, sendo um método de previsão de demanda para dados que apresentem além de tendência a presença de sazonalidade.

“A sazonalidade caracteriza-se pela ocorrência de variações, para cima e para baixo, a intervalos regulares nas séries temporais da demanda. O período dessa ocorrência pode ser anual, mensal, semanal e até diário” (TUBINO, 2009, p.26).

Este método envolve além da equação vista no modelo de Holt, tendência (T_t) e nível (B_t) uma equação para o componente sazonal (S_t). Além dos componentes de suavização α , β e γ . Lustosa et al. (2008), ressaltam que tal modelo necessita de uma quantidade maior de dados, ou seja, uma série mais longa, ao qual tenha pelo menos três ciclos sazonais completos.

De acordo com Hyndman e Athanasopoulos (2013), os modelos de suavização exponencial de Holt Winters se dividem em dois grupos: aditivo e

multiplicativo. Esses dois grupos se diferem na natureza do componente sazonal, no modelo aditivo a variação da componente sazonal é constante ao longo da série, já o modelo multiplicativo as variações sazonais estão mudando conforme a série muda.

As Equações 13 à 15 juntamente com a equação 12 vista anteriormente, expressam o modelo multiplicativo segundo Lustosa et al. (2008).

$$F_t(t+k) = (B_t + kT_t) \cdot S_{t-L+k} \quad k = 1, 2 \dots \quad (13)$$

$$B_t = \alpha \cdot \left(\frac{D_t}{S_{t-L}} \right) + (1 - \alpha) \cdot (B_{t-1} + T_{t-1}) \quad (14)$$

$$S_t = \gamma \cdot \left(\frac{D_t}{B_t} \right) + (1 - \gamma) \cdot S_{t-L} \quad (15)$$

Para o modelo aditivo as equações que representam previsão e tendência serão as mesmas utilizadas anteriormente na Equação 12 e 13, já para base e sazonalidade serão descritas nas equações 16 e 17 de acordo com Albuquerque e Serra (2006).

$$B_t = \alpha (D_t - S_{t-L}) + (1 - \alpha) \cdot (B_{t-1} + T_{t-1}) \quad (16)$$

$$S_t = \gamma (D_t - B_t) + (1 - \gamma) S_{t-L} \quad (17)$$

onde:

α = constante de suavização para base;

β = constante de suavização para tendência;

γ = constante de suavização para sazonalidade;

D_t = a demanda do período t ;

B_t = base ao final do instante t ;

T_t = tendência ao final do instante t ;

S_t = índice de sazonalidade no instante t ;

L = número de variações sazonais em uma unidade de tempo;

$F_t(u)$ = previsão ao final do período t para o período u ($u > t$).

Fernandes e Filho (2010) observam que as mesmas considerações feitas para as constantes α e β , são validas para a constante γ , quanto maior for o valor de γ , maior será o poder de resposta do mesmo em relação a mudanças. Sendo

recomendável para este método y entre 0,1 e 0,3.

Na Quadro 4, Hyndman e Athanasopoulos (2013), apresentam as equações recorrentes para todos os possíveis métodos de suavização exponencial de acordo com a correção de erro aditivo ou multiplicativo, as equações apresentadas para cada método são de alisamento indicadas por l_t , b_t e s_t e de previsão para h previsões indicadas por y_t .

ADDITIVE ERROR MODELS

Trend	Seasonal		
	N	A	M
N	$y_t = l_{t-1} + \varepsilon_t$ $l_t = l_{t-1} + \alpha\varepsilon_t$	$y_t = l_{t-1} + s_{t-m} + \varepsilon_t$ $l_t = l_{t-1} + \alpha\varepsilon_t$ $s_t = s_{t-m} + \gamma\varepsilon_t$	$y_t = l_{t-1}s_{t-m} + \varepsilon_t$ $l_t = l_{t-1} + \alpha\varepsilon_t/s_{t-m}$ $s_t = s_{t-m} + \gamma\varepsilon_t/l_{t-1}$
A	$y_t = l_{t-1} + b_{t-1} + \varepsilon_t$ $l_t = l_{t-1} + b_{t-1} + \alpha\varepsilon_t$ $b_t = b_{t-1} + \beta\varepsilon_t$	$y_t = l_{t-1} + b_{t-1} + s_{t-m} + \varepsilon_t$ $l_t = l_{t-1} + b_{t-1} + \alpha\varepsilon_t$ $b_t = b_{t-1} + \beta\varepsilon_t$ $s_t = s_{t-m} + \gamma\varepsilon_t$	$y_t = (l_{t-1} + b_{t-1})s_{t-m} + \varepsilon_t$ $l_t = l_{t-1} + b_{t-1} + \alpha\varepsilon_t/s_{t-m}$ $b_t = b_{t-1} + \beta\varepsilon_t/s_{t-m}$ $s_t = s_{t-m} + \gamma\varepsilon_t/(l_{t-1} + b_{t-1})$
A _d	$y_t = l_{t-1} + \phi b_{t-1} + \varepsilon_t$ $l_t = l_{t-1} + \phi b_{t-1} + \alpha\varepsilon_t$ $b_t = \phi b_{t-1} + \beta\varepsilon_t$	$y_t = l_{t-1} + \phi b_{t-1} + s_{t-m} + \varepsilon_t$ $l_t = l_{t-1} + \phi b_{t-1} + \alpha\varepsilon_t$ $b_t = \phi b_{t-1} + \beta\varepsilon_t$ $s_t = s_{t-m} + \gamma\varepsilon_t$	$y_t = (l_{t-1} + \phi b_{t-1})s_{t-m} + \varepsilon_t$ $l_t = l_{t-1} + \phi b_{t-1} + \alpha\varepsilon_t/s_{t-m}$ $b_t = \phi b_{t-1} + \beta\varepsilon_t/s_{t-m}$ $s_t = s_{t-m} + \gamma\varepsilon_t/(l_{t-1} + \phi b_{t-1})$
M	$y_t = l_{t-1}b_{t-1} + \varepsilon_t$ $l_t = l_{t-1}b_{t-1} + \alpha\varepsilon_t$ $b_t = b_{t-1} + \beta\varepsilon_t/l_{t-1}$	$y_t = l_{t-1}b_{t-1} + s_{t-m} + \varepsilon_t$ $l_t = l_{t-1}b_{t-1} + \alpha\varepsilon_t$ $b_t = b_{t-1} + \beta\varepsilon_t/l_{t-1}$ $s_t = s_{t-m} + \gamma\varepsilon_t$	$y_t = l_{t-1}b_{t-1}s_{t-m} + \varepsilon_t$ $l_t = l_{t-1}b_{t-1} + \alpha\varepsilon_t/s_{t-m}$ $b_t = b_{t-1} + \beta\varepsilon_t/(s_{t-m}l_{t-1})$ $s_t = s_{t-m} + \gamma\varepsilon_t/(l_{t-1}b_{t-1})$
M _d	$y_t = l_{t-1}b_{t-1}^\phi + \varepsilon_t$ $l_t = l_{t-1}b_{t-1}^\phi + \alpha\varepsilon_t$ $b_t = b_{t-1}^\phi + \beta\varepsilon_t/l_{t-1}$	$y_t = l_{t-1}b_{t-1}^\phi + s_{t-m} + \varepsilon_t$ $l_t = l_{t-1}b_{t-1}^\phi + \alpha\varepsilon_t$ $b_t = b_{t-1}^\phi + \beta\varepsilon_t/l_{t-1}$ $s_t = s_{t-m} + \gamma\varepsilon_t$	$y_t = l_{t-1}b_{t-1}^\phi s_{t-m} + \varepsilon_t$ $l_t = l_{t-1}b_{t-1}^\phi + \alpha\varepsilon_t/s_{t-m}$ $b_t = b_{t-1}^\phi + \beta\varepsilon_t/(s_{t-m}l_{t-1})$ $s_t = s_{t-m} + \gamma\varepsilon_t/(l_{t-1}b_{t-1}^\phi)$

MULTIPLICATIVE ERROR MODELS

Trend	Seasonal		
	N	A	M
N	$y_t = l_{t-1}(1 + \varepsilon_t)$ $l_t = l_{t-1}(1 + \alpha\varepsilon_t)$	$y_t = (l_{t-1} + s_{t-m})(1 + \varepsilon_t)$ $l_t = l_{t-1} + \alpha(l_{t-1} + s_{t-m})\varepsilon_t$ $s_t = s_{t-m} + \gamma(l_{t-1} + s_{t-m})\varepsilon_t$	$y_t = l_{t-1}s_{t-m}(1 + \varepsilon_t)$ $l_t = l_{t-1}(1 + \alpha\varepsilon_t)$ $s_t = s_{t-m}(1 + \gamma\varepsilon_t)$
A	$y_t = (l_{t-1} + b_{t-1})(1 + \varepsilon_t)$ $l_t = (l_{t-1} + b_{t-1})(1 + \alpha\varepsilon_t)$ $b_t = b_{t-1} + \beta(l_{t-1} + b_{t-1})\varepsilon_t$	$y_t = (l_{t-1} + b_{t-1} + s_{t-m})(1 + \varepsilon_t)$ $l_t = l_{t-1} + b_{t-1} + \alpha(l_{t-1} + b_{t-1} + s_{t-m})\varepsilon_t$ $b_t = b_{t-1} + \beta(l_{t-1} + b_{t-1} + s_{t-m})\varepsilon_t$ $s_t = s_{t-m} + \gamma(l_{t-1} + b_{t-1} + s_{t-m})\varepsilon_t$	$y_t = (l_{t-1} + b_{t-1})s_{t-m}(1 + \varepsilon_t)$ $l_t = (l_{t-1} + b_{t-1})(1 + \alpha\varepsilon_t)$ $b_t = b_{t-1} + \beta(l_{t-1} + b_{t-1})\varepsilon_t$ $s_t = s_{t-m}(1 + \gamma\varepsilon_t)$
A _d	$y_t = (l_{t-1} + \phi b_{t-1})(1 + \varepsilon_t)$ $l_t = (l_{t-1} + \phi b_{t-1})(1 + \alpha\varepsilon_t)$ $b_t = \phi b_{t-1} + \beta(l_{t-1} + \phi b_{t-1})\varepsilon_t$	$y_t = (l_{t-1} + \phi b_{t-1} + s_{t-m})(1 + \varepsilon_t)$ $l_t = l_{t-1} + \phi b_{t-1} + \alpha(l_{t-1} + \phi b_{t-1} + s_{t-m})\varepsilon_t$ $b_t = \phi b_{t-1} + \beta(l_{t-1} + \phi b_{t-1} + s_{t-m})\varepsilon_t$ $s_t = s_{t-m} + \gamma(l_{t-1} + \phi b_{t-1} + s_{t-m})\varepsilon_t$	$y_t = (l_{t-1} + \phi b_{t-1})s_{t-m}(1 + \varepsilon_t)$ $l_t = (l_{t-1} + \phi b_{t-1})(1 + \alpha\varepsilon_t)$ $b_t = \phi b_{t-1} + \beta(l_{t-1} + \phi b_{t-1})\varepsilon_t$ $s_t = s_{t-m}(1 + \gamma\varepsilon_t)$
M	$y_t = l_{t-1}b_{t-1}(1 + \varepsilon_t)$ $l_t = l_{t-1}b_{t-1}(1 + \alpha\varepsilon_t)$ $b_t = b_{t-1}(1 + \beta\varepsilon_t)$	$y_t = (l_{t-1}b_{t-1} + s_{t-m})(1 + \varepsilon_t)$ $l_t = l_{t-1}b_{t-1} + \alpha(l_{t-1}b_{t-1} + s_{t-m})\varepsilon_t$ $b_t = b_{t-1} + \beta(l_{t-1}b_{t-1} + s_{t-m})\varepsilon_t/l_{t-1}$ $s_t = s_{t-m} + \gamma(l_{t-1}b_{t-1} + s_{t-m})\varepsilon_t$	$y_t = l_{t-1}b_{t-1}s_{t-m}(1 + \varepsilon_t)$ $l_t = l_{t-1}b_{t-1}(1 + \alpha\varepsilon_t)$ $b_t = b_{t-1}(1 + \beta\varepsilon_t)$ $s_t = s_{t-m}(1 + \gamma\varepsilon_t)$
M _d	$y_t = l_{t-1}b_{t-1}^\phi(1 + \varepsilon_t)$ $l_t = l_{t-1}b_{t-1}^\phi(1 + \alpha\varepsilon_t)$ $b_t = b_{t-1}^\phi(1 + \beta\varepsilon_t)$	$y_t = (l_{t-1}b_{t-1}^\phi + s_{t-m})(1 + \varepsilon_t)$ $l_t = l_{t-1}b_{t-1}^\phi + \alpha(l_{t-1}b_{t-1}^\phi + s_{t-m})\varepsilon_t$ $b_t = b_{t-1}^\phi + \beta(l_{t-1}b_{t-1}^\phi + s_{t-m})\varepsilon_t/l_{t-1}$ $s_t = s_{t-m} + \gamma(l_{t-1}b_{t-1}^\phi + s_{t-m})\varepsilon_t$	$y_t = l_{t-1}b_{t-1}^\phi s_{t-m}(1 + \varepsilon_t)$ $l_t = l_{t-1}b_{t-1}^\phi(1 + \alpha\varepsilon_t)$ $b_t = b_{t-1}^\phi(1 + \beta\varepsilon_t)$ $s_t = s_{t-m}(1 + \gamma\varepsilon_t)$

Quadro 4 - Equações dos métodos utilizados nas previsões de suavização exponencial na forma de correção de erro.

Fonte: Hyndman e Athanasopoulos (2013)

3.6 MEDIDA E CONTROLE DO ERRO

Uma questão importante que deve ser levada em conta no processo de previsão de demanda é a viabilidade dos resultados obtidos, ou seja, a precisão dos resultados. Uma forma de analisar a precisão dos resultados é medindo matematicamente o quanto o modelo se aproxima da realidade, quão mais próximo da realidade estiver o modelo, menor será a diferença ou erro encontrado entre demanda real e demanda prevista.

As medidas dos erros de acordo com Fernandes e Filho (2010) são parâmetros utilizados no monitoramento do modelo. Podendo ser matematicamente expresso pela diferença entre a demanda real em um determinado período e a previsão para esse mesmo período, conforme Equação (18).

$$E_t = D_t - F_t \quad (18)$$

Segundo Tubino (2009), o monitoramento do modelo através do cálculo do erro da previsão visa: verificar a precisão dos valores previstos, reconhecer, separar e corrigir variações irregulares além de auxiliar na escolha do modelo de previsão mais eficiente.

Fernandes e Filho (2010) apontam dois tipos de erro existentes nas previsões: erros de ruído e erros de viés. Os erros de ruído são resultado de fatores imprevisíveis referentes ao mercado, já os erros de viés consistem em erros do método de previsão escolhido resultando em enganos consistentes.

A amplitude dos erros de previsão pode ser monitorada por meio de diversas técnicas. Neste tópico serão apresentadas algumas dessas técnicas.

“Para todos os métodos das médias, inclusive após submissão a correções, como no caso do efeito de tendência, as medidas mais comuns de erro são o MAD (Desvio Absoluto Médio) e o MSE (erro médio quadrático)” (MOREIRA, 2011, p.318).

O MAD (*Mean Absolute Deviation*) é uma técnica que calcula o desvio (erros) absoluto médio entre a demanda prevista e a demanda real. Tubino (2009), mostra que normalmente os limites inferiores e superiores de um gráfico de Controle Estatístico de Processo (CEP) correspondem ao desvio absoluto médio (MAD). E pode ser representado pela Equação (19):

$$MAD = \frac{\sum |D_{\text{atual}} - D_{\text{prevista}}|}{n} \quad (19)$$

O MSE (*Mean Squared Error*) é uma técnica que utiliza o quadrado do erro da previsão. De acordo com Moreira (2011), essa técnica evita que os erros se anulem, tendo um papel de controlar o desempenho das médias como preditor. O erro médio quadrático pode ser representado pela Equação (20):

$$MSE = \frac{\sum (Y - D)^2}{n - 1} \quad (20)$$

Os erros percentuais conforme Hyndman e Athanasopoulos (2013), possuem a vantagem de ter uma escala independente, sendo frequentemente usados na comparação de diferentes conjuntos de dados. Dentre as medidas de erros percentuais a mais utilizada é a MAPE.

Para Lustosa et al. (2008), a MAPE (*Mean Absolute Percentage Error*) ou EPAM (Erro Percentual Absoluto Médio) é uma técnica que considera os desvios percentuais absolutos médios no cálculo do erro. Sendo representada pela Equação (21):

$$EPAM = \frac{\sum_{t=1}^n \left| \frac{Dt - Ft}{Dt} \right|}{n} \quad (21)$$

O método U de Theil é de grande importância para indicar a proximidade do modelo a realidade. De acordo com Bitencurt et al. (2005), o coeficiente U de Theil é uma métrica que avalia capacidade de precisão do modelo, e pode ser expressado pelo Equação 22:

$$U = \frac{\sqrt{\sum_{k=1}^N (a_k - y_k)^2}}{\sqrt{\sum_{k=1}^N (a_k - a_{k-1})^2}} \quad (22)$$

onde:

a_k = saída desejada;

y_k = previsão obtida.

Segundo Makridakis, Wheelwright e Hyndman (1998 apud MILNITZ; MARCHI; SAMOHYL, 2011, p.5), quanto mais próximo de zero estiver esse índice melhor será a acuracidade do modelo.

Outro critério de informação muito usado para comprar os modelos

ajustados aos dados reais é o Akaike (AIC), um procedimento de estimação de máxima verossimilhança.

De acordo com Akaike (1974), $AIC = (-2) \log(\text{risco máximo}) + 2$ (número de parâmetros ajustados de forma independente ao modelo), sendo definido pela equação 23:

$$AIC = -2 \log L(\hat{\theta}) + 2(p) \quad (23)$$

Além dessas medidas de erro apresentadas outro parâmetro utilizado para avaliar o ajuste do modelo á serie temporal é o coeficiente de determinação R^2 . “Basicamente, este coeficiente indica quanto o modelo foi capaz de explicar os dados coletados” (PORTAL ACTION, 2016). Este coeficiente é dado pela Equação 24.

$$R^2 = 1 - \frac{\sum_{t=1}^n (x_t - \hat{x}_t)^2}{\sum_{t=1}^n (x_t - \bar{x})^2} \quad (24)$$

R^2 varia de 0 á 1, o que indica que quanto mais próximo r^2 estiver de 0 pior será o modelo de ajuste por outro lado quanto mais próximo estiver de 1 melhor será o ajuste.

“Às vezes, diferentes medidas de precisão irão levar a resultados diferentes a respeito de qual método de previsão é melhor.” (HYNDMAN e ATHANASOPOULOS, 2013).

4 MATERIAIS E MÉTODOS

Neste capítulo será apresentado uma breve descrição da empresa em estudo, bem como as técnicas de pesquisa adotadas para a elaboração deste trabalho.

4.1 A EMPRESA

A empresa objeto de estudo é uma indústria do ramo alimentício localizada no oeste do Paraná, iniciou suas atividades no ramo alimentício no ano de 1970 e desde então não parou de crescer. A capacidade produtiva da indústria gira em torno de 240 toneladas diárias de alimentos.

Preocupada com a satisfação de seus consumidores, a empresa investe em tecnologias, a fim de oferecer aos seus clientes produtos alimentícios de qualidade. Ela desenvolve o programa 5s e Boas Práticas de Fabricação, além de contar com uma estrutura capaz de atender pequenas e grandes empresas. Conta com um quadro de funcionários de 680 pessoas sendo considerada de acordo Sebrae (2015), como uma indústria de grande porte.

Os produtos comercializados pela empresa podem ser encontrados em 16 estados brasileiros e em dois países do Mercosul.

4.2 CLASSIFICAÇÃO DA PESQUISA

São vários os conceitos em relação ao que é uma pesquisa, no entanto em todos eles pode-se perceber a relevância que a pesquisa tem na busca pelo saber, especialmente no estudo dos aspectos sociais do homem onde visa à solução de problemas coletivos.

Marconi e Lakatos (2010, p. 139), definem a pesquisa como “um procedimento formal, com método de pensamento reflexivo, que requer um

tratamento científico e se constitui no caminho para conhecer a realidade ou para descobrir verdades parciais”.

Neste sentido, de acordo com Bello (2012), a pesquisa científica busca soluções para problemas que exigem respostas. Para o autor a pesquisa é o caminho que leva ao conhecimento, pois através dela diferentes instrumentos são utilizados para se chegar à exatidão da resposta.

Para chegar às respostas desejadas em relação a este trabalho é necessário o planejamento dos instrumentos e procedimentos no qual se baseará esta pesquisa.

Para Kauark, Manhães e Medeiros (2010), a pesquisa pode ser classificada de várias formas, levando em conta a natureza da pesquisa, o objetivo da pesquisa, a forma de abordagem do assunto e os procedimentos usados para chegar ao resultado. A Figura 8 ilustra as formas de se classificar uma pesquisa.

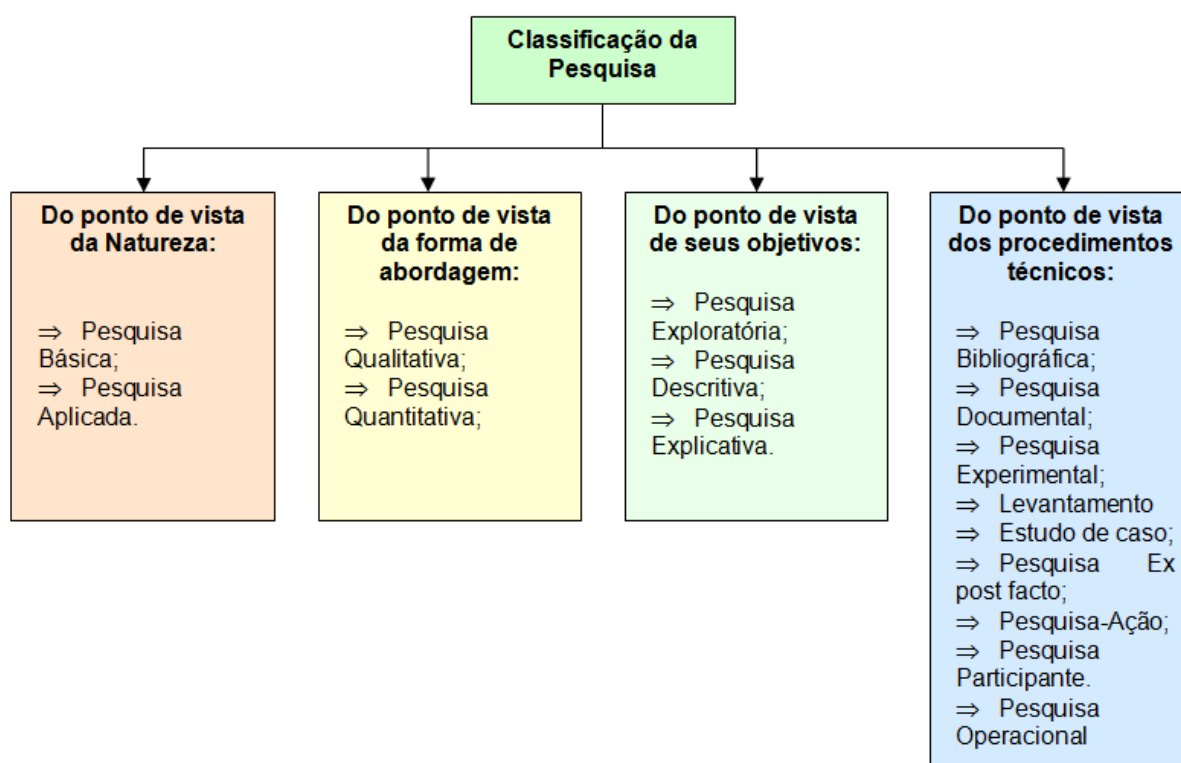


Figura 8 - Classificação da Pesquisa

Fonte: Adaptado de Kauark, Manhães e Medeiros (2010) e Cardoso (2010).

Para Gil (2008), a principal característica da pesquisa aplicada é o interesse em sua aplicação.

Outra característica desse tipo de pesquisa citado por Danton (2002), é a

busca por respostas de problemas concretos e imediatos.

Desta forma do ponto de vista da natureza esta pesquisa é classificada como uma pesquisa aplicada, pois buscou prever a demanda (solução do problema proposto) dos produtos, através da aplicação do modelo que mais se ajustou às demandas reais, servindo como uma importante ferramenta do planejamento da empresa. Se enquadrando, portanto na definição de Gil (2008) e Danton (2015) que descreve esse tipo de pesquisa como um estudo de assuntos que envolvam interesses locais.

Uma pesquisa quantitativa “considera o que pode ser quantificável, o que significa traduzir em números opiniões e informações para classificá-las e analisá-las” (KAUARK; MANHÃES e MEDEIROS, 2010, p.26).

Inicialmente foi realizado um estudo de relevância em termos de vendas e lucros de todos os produtos fabricados pela empresa em estudo, realizando ao final a escolha de dois produtos que mais agreguem valor para empresa, para a escolha desses produtos optou-se por uma análise de representatividade obtida por meio da curva ABC dos produtos. Depois de selecionados os produtos foi realizado uma análise de previsão da demanda por meio de métodos estatísticos baseada na análise dos dados históricos de 5 anos do produto, ou seja, em dados que podem ser quantificáveis, se caracterizando quanto ao ponto de vista da forma de abordagem como uma pesquisa quantitativa.

Do ponto de vista de seus objetivos, essa pesquisa se caracteriza como descritiva, pois de acordo com Gil (2008), uma pesquisa descritiva tem como principal objetivo a descrição da população, a descrição de um fenômeno ou ainda a descrição das relações entre as variáveis. Sendo as técnicas padronizadas de coleta de dados uma das características mais importante desse tipo de pesquisa.

Quanto aos procedimentos técnicos esta pesquisa se classifica como uma pesquisa bibliográfica, pois inicialmente realizou-se um estudo bibliográfico sobre a previsão de demanda com o intuito de analisar os métodos de previsão e a aplicação de cada um deles e cabe destacar que “A pesquisa bibliográfica deve anteceder todos os tipos de pesquisas” (DANTON, 2002, p. 10).

Realizado o estudo bibliográfico a pesquisa explorou as fontes documentais necessárias, ou seja, realizou-se uma a coleta de dados junto ao sistema da empresa, os dados coletados passaram por um tratamento analítico. Desta forma, ainda quanto aos procedimentos técnicos se caracteriza como uma pesquisa

documental, pois segundo Kauark, Manhães e Medeiros (2010), uma pesquisa documental é elaborada a partir de dados que não receberam tratamento analítico. Gil (2008) complementa explicando que o primeiro passo é a busca por dados documentais em grande número.

Após a análise dos dados foi escolhido o modelo, esta escolha levou em conta a análise dos resultados alcançados, ou seja, o modelo que obteve a maior eficácia de previsão e que melhor se ajustou a demanda. Desta maneira, o modelo utilizou técnicas estatísticas.

As técnicas estatísticas utilizadas neste trabalho preveem a demanda por meio de modelos matemáticos, esses modelos buscam resultados que traduzam a realidade a fim de fornecer soluções à tomada de decisão. Desta forma, ainda quanto aos procedimentos técnicos a pesquisa se classifica como uma pesquisa operacional.

Cardoso (2001), explica que a pesquisa operacional busca por meio de modelos matemáticos apresentarem soluções de problemas relacionados à tomadas de decisões. Sendo a análise estatística um dos ramos mais importantes desenvolvidos por esse tipo de pesquisa.

Na Figura 9, pode-se visualizar as etapas para a resolução de um problema em um estudo de pesquisa operacional.

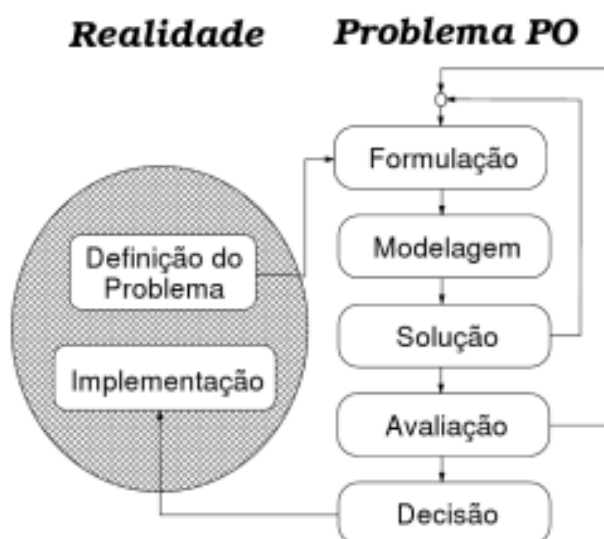


Figura 9 - Etapas da resolução de problema em PO
Fonte: Cardoso (2010).

4.3 COLETA DE DADOS

As informações coletados para a elaboração deste trabalho são dados históricos dos produtos, tais dados foram coletados por meio do sistema de informação utilizado pela empresa em forma de planilhas eletrônicas.

O conjunto de dados coletados corresponde a venda e lucratividade mensal ao longo de 5 anos, num período que compreende setembro de 2010 a setembro de 2015, de aproximadamente 168 produtos oferecidos pela empresa. Para atender ao pedido da empresa em relação à privacidade e sigilo de suas informações, os dados coletados foram divididos por uma constante.

4.4 ANÁLISE DE DADOS

Após a coleta os dados foram organizados para a realização de todas as análises necessárias. Primeiramente organizou-se os dados separando dentre os 168 produtos, aqueles que possuíam um histórico de venda maior que 5 anos. Nesse primeiro tratamento foram selecionados 30 produtos.

Os dados relativos à venda e a lucratividade dos produtos escolhidos, foram submetidos a uma análise de relevância financeira para empresa por meio da construção de uma curva ABC. Através dos resultados obtidos com a curva ABC, pode-se identificar e selecionar os produtos de maior representatividade.

Com a escolha dos produtos realizou-se uma análise estatística dos produtos utilizando-se dois *softwares*, Gretl e Nnq-estatística.

Os resultados da análise descritiva dos dados foram obtidos através da utilização do pacote econométrico Gretl v1.6.5, o mesmo buscou explicar o comportamento do conjunto de dados. De acordo com Adkins (2007), o Gretl é um acrônimo para expressar as palavras GNU, regressão, econometria e series temporais. É um software gratuito, de fácil uso e razoavelmente poderoso, que possui funções estatísticas e econométricas para a análise de regressão e séries temporais.

Tanto para a escolha do modelo como para as previsões individuais utilizou-

se o *software* Nnq-statística, onde de acordo com a presença de nível, tendência e sazonalidade, *software* o gerou e testou os possíveis métodos de suavização exponencial. O Nnq-statística é um software gratuito implementado como suplemento (*Add-in*) do Excel, disponibilizado e desenvolvido pelo Núcleo de Normalização e Qualimetria do Departamento de Engenharia de Produção e Sistemas da Universidade Federal de Santa Catarina (UFSC).

Os modelos de suavização utilizados pelo Nnq-statística são: ANA, MNA, AAA, MAA, AAdA, MAdA, MNM, MAM, MAdM, MMM, MMdM. A primeira letra representa a correção de erro utilizada, a segunda a presença e o tipo de tendência, e a última o tipo de sazonalidade, para a compreensão dessas siglas elaborou-se o Quadro 5.

MODELOS DE SUAVIZAÇÃO	CORREÇÃO DE ERRO	TENDÊNCIA	SAZONALIDADE
ANA	aditiva	não existe	aditiva
MNA	multiplicativa	não existe	aditiva
AAA	aditiva	aditiva	aditiva
MAA	multiplicativa	aditiva	aditiva
AAdA	aditiva	aditiva amortecida	aditiva
MAdA	multiplicativa	aditiva amortecida	aditiva
MNM	multiplicativa	não existe	multiplicativa
MAM	multiplicativa	aditiva	multiplicativa
MAdM	multiplicativa	aditiva amortecida	multiplicativa
MMM	multiplicativa	multiplicativa	multiplicativa
MMdM	multiplicativa	multiplicativa amortecida	multiplicativa

Quadro 5 - Modelos de suavização Nnq-statística
Fonte: Autora (2016).

Os tipos de erros abordados pelo *software* foram descritos na seção 4.6 deste trabalho. No entanto, o Nnq-statística propõe um método de suavização exponencial que mais se aproxime ao conjunto de dados, levando em conta a minimização do erro amostral medido pelo AIC.

5 RESULTADOS E DISCUSSÃO

Neste capítulo serão apresentados os resultados obtidos com a análise dos dados históricos dos produtos da empresa em estudo. Primeiramente, será apresentado o resultado obtido com a aplicação da curva ABC, também será apresentada uma estatística descritiva dos dados e posteriormente será abordado a escolha do modelo e previsão para os próximos 12 meses.

5.1 CURVA ABC

A fim de definir os produtos mais representativos na produção e comercialização da empresa, construiu-se a curva ABC, identificando-se os produtos mais relevantes em relação ao valor de venda.

Os produtos selecionados para análise da curva ABC foram os que possuíam histórico de venda superior a 5 anos considerando o período de setembro de 2010 a setembro de 2015. Na Tabela 1, todos os produtos selecionados são apresentados com seu valor total embasado no valor unitário.

Tabela 1 – A Quantidade vendida, o valor unitário e o valor total dos produtos comercializados pela empresa em estudo

(continua)

PRODUTO	QUANTIDADE VENDIDA	VALOR UNITÁRIO	VALOR TOTAL DO PRODUTO	VALOR TOTAL EM %
1010	940,24603	R\$ 5,77	R\$ 5.424,56	1,224%
1020	2576,09492	R\$ 5,43	R\$ 13.999,73	3,159%
1030	6721,901141	R\$ 5,26	R\$ 35.383,38	7,983%
1040	7071,14054	R\$ 4,41	R\$ 31.170,37	7,033%
1050	8865,27659	R\$ 4,22	R\$ 37.422,88	8,443%
1060	5338,858257	R\$ 4,39	R\$ 23.441,86	5,289%
1070	8970,944432	R\$ 4,36	R\$ 39.157,31	8,835%
1080	9872,938322	R\$ 4,28	R\$ 42.247,41	9,532%
1090	5684,617965	R\$ 4,36	R\$ 24.774,00	5,589%
1100	494,854523	R\$ 9,40	R\$ 4.649,78	1,049%
1110	616,2448	R\$ 9,52	R\$ 5.869,24	1,324%
1120	354,784425	R\$ 10,39	R\$ 3.686,70	0,832%
1130	376,43865	R\$ 9,03	R\$ 3.400,56	0,767%

Tabela 1 - A Quantidade vendida, o valor unitário e o valor total dos produtos comercializados pela empresa em estudo

(conclusão)

PRODUTO	QUANTIDADE VENDIDA	VALOR UNITÁRIO	VALOR TOTAL DO PRODUTO	VALOR TOTAL EM %
1140	373,7309	R\$ 9,40	R\$ 3.512,74	0,793%
50	223,4547	R\$ 11,27	R\$ 2.517,31	0,568%
1160	295,8288	R\$ 10,23	R\$ 3.025,85	0,683%
1170	10902,43058	R\$ 2,64	R\$ 28.771,06	6,491%
1180	16149,18682	R\$ 2,24	R\$ 36.240,52	8,176%
1190	756,937195	R\$ 4,57	R\$ 3.456,88	0,780%
1200	2450,734513	R\$ 4,45	R\$ 10.895,59	2,458%
1210	2832,84245	R\$ 4,49	R\$ 12.713,70	2,868%
1220	2420,288245	R\$ 4,43	R\$ 10.713,24	2,417%
1230	552,020855	R\$ 4,60	R\$ 2.541,98	0,574%
1240	1363,716	R\$ 2,71	R\$ 3.695,25	0,834%
1250	1092,13248	R\$ 2,40	R\$ 2.615,92	0,590%
1260	2567,56968	R\$ 2,69	R\$ 6.916,49	1,560%
1270	5863,8456	R\$ 2,65	R\$ 15.524,59	3,503%
1280	8599,22636	R\$ 2,20	R\$ 18.911,64	4,267%
1290	1843,32	R\$ 2,69	R\$ 4.960,19	1,119%
1300	2406,9114	R\$ 2,32	R\$ 5.588,46	1,261%
TOTAL	118578,5172		R\$ 443.229,19	100,000%

A partir dos dados foi gerada a classificação ABC dos produtos, ilustrado no gráfico da Figura 10. A porcentagem da taxa de corte foi de 80% para os produtos de classe A, 15% para os produtos de classe B e 5% para os produtos de classe C.




Figura 10 - Curva ABC
Fonte: Autoria própria.

Através dos dados obtidos pela curva ABC, percebe-se que os produtos da classe A representam 78,3% do valor total de venda nesse período, os de classe B, 15,7% e os de classe C, 6%.

Notou-se ainda a representatividade dos produtos: 1080 e 1070. Esses 2 produtos juntos representam 6,67% do total de produtos analisados e 18,37% do total faturado pela indústria nesse período.

Por estes motivos e pela falta de tempo hábil para a realização da análise de todos os produtos da empresa será realizado um estudo de previsão de demanda apenas desses dois produtos.

5.2 ANÁLISE ESTATÍSTICA PARA O PRODUTO 1080.

O produto 1080 representa cerca de 9,53% do total faturado pela empresa, um valor relativamente alto levando em conta que o mesmo representa apenas 3,33% dos produtos analisados. Por esta razão necessita de uma maior importância na sua gestão de estoque e produção.

5.2.1 Análise Descritiva das Vendas

Buscou-se através da análise exploratória agrupar o conjunto de dados do produto 1080, de modo a retirar as informações importantes para a análise estatística.

De acordo com Reis e Reis (2002), a análise descritiva além de organizar, resumir e descrever as informações relevantes de um conjunto de dados observados, também identifica as falhas, que podem ser de dois tipos: registros incorretos de valores, e de dados discrepantes.

Na estatística descritiva o conjunto de dados possui três características principais: Medidas de tendência central, Medidas de dispersão e Forma de distribuição dos dados.

O conjunto de dados escolhidos para análise foi a quantidade mensal

vendida pela empresa do produto 1080 em peso, expresso na Tabela 2.

Tabela 2 - Quantidade mensal vendida do produto 1080

MÊS	ANO					
	2010	2011	2012	2013	2014	2015
Janeiro		106,86704	110,03332	116,48408	102,1074	115,9766
Fevereiro		131,86496	131,18304	164,56816	177,0664	124,5954
Março		153,87488	162,19568	174,2812	140,0426	217,3384
Abril		164,21152	154,3008	169,4962	167,5374	176,9272
Mai		161,4344	186,34864	161,15084	212,5504	208,3634
Junho		144,21216	184,37424	179,35572	144,6944	208,8776
Julho		174,73392	145,08672	181,78032	195,5992	199,3232
Agosto		170,77808	159,60192	184,6312	239,0114	232,0166
Setembro	143,43024	160,06336	141,91184	200,23831	181,7708	183,83334
Outubro	131,67888	153,76616	140,93104	138,63	206,0328	
Novembro	139,140352	145,18816	131,55056	167,7948	210,0572	
Dezembro	99,93504	130,00352	135,37648	133,6422	163,0866	

Utilizando os dados coletados de setembro de 2010 à setembro de 2015, realizou-se a uma análise exploratória dos mesmos. Algumas informações pertinentes ao estudo, obtidas com essa análise estão descritas na Tabela 3.

Tabela 3 – Análise Descritiva de Venda

PRODUTO 1080	
Média	161,85
Mediana	161,43
Mínimo	99,935
Máximo	239,01
Desvio Padrão	32,225
C.V	0,19910

Pode-se notar que as medidas de tendência central (média e mediana), ficaram próximas, o que indica que não há valores extremamente grandes ou extremamente pequenos no conjunto de dados observados. Essas medidas traduzem o valor que é típico do conjunto de dados.

As medidas de variabilidade do conjunto de dados quantificam o grau de dispersão encontrados no mesmo. Essas medidas de variabilidade são: amplitude total, desvio padrão e coeficiente de variação. A AT (amplitude total) foi de 139,075 (O valor máximo do conjunto de dados 239,01 - o valor mínimo 99,935). Porém de acordo com Reis e Reis (2002), essa medida é superficial e não consegue expressar o que acontece com todo o conjunto de dados.

Assim os valores de desvio padrão e coeficiente de variação podem expressar melhor a variação que acontece com o conjunto de dados.

O desvio padrão indica a variação dos dados em relação à média, nos dados observados o valor de 32,225 no desvio padrão indica que há uma variabilidade nos dados. De acordo com Andradre (2011), quanto mais próximo de zero estiver o desvio padrão mais homogêneo e concentrado será o conjunto de dados.

Apesar do conjunto de dados apresentarem uma variabilidade, pode-se notar observando o valor do desvio padrão e o valor do coeficiente de variação (C.V.) que essa variabilidade não é alta. O coeficiente de variação “indica qual a proporção da média que o desvio padrão representa” (JOAQUIM, 2015, p. 16)

A fim de avaliar a normalidade do conjunto de dados, alguns testes foram realizados, os resultados obtidos com estes testes estão descritos na Tabela 4.

Tabela 4 - Testes de normalidade

	Teste	p-valor
Doornik-Hansen	0,969265	0,615924
Shapiro-Wilk W	0,984657	0,641739
Lilliefors	0,090895	0,23
Jarque-Bera	1,06769	0,586346

Realizou-se também a representação gráfica do teste de normalidade Doornik-Hansen, conforme se pode observar na Figura 11.




Figura 11 - Histograma sobreposto por curva normal dos dados de venda do produto 1080.
Fonte: Autora própria.

Ao observar a curva normal sobre o histograma e os testes de normalidade realizados ($p\text{-valor} > 5\%$, nível de significância adotado), pode-se notar que o conjunto de dados referentes à quantidade vendida do produto 1080 apresenta uma

distribuição normal.

Outliers são valores no conjunto de dados que se localizam muito distante da média.

Não foram observados a presença de *outliers* no conjunto de dados, conforme pode ser visto através no Box-plot da Figura 12. De acordo com Tukey (1960), a presença de *outliers* pode causar enviesamento na estimativa dos parâmetros necessários á adequação do modelo. De mesmo modo Santiago, Camargo e Margarido (1996), explicam que entre os efeitos causas pela presença de *outliers* na série temporal a mudança no nível e alterações na tendência ganham destaque.




Figura 12 – Box-plot dos dados de venda obtidos mensalmente com o produto 1080.
Fonte: Autoria própria.

5.2.2 Escolha do Método Adequado

Após a análise descritiva feita no tópico anterior realizou-se a plotagem dos dados, com o intuito de identificar os principais métodos que se adequem ao meu conjunto de dados, ou seja, que melhor expressem a serie temporal.

Podemos observar a representação gráfica dos dados de venda obtidos

mensalmente com o produto 1080 na Figura 13.




Figura 13 - Gráfico do dados de venda do produto 1080 referente aos meses de análise
Fonte: Autoria própria.

Um das características identificadas através da análise visual da série temporal na Figura 13 é a presença de tendência e a presença de uma sazonalidade entre os anos observados. Podemos notar uma tendência de crescimento ao longo da série, também podemos notar ciclos de variação na venda do produto, essa variação se mostra constante ao longo do tempo, identificando assim uma forte ciclicidade anual.

A decomposição dos dados mostrando o comportamento sazonal da série pode ser visualizado no gráfico da Figura 14.




Figura 14 - Índices sazonais do conjunto de dados do produto 1080
Fonte: Autoria própria.

Nota-se ao observar a Figura 14, uma significativa queda na venda do produto 1080 nos meses de janeiro, fevereiro e dezembro e picos de aumento de venda entre março e setembro.

Observada as características presentes no conjunto de dados, os métodos escolhidos para a previsão do modelo são os métodos de suavização exponencial. Para a escolha do método adequado dentre os modelos de suavização exponencial utilizou-se o *Software* NNQ-Estatística. O *software* sugere um modelo levando em conta a minimização dos erros amostrais.

Os resultados podem ser visualizados na Tabela 5, onde através da análise dos erros compara os métodos de suavização exponencial que podem ser aplicáveis ao conjunto de dados.

Tabela 5 - Comparação dos erros encontrados em cada métodos de suavização aplicáveis aos dados

Método	DM	MDA	MSE	EPAM	r^1	U de Theil	AIC
ANA	4,062	15,164	18,902	9,45%	-0,125	0,585	637,357
MNA	4,494	15,072	19,103	9,30%	-0,112	0,582	632,867
AAA	0,031	13,642	17,438	8,70%	-0,067	0,525	631,516
MAA	0,104	13,575	17,514	8,60%	-0,062	0,522	625,879
AAAdA	-0,132	14,074	17,780	8,93%	-0,037	0,538	635,890
MAdA	-0,189	14,065	17,856	8,91%	-0,038	0,536	632,638
MNM	4,072	14,746	18,600	9,11%	-0,151	0,574	630,801
MAM	-0,132	13,390	17,157	8,47%	-0,073	0,513	623,680
MAdM	-0,361	13,505	17,432	8,50%	-0,041	0,519	627,045
MMM	0,093	13,480	17,119	8,53%	-0,078	0,513	623,662
MMdM	0,377	13,585	17,455	8,53%	-0,039	0,520	627,299

As medidas de erro contidas no Quadro 3 foram apresentadas no tópico 3.6 do presente estudo.

Levando em conta o menor valor do AIC o método escolhido pelo *software* foi o MMM (correção de erro multiplicativa, tendência multiplicativa e sazonalidade multiplicativa), neste método os fatores de nível, tendência e sazonalidade foram abrangidos pelo método multiplicativo e se mostraram satisfatórios.

De acordo com Souza, Samohyl e Miranda (2008), o método de previsão ingênuo, é um método simples cuja previsão não se baseia nos dados históricos e na decomposição dos componentes (tendência e sazonalidade), esse método prevê a demanda seguinte levando em consideração o último dado verificado, todo o peso é dado à observação mais recente.

O método MMM apresentou o menor AIC (Akaike) e erros pequenos, quando comparado aos demais métodos avaliados. O coeficiente de autocorrelação r^1 foi próximo de zero como desejável e o U de Theil inferior a 1,0, indicando que todos os métodos de previsão por suavização exponencial foram melhores que o método ingênuo de previsão.

5.2.3 Previsão Utilizando o Método Escolhido

Depois de concluída as etapas de coleta, organização, análise dos dados e escolha do modelo realizou-se as previsões de venda do produto 1080 para os próximos 12 meses, utilizando-se do método MMM que considera a correção de erro, a tendência e a sazonalidade multiplicativa.

Os parâmetros do modelo são α (0,01), β (0,07), γ (0,01), indicando respectivamente uma variação de nível baixa, pouca variação dos padrões de crescimento e pouca variação nos padrões de sazonalidade ao longo do conjunto de dados. As previsões podem ser visualizadas na Tabela 6.

Tabela 6 – Previsão de venda do produto 1080 para os próximos 12 meses utilizando o método MMM

Datas	t	Previsão	L.inf 95	L.Sup 95
out/15	62	186,03	153,80	218,26
nov/15	63	190,33	158,10	222,55
dez/15	64	159,45	127,23	191,68
jan/16	65	130,84	98,62	163,07
fev/16	66	176,35	144,12	208,58
mar/16	67	203,39	171,16	235,61
abr/16	68	203,50	171,27	235,73
mai/16	69	223,93	191,70	256,15
jun/16	70	203,65	171,42	235,87
jul/16	71	215,58	183,35	247,80
ago/16	72	240,21	207,98	272,44
set/16	73	211,79	179,56	244,01

A fim de demonstrar a aderência do modelo escolhido ao conjunto de dados, compararam-se as previsões realizadas com o fluxo real. Para isso coletou-se junto ao banco de dados da empresa os valores de venda do produto 1080, no período de outubro de 2015 á abril de 2016. O gráfico da Figura 15 ilustra essa comparação.

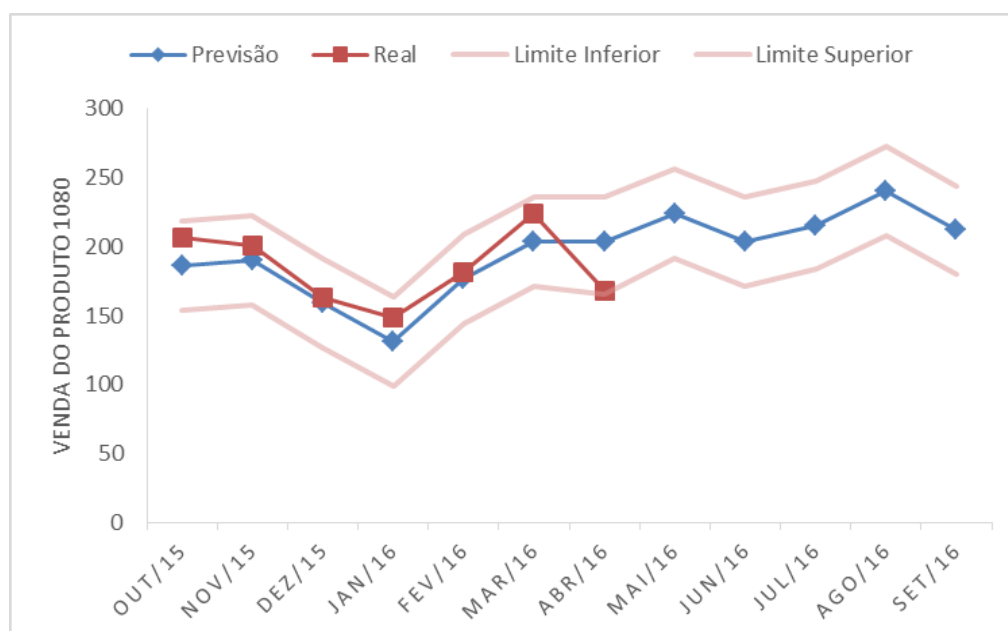


Figura 15 - Previsto x Realizado
Fonte: Autoria própria.

Percebe-se através da Figura 14, a proximidade dos valores previstos com os valores reais do produto 1080, nota-se também que em nenhum momento a demanda ultrapassou os limites inferiores e superiores confirmando a eficácia do modelo de previsão MMM ao explicar ao comportamento dos dados.

Nota-se, porém um comportamento inesperado do fluxo de venda real do produto 1080 no mês de abril, esse comportamento pode ser explicado através da análise qualitativa do cenário atual.

“A dinâmica no Brasil hoje é extremamente complicada, com a combinação da instabilidade e incerteza na política, as mudanças constantes em Brasília e a paralisação e contração da economia” (PUFF, 2016).

Diante deste cenário a venda do produto 1080 sofreu uma queda inesperada que não pode ser previsto pelos dados quantitativos.

De acordo com Weener e Ribeiro (2006), uma análise qualitativa dos dados agrega a previsão quantitativa informações contextuais importantes que a mesma não contempla.

5.3 ANÁLISE ESTATÍSTICA PARA O PRODUTO 1070.

O produto 1070 representa cerca de 8,83% do total faturado pela empresa, sua representatividade é alta considerando que o mesmo representa cerca de 3,33% dos produtos analisados. Como já citado os produtos de classe A na curva ABC merecem uma atenção especial, por esta razão este tópico abordará a análise estatística do produto 1070.

5.3.1 Análise Descritiva das Vendas

De igual modo ao produto 1080 estudado no item 5.2.1 deste trabalho, buscou-se através da análise exploratória agrupar o conjunto de dados do produto 1070, de modo a retirar as informações importantes para a análise estatística.

O conjunto de dados referentes a venda mensal do produto 1070 em peso, é expresso na Tabela 7.

Tabela 7 - Quantidade mensal vendida do produto 1070

MÊS	ANO					
	2010	2011	2012	2013	2014	2015
Janeiro		104,1174	107,7452	112,8362	109,648	91,8784
Fevereiro		126,8069	125,8139	154,4009	162,7038	111,4033
Março		150,4512	159,7126	164,2217	135,3926	173,2764
Abril		157,0934	145,6197	176,6096	151,9146	137,839
Mai		143,9579	156,8928	157,3276	175,6834	135,198
Junho		148,4771	186,8358	176,6158	118,6664	155,4582
Julho		174,9701	143,1274	176,4222	176,5492	145,9465
Agosto		169,2918	163,5539	192,4478	193,695	166,8692
Setembro	135,5635	164,6288	137,5886	196,1692	131,8236	123,8168
Outubro	133,0115	154,669	136,999	150,1456	161,0758	
Novembro	131,6394	147,6654	125,8925	163,798	139,9044	
Dezembro	99,60912	134,8008	133,6224	128,4318	122,618	

Utilizando os dados coletados do produto 1070, realizou-se a uma análise exploratória dos mesmos. Algumas informações pertinentes ao estudo, obtidas com essa análise estão descritas na Tabela 8.

Tabela 8 - Análise Descritiva de Venda

PRODUTO 1070	
Média	147,06
Mediana	147,67
Mínimo	91,878
Máximo	196,17
Desvio padrão	24,173
C.V.	0,16437

Através da análise descritiva do produto 1070, percebe-se que as medidas de tendências estão bem próximas, que a diferença entre o maior e o menor valor do conjunto de dados é de 104,292, que o desvio padrão não indica muita dispersão nos dados e que a proporção da média que o desvio padrão representa é baixa indicando uma baixa variabilidade os dados.

Na Tabela 9 estão descritos os resultados obtidos através dos testes de normalidade.

Tabela 9 - Teste de normalidade

	Teste	p-valor
Doornik-Hansen	0,261275	0,877536
Shapiro-Wilk W	0,988784	0,850585
Lilliefors	0,0584762	0,87
Jarque-Bera	0,70303	0,703621

Além dos testes de normalidade citados acima, pode-se perceber também a normalidade nos resíduos no teste Doornik-Hansen, através de sua a representação gráfica ilustrada na Figura 16.




Figura 16 - Histograma sobreposto por curva normal dos dados de venda do produto 1070.
Fonte: Autoria própria.

Através do Box-Plot dos dados ilustrado na Figura 17, pode-se perceber a ausência de pontos discrepantes (*outliers*) ao longo do conjunto de dados.




Figura 17 - Box-plot dos dados de venda obtidos mensalmente com o produto 1080.
Fonte: Autoria própria.

5.3.2 Escolha do Método Adequado

A escolha do modelo adequado está pautada nos parâmetros: tendência, ciclicidade e sazonalidade da série temporal. Para melhor visualização desses parâmetros fez-se necessário a plotagem gráfica do conjunto de dados, representado pela Figura 18.




Figura 18 - Gráfico do dados de venda do produto 1070 referente aos meses de análise
Fonte: Autoria própria.

Pode-se visualizar na Figura 18 a presença de uma sazonalidade entre os meses observados, porém nota-se que a serie temporal não apresenta uma tendência a crescimento ou queda, podemos notar ainda ciclos de variação na venda do produto 1070.

Decompondo a serie temporal obtêm-se os índices de comportamento sazonal do conjunto de dados, ilustrado na Figura 19.




Figura 19 - Índices sazonais do conjunto de dados do produto 1070
Fonte: Autoria própria.

Como observado no produto 1080 também há uma queda na venda do produto 1070 nos meses de janeiro, fevereiro e dezembro. Pode-se observar também um aumento significativo da venda no mês de agosto.

Aplicaram-se modelos de suavização exponencial para previsão da demanda do produto 1070. A escolha do método adequado, ou seja, que mais se ajustou ao conjunto de dados foi realizada com o auxílio do NNQ-Estatística, um *software* que sugere um modelo levando em conta a minimização dos erros amostrais.

Os resultados obtidos com o NNQ-Estatística estão apresentados na Tabela 10.

A Tabela 10 compara 11 métodos de suavização exponencial de acordo com erros amostrais obtidos em cada método. Os erros tratados pelo *software* foram descritos no tópico 3.6 deste estudo.

Tabela 10 - Comparação dos erros encontrados em cada métodos de suavização aplicáveis aos dados do produto 1070.

Método	DM	MDA	MSE	EPAM	R¹	U de Theil	AIC
ANA	0,005	13,289	16,125	9,14%	0,068	0,569	617,969
MNA	0,044	13,432	16,165	9,26%	0,069	0,570	615,738
AAA	0,570	12,403	15,553	8,70%	0,200	0,549	617,566
MAA	2,565	12,071	15,760	8,57%	0,150	0,546	612,548
AAAdA	0,526	12,351	15,584	8,52%	0,001	0,551	619,807
MAdA	0,664	12,541	15,668	8,71%	0,002	0,554	615,769
MNM	1,086	12,654	15,687	8,85%	0,190	0,547	610,650
MAM	1,007	12,364	15,617	8,67%	0,208	0,549	613,244
MAdM	1,129	11,994	15,317	8,40%	0,186	0,538	612,707
MMM	1,031	12,673	15,743	8,87%	0,188	0,549	615,010
MMdM	1,490	12,062	15,322	8,45%	0,208	0,538	612,838

O NNQ-Estatística opta pelo método que possua o menor valor no AIC, neste caso o método escolhido pelo software foi o MNM que significa que a correção de erro é multiplicativa, não há tendência e a sazonalidade é multiplicativa, neste caso os fatores de nível e tendência foram abrangidos pelo modelo e se mostraram satisfatórios.

O método MNM apresentou erros pequenos, quando comparado aos demais métodos avaliados. O coeficiente de autocorrelação r^1 foi próximo de zero como desejável e o U de Theil inferior a 1,0, indicando que todos os métodos de previsão por suavização exponencial foram melhores que o método ingênuo de previsão.

5.3.3 Previsão Utilizando o Método Escolhido

A partir da escolha do método de suavização exponencial adequado o MNM gerou-se a previsão da demanda para os próximos 12 meses, a fim de compará-la aos dados reais de venda do produto 1070.

As previsões foram geradas considerando α (0,20), β (0), γ (0,01) e podem

ser visualizadas na Tabela 11. O valor de α indica uma variação de nível baixa, a valor de γ indica pouca variação nos padrões de sazonalidade e o valor de β indica que não há variação de crescimento ao longo do conjunto de dados.

Tabela 11 - Previsão de venda baseada no método MNM do produto 1070 para os próximos 12 meses

Datas	t	Previsão	L.inf 95	L.Sup 95
out/15	62	135,18	107,57	162,78
nov/15	63	129,38	102,46	156,31
dez/15	64	114,39	90,15	138,63
jan/16	65	94,84	74,39	115,30
fev/16	66	124,35	97,07	151,63
mar/16	67	143,58	111,56	175,59
abr/16	68	141,81	109,68	173,94
mai/16	69	141,76	109,14	174,37
jun/16	70	141,46	108,42	174,50
jul/16	71	150,06	114,50	185,62
ago/16	72	164,37	124,87	203,88
set/16	73	139,73	105,68	173,77

Para verificar a proximidade da previsão com a realidade, coletaram-se os dados de venda do produto 1070 referentes aos meses de outubro de 2015 á abril de 2016. A Figura 20 ilustra graficamente os dados da previsão e os dados reais.

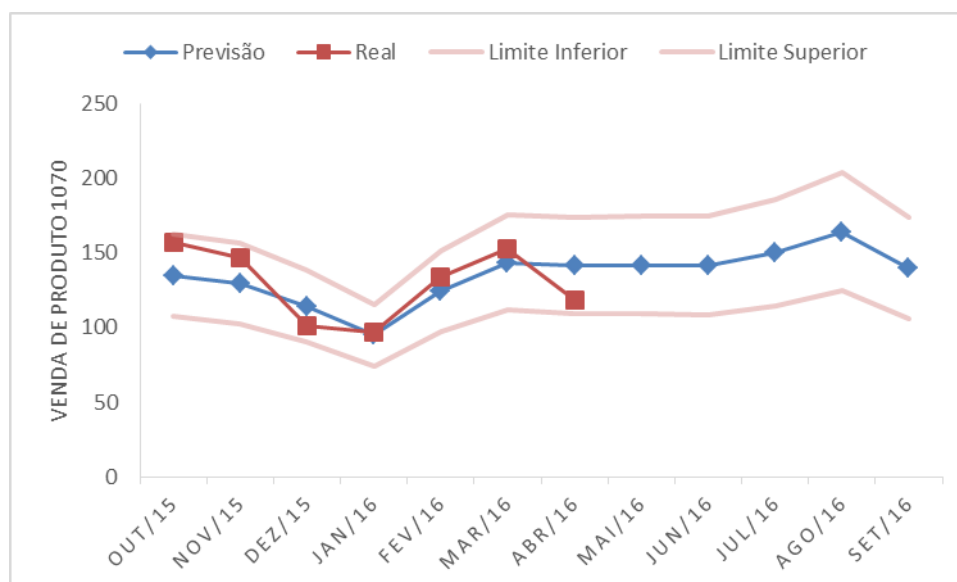


Figura 20 - Previsto x Realizado
Fonte: Autoria própria.

Pode-se observar na Figura 20 a proximidade da previsão aos dados reais, nota-se que em nenhum momento a demanda ultrapassou os limites inferiores e

superiores, mostrando assim a eficácia do modelo de previsão MNM ao explicar o comportamento do conjunto de dados.

No entanto, como no produto 1080, houve também no produto 1070 um comportamento inesperado do fluxo de venda real no mês de abril de 2016. Esse comportamento inesperado atingiu todos os setores da empresa e pode ser explicado por uma análise qualitativa do cenário atual.

6 CONCLUSÃO

Foi proposto ao longo deste trabalho avaliar, analisar e prever a demanda de produtos de uma indústria do ramo alimentício no oeste do Paraná por meio de métodos estatísticos.

Inicialmente, a construção das teorias sobre curva ABC e previsão de demanda foi apresentada de forma resumida, evidenciando os aspectos relevantes para o estudo. Na sequência, abordaram-se os procedimentos necessários para operacionalizar as teorias propostas.

Com os resultados obtidos na operacionalização das teorias pode-se fornecer a empresa uma ideia dos principais produtos em termos de retorno financeiro, bem como uma previsão de venda de dois desses produtos, estabelecendo qual o melhor modelo de suavização exponencial para o caso específico de cada um dos produtos avaliados.

O *software* NNQ mostrou-se capaz de auxiliar na realização das previsões pelos diversos métodos, bem como na indicação dos melhores modelos com base nos valores dos erros, U de Theil e Akaike.

Espera-se com isso pode subsidiar a tomada de decisão da empresa em termos de compras de matérias primas e direcionamento de suas linhas de produção, com base nas previsões apresentadas, sendo que os cálculos de demanda são o ponto de início dos processos de planejamento e controle de produção.

REFERÊNCIAS

ADKINS, Lee C. **Using Gretl for Principles of Econometrics**. 3ª edição, versão 1.3131, 2010. Disponível em: < <http://www.learneconometrics.com/gretl/ebook.pdf>> Acessado em: 24 de mai. 2016.

ALBUQUERQUE, Jean C. da S.; SERRA, Cláudio M. V. **Utilização de modelos de holt-winters para a previsão de séries temporais de consumo de refrigerantes no Brasil**. In: ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO ENEGEP, 24., 2006, Fortaleza. **Anais...** . Fortaleza: Abepro, 2006. Disponível em: < http://www.abepro.org.br/biblioteca/ENEGEP2006_TR460317_7576.pdf> Acesso em: 04 nov. 2015.

ANDERSON, David R; SWEENEY, Dennis J.; WILLIAMS, Thomas A. **Estatística Aplicada à Administração e Economia**. São Paulo: Cengage Learning, 2011.

ANDRADE, Carlos A. S. **Noções de Econometria com Gretl**. Disponível em: <https://www.academia.edu/10072595/No%C3%A7%C3%B5es_de_econometria_tutorial_com_aplica%C3%A7%C3%A3o_do_software_Gretl>. Acesso em: 13 de mai. 2016.

ABIA - ASSOCIAÇÃO BRASILEIRA DAS INDÚSTRIS DA ALIMENTAÇÃO. **Indústria da Alimentação – Principais Indicadores Econômicos**. Disponível em: < <http://www.abia.org.br/vst/faturamento.pdf>> Acesso em: 28 out. 2015.

AKAIKE, Hiroyuki. *A New Look at the Statistical Model Identification*. **IEEE Transaction on Automatic Control**., Boston, v.19, n.6, p. 716-723, Dec. 1974.

BARBETTA, Pedro A.; REIS, Marcelo M.; BORNIA, Antonio C. **Estatística para Cursos de Engenharia e Informática**. São Paulo: Atlas, 2012.

BELLO, José L. de P. **Manual para elaboração de Trabalhos de Conclusão de Curso, Monografias, Dissertações e Teses**. São Paulo: Clube dos Autores, 2012.

BIRCHAL, Sérgio de O. Empresa e Indústria Alimentícia no Brasil. **Revista de Administração FEAD**, v.1, n.2, p. 55-69, 2004. Disponível em: < <http://revista.fead.br/index.php/adm/article/view/78/60>>. Acesso em: 31 out. 2015.

BITERNCURT, Wanderci A.; PEREIRA, Nadia C.; JUNIOR, Luiz G.; REIS, Ricardo Pereira R.; CALEGARIO, Cristina L. **Um estudo econométrico da base da**

commodity café a partir do índices ESALQ e preço futuro BM&F. Lavras, Minas Gerais, 2005. Disponível em: < <http://www.sober.org.br/palestra/6/1061.pdf> > . Acesso em : 3 out. 2015.

BRACARENSE, Paulo A.; **Estatística aplicada às Ciências Sociais.** Curitiba: IESDE Brasil S.A., 2012.

CECATTO, Cristiano; BELFIORE, Patrícia. O uso de métodos de previsão de demanda nas indústrias alimentícias brasileiras. **Gest. Prod.**, São Carlos, v.22, n.2, p. 404-418, 2015. Disponível em: < <http://www.scielo.br/pdf/gp/v22n2/0104-530X-gp-22-2-404.pdf> > . Acesso em: 30 out. 2015.

CHOPRA, Sunil; MEINDL, Peter. **Gestão da Cadeia de Suplimentos – Estratégias, Planejamento e Operações.** São Paulo: Pearson Prentice Hall, 2011.

CORRÊA, Henrique L.; CORRÊA, Carlos A. **Administração de Produção e Operações.** São Paulo: Atlas, 2012.

CORRÊA, Henrique L.; GIANESI, Irineu G. N.; CAON, Mauro. **Planejamento, Programação e Controle da Produção.** São Paulo: Atlas, 2010.

DIAS, Marco A. P. **Administração de Materiais: Princípios, Conceitos e Gestão.** São Paulo: Atlas, 2012.

DANTON, Gian. **Metodologia Científica.** Minas Gerais: Virtual Books Online M&M Editores Ltda, 2002.

DOANE, David P.; SEWARD, Lori E. **Estatística Aplicada à Administração e Economia.** São Paulo: AMGH Editora Ltda, 2014.

FERNANDES, Flavio C. F.; FILHO, Moacir G. **Planejamento e Controle da Produção.** São Paulo: Atlas, 2010.

FUSCO, José Paulo A.; SACOMANO, José B. **Operações e Gestão Estratégica da Produção.** São Paulo: Arte & Ciência, 2007.

GIL, Antonio C. **Métodos e Técnicas de Pesquisa Social.** São Paulo: Atlas, 2008.

HYNDMAN, Rob; ATHANASOPOULOS, George. **Forecasting: princípios and practice**. O Texts, 2013.

JOAQUIM, Vitor N. **Estatística descritiva: Instrumento de decisão**. São Paulo: Chambel Multimedia, 2015.

KAUARK, Fabiana; MANHÃES, Fernanda C.; MEDEIROS, Carlos H. **Metodologia da Pesquisa: Guia Prático**. Itabuna: Via Litterarum, 2010.

LUSTOSA, Leonardo et. al. **Planejamento e Controle da Produção**. Rio de Janeiro: Elsevier, 2008.

MARCONI, Marina de A.; LAKATOS, Eva M. **Fundamentos de Metodologia Científica**. São Paulo: Atlas, 2010.

MARTINS, Petrônio G.; LAUGENI, Fernando P. **Administração da Produção**. São Paulo: Saraiva, 2005.

MILNITZ, Diego; MARCHI, Jamur J.; SAMOHYL, Robert W. Previsão de Demanda: uma aplicação do método de holt winters em uma indústria têxtil de grande porte. In: ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO, 31. 2011, Belo Horizonte. **Anais eletrônicos...** Rio de Janeiro: ABEPRO, 2011. Disponível em: <http://www.abepro.org.br/biblioteca/enegep2010_TN_STP_113_740_15622.pdf>. Acesso em: 03 out. 2015.

MOREIRA, Daniel A. **Administração da Produção e Operação**. São Paulo: Cengage Learning, 2011.

OLIVEIRA, Giuliano C.; OLIVEIRA, Bráulio A. C. Evolução e Perspectiva da Indústria Alimentícia Brasileira. **Seminário em Administração FEA-US**, São Paulo, 2003. Disponível em: <<http://www.ead.fea.usp.br/Semead/6semead/ADM%20GERAL/039Adm%20-%20Evolu%20e%20Perspectivas%20da%20Ind%20FAstria.doc>> Acessado em: 29 out. 2015.

PORTAL ACTION. Disponível em: < <http://www.portalaction.com.br/analise-de-regressao/16-coeficiente-de-determinacao>>. Acessado em: 28 mai. 2016.

PUFF, Jefferson. Para agências de risco, nem Dilma nem Temer evitarão estagnação da economia. BBC Brasil, Rio de Janeiro, 11 de abril de 2016.

Disponível em: <
http://www.bbc.com/portuguese/noticias/2016/04/160411_dilmaxtemer_jp>.
Acessado em: 22 mai. 2016.

REIS, Edna A.; REIS, Ilka A. **Análise descritiva de dados Síntese numérica.** Relatório Técnico, RTO – 02/2002. Disponível em: <
<ftp://ftp.est.ufmg.br/pub/rts/rte0202.pdf>> Acessado em: 11 mai. 2016.

SANTIAGO, Maura M. D.; CAMARGO, Maria de L. B.; MARGARIDO, Mario A. Detecção e Análise de *Outliers* em Séries Temporais de Índices de Preços Agrícolas no Estado de São Paulo. **Agricultura em São Paulo**, São Paulo, v. 43, n 2, p. 89-115, 1996. Disponível em: < ftp://ftp.sp.gov.br/ftpiea/rea/tomo2_96/artigo6.pdf> Acesso em: 28 mai. 2016.

SEBRAE. **Critérios de Classificação de Empresas: MEI – ME – EPP.** Disponível em: < <http://www.sebrae-sc.com.br/leis/default.asp?vcdtexto=4154>> Acesso em: 11 de nov. 2015.

SLACK, Nigel; CHAMBERS, Stuart; JOHNSTON, Robert. **Administração da Produção.** São Paulo: Atlas, 2009.

SOUZA, Gueibi P; SAMOHYL, Robert W; MIRANDA, Rodrigo G. de. **Métodos Simplificados de Previsão Empresarial.** Rio de Janeiro: Ciência Moderna, 2008.

SPIEGEL, Murray R. **Estatística.** São Paulo: Pearson Makron Books, 1993. – (Coleção Schaum)

TUBINO, Dalvio F. **Planejamento e Controle da Produção: Teoria e Prática.** São Paulo: Atlas, 2009.

TUKEY, Jhon W. **A Survey of Sampling from Contaminated Distribution. Contributions to Probability and Statistics.** California: University Press Stanford, 1960.

WERNER, Liane; RIBEIRO, José L. D. Modelo Composto para Prever Demanda Através da Integração de Previsões. **Produção**, v.16, n. 3, p. 493-509. Set/Dez.2006. Disponível em: < <http://www.scielo.br/pdf/prod/v16n3/a11v16n3.pdf>>. Acessado: 22 de mai. 2016.