

UNIVERSIDADE DE ARARAQUARA
MESTRADO PROFISSIONAL EM ENGENHARIA DE PRODUÇÃO

Bruno Rafael Falavigna Beneventi

**PREVISÃO DE DEMANDA: ESTUDO DE CASO EM UMA INDÚSTRIA
ALIMENTÍCIA DO INTERIOR DO ESTADO DE SÃO PAULO**

Dissertação apresentada ao Programa de Mestrado Profissional em Engenharia de Produção da Universidade de Araraquara – UNIARA – como parte dos requisitos para obtenção do título de Mestre em Engenharia de Produção, Área de Concentração: Gestão Estratégica e Operacional da Produção.

Profa. Dra. Ethel Cristina Chiari da Silva
Orientadora

Araraquara, SP – Brasil
2017

FICHA CATALOGRÁFICA

B413 Beneventi, Bruno

Previsão de demanda: um estudo de caso em indústria alimentícia do interior do estado de São Paulo/Bruno Beneventi. – Araraquara: Universidade de Araraquara, 2017.
140f.

Dissertação (Mestrado) - Mestrado Profissional em Engenharia de Produção – Universidade de Araraquara - UNIARA

Orientador: Prof. Dra. Ethel Cristina Chiari da Silva

1. Previsão de demanda. 2. Métodos de previsão de demanda.
3. Séries temporais. 4. Indústria alimentícia. I. Título.

CDU 62-1

REFERÊNCIA BIBLIOGRÁFICA

BENEVENTI, B. R. F. **Previsão de Demanda: Um Estudo de Caso em uma Empresa Alimentícia do Interior do Estado de São Paulo**. 2017. 140 f. Dissertação de Mestrado em Engenharia de Produção – Universidade de Araraquara, Araraquara-SP.

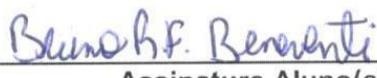
ATESTADO DE AUTORIA E CESSÃO DE DIREITOS

NOME DO AUTOR: Bruno Rafael Falavigna Beneventi

TÍTULO DO TRABALHO: Previsão de Demanda: Um Estudo de Caso em uma Empresa Alimentícia do Interior do Estado de São Paulo

TIPO DO TRABALHO/ANO: Dissertação / 2017

Conforme LEI Nº 9.610, DE 19 DE FEVEREIRO DE 1998, o autor declara ser integralmente responsável pelo conteúdo desta dissertação e concede a Universidade de Araraquara permissão para reproduzi-la, bem como emprestá-la ou ainda vender cópias somente para propósitos acadêmicos e científicos. O autor reserva outros direitos de publicação e nenhuma parte desta dissertação pode ser reproduzida sem a sua autorização.


Assinatura Aluno(a)

Bruno Rafael Falavigna Beneventi

Universidade de Araraquara – UNIARA

Rua Carlos Gomes, 1217, Centro. CEP: 14801–340, Araraquara-SP

E-mail : bruno_beneventi182@hotmail.com



UNIVERSIDADE DE ARARAQUARA - UNIARA
MESTRADO PROFISSIONAL EM ENGENHARIA DE PRODUÇÃO

FOLHA DE APROVAÇÃO

Dissertação apresentada ao Programa de Mestrado Profissional em Engenharia de Produção da Universidade de Araraquara – UNIARA – para obtenção do título de Mestre em Engenharia de Produção.

Área de Concentração: Gestão Estratégica e Operacional da Produção.

NOME DO AUTOR: **BRUNO RAFAEL FALAVIGNA BENEVENTI**

TÍTULO DO TRABALHO:

"PREVISÃO DE DEMANDA: ESTUDO DE CASO EM UMA INDÚSTRIA ALIMENTÍCIA DO INTERIOR DO ESTADO DE SÃO PAULO."

Assinatura do(a) Examinador(a)

Conceito

Prof(a). Dr(a). Ethel Cristina Chiari da Silva (orientador(a))
Universidade de Araraquara - UNIARA

Aprovado () Reprovado

Prof(a). Dr(a). Jorge Alberto Achcar
Universidade de Araraquara - UNIARA

Aprovado () Reprovado

Prof(a). Dr(a). Marcelo Giroto Rebelato
Universidade Estadual Paulista Júlio de M. Filho - UNESP

Aprovado () Reprovado

Versão definitiva revisada pelo(a) orientador(a) em: 25 / 11 / 2017

Prof(a). Dr(a). Ethel Cristina Chiari da Silva (orientador(a))

Aos meus pais, Joacir Domingos e Maria Aparecida que sempre com muito amor me ensinaram a enfrentar a vida de peito aberto, trabalhar meus medos, vencer dificuldades, amar os desafios e nunca deixar de sonhar.

AGRADECIMENTOS

Agradeço primeiramente a Deus por ter me dado forças para alcançar este objetivo.

Aos meus pais que se esforçaram muito para me proporcionar esta chance.

A minha família pelo reconhecimento e apoio em todos os momentos.

Ao meu irmão pelo companheirismo.

Aos amigos de todas as horas, as de lazer, as de dificuldades, de tristeza e de felicidades.

Ao Prof. Dr. Marcelo Giroto Rebelato por participar da banca examinadora e nas considerações deste trabalho.

Ao Prof. Dr. Jorge Alberto Achcar por participar da banca examinadora e auxiliar nas análises estatísticas deste trabalho.

E principalmente a minha Orientadora, Profa. Dra. Ethel Cristina Chiari da Silva que sempre esteve me ajudando e auxiliando para a conclusão deste trabalho.

“O mundo é um lugar perigoso de se viver, não por causa daqueles que fazem o mal, mas sim por causa daqueles que observam e deixam o mal acontecer.”

Albert Einstein

RESUMO

A economia brasileira tem enfrentado instabilidade política e econômica, tendo como consequência altas taxas de inflação influenciando todos os ramos de negócios, o que torna indispensável para as empresas a busca de técnicas de planejamento, dentre elas o emprego de métodos de previsão de demanda para orientar a produção e venda de seus produtos, como forma de redução de custos e aumento de competitividade. A indústria alimentícia é um dos setores mais importantes da economia nacional, e como as demais, requer práticas de planejamento de sua produção, cujos produtos estão sujeitos a situações de complexidade, sazonalidade e perecibilidade, requerendo aplicação de método de previsão de demanda que mais se adapta a esses fatores. Isso leva ao objetivo desse estudo, identificar, analisar e discutir a adequação dos modelos de previsão de demanda a fim de auxiliar os gestores na tomada de decisão, buscando otimizar os recursos da empresa, minimizando riscos inerentes ao mercado de alimentos e aumentando a competitividade. Para atingir a esse proposto, a metodologia empregada é o de pesquisa bibliográfica e realização de estudo de caso, utilizando-se da observação direta, por meio de análise de dados por meio de relatórios e indicadores fornecidos por uma empresa de médio porte do ramo alimentício instalado no interior do estado de São Paulo. Com isso comprovou-se a importância da previsão de demanda para as operações e foram identificadas alternativas para facilitar o trabalho dos gestores de produção. E conclui-se que a previsão de demanda permite um programa otimizado de todo o planejamento e produção, possibilitando melhor alocação de recursos físicos nos processos operacionais.

Palavras-chave: Previsão de demanda. Métodos de previsão de demanda. Séries temporais. Indústria de alimentos.

ABSTRACT

The Brazilian economy has faced political and economic instability, resulting in high rates of inflation influencing all business sectors, which makes it indispensable for companies to seek planning techniques, among them the use of demand forecasting methods to guide the production and sale of its products, as a way of reducing costs and increasing competitiveness. The food industry is one of the most important sectors of the national economy, and like the others, it requires production planning practices, whose products are subject to complexity, seasonality and perishability, requiring a demand forecasting method that takes these factors into account. This leads to the objective of this study to identify, analyze and discuss the adequacy of demand forecasting models in order to assist managers in decision making, seeking to optimize company resources, minimizing risks inherent in the food market and increasing competitiveness. In order to reach this goal, the methodology used is the bibliographic research and the study of a case, using direct observation, through data analysis through reports and indicators provided by a medium-sized food company installed in the interior of the state of São Paulo. This proved the importance of forecasting demand for operations and identified alternatives to facilitate the work of production managers. It is concluded that the forecast of demand allows an optimized program of all planning and production, allowing better allocation of physical resources in the operational processes.

Key-words: *Forecast of demand. Demand forecasting methods. Time series. Food industry.*

Lista de Figuras

Figura 1 – Exemplo série temporal.....	42
Figura 2 – Linha de regressão linear em relação aos dados reais.....	44
Figura 3 – Condução do estudo de caso.....	66
Figura 4 – Série histórica de demanda mensal.....	73
Figura 5 – Modelo de média móvel produto 1.....	74
Figura 6 – Modelo de média móvel produto 2.....	75
Figura 7 – Modelo de média móvel produto 3.....	75
Figura 8 – Modelo de média móvel produto 4.....	76
Figura 9 – Modelo de média móvel produto 5.....	77
Figura 10 – Modelo de média móvel produto 6.....	77
Figura 11 – Modelo de média móvel produto 7.....	78
Figura 12 – Modelo de média móvel produto 8.....	79
Figura 13 – Modelo de média móvel produto 9.....	79
Figura 14 – Modelo de média móvel produto 10.....	80
Figura 15 – Previsões produto 1.....	81
Figura 16 – ACF produto 1.....	82
Figura 17 – PACF produto 1.....	82
Figura 18 – Resíduos do modelo (produto 1).....	83
Figura 19 – Modelo ajustado e dados observados (produto 1).....	83
Figura 20 – Previsões produto 2.....	85
Figura 21 – ACF produto 2.....	85
Figura 22 – PACF produto 2.....	86
Figura 23 – Resíduos produto 2.....	86
Figura 24 – Ajuste com tempo produto 2.....	87

Figura 25 – Previsões produto 3.....	88
Figura 26 – ACF produto 3.....	89
Figura 27 – PACF produto 3.....	89
Figura 28 – Resíduos produto 3.....	90
Figura 29 – Ajuste com tempo produto 3.....	90
Figura 30 – Previsões produto 4.....	92
Figura 31 – ACF produto 4.....	92
Figura 32 – PACF produto 4.....	93
Figura 33 – Resíduos produto 4.....	93
Figura 34 – Ajuste com tempo produto 4.....	94
Figura 35 – Previsões produto 5.....	95
Figura 36 – ACF produto 5.....	96
Figura 37 – PACF produto 5.....	96
Figura 38 – Resíduos produto 5.....	97
Figura 39 – Ajuste com tempo produto 5.....	97
Figura 40 – Previsões produto 6.....	99
Figura 41 – ACF produto 6.....	99
Figura 42 – PACF produto 6.....	100
Figura 43 – Resíduos produto 6.....	100
Figura 44 – Ajuste com tempo produto 6.....	101
Figura 45 - Previsões produto 7.....	102
Figura 46 – ACF produto 7.....	103
Figura 47 – PACF produto 7.....	103
Figura 48 – Resíduos produto 7.....	104
Figura 49 – Ajuste com tempo produto 7.....	104

Figura 50 – Previsões produto 8.....	106
Figura 51 – ACF produto 8.....	106
Figura 52 – PACF produto 8.....	107
Figura 53 – Resíduos produto 8.....	107
Figura 54 – Ajuste com tempo produto 8.....	108
Figura 55 – Previsões produto 9.....	109
Figura 56 – ACF produto 9.....	110
Figura 57 – PACF produto 9.....	110
Figura 58 – Resíduos produto 9.....	111
Figura 59 – Ajuste com tempo produto 9.....	111
Figura 60 – Previsões produto 10.....	113
Figura 61 – ACF produto 10.....	113
Figura 62 – PACF produto 10.....	114
Figura 63 – Resíduos produto 10.....	114
Figura 64 – Ajuste com tempo produto 10.....	115
Figura 65 – Resíduos produto 1.....	117
Figura 66 – Regressão com tempo produto 1.....	117
Figura 67 – Resíduos produto 2.....	118
Figura 68 – Regressão com tempo produto 2.....	119
Figura 69 – Resíduos produto 3.....	120
Figura 70 – Regressão com tempo produto 3.....	120
Figura 71 – Resíduos produto 4.....	121
Figura 72 – Regressão com tempo produto 4.....	122
Figura 73 – Resíduos produto 5.....	123
Figura 74 – Regressão com tempo produto 5.....	123

Figura 75 – Resíduos produto 6.....	124
Figura 76 – Regressão com tempo produto 6.....	125
Figura 77 – Resíduos produto 7.....	126
Figura 78 – Regressão com tempo produto 7.....	126
Figura 79 – Resíduos produto 8.....	127
Figura 80 – Regressão com tempo produto 8.....	128
Figura 81 – Resíduos produto 9.....	129
Figura 82 – Regressão com tempo produto 9.....	129
Figura 83 – Resíduos produto 10.....	130
Figura 84 – Regressão com tempo produto 10.....	131

Lista de Quadros

Quadro 1 – Classificação dos Métodos para Classificação da Demanda.....	33
Quadro 2 – Aplicação de previsão de demanda.....	34
Quadro 3 – Classificação dos estabelecimentos segundo porte.....	69

Lista de Tabelas

Tabela 1 – Dados históricos de demanda de dez produtos da empresa desse estudo no período de Janeiro de 2014 a Abril de 2017.....	71
Tabela 2 – Covariáveis.....	72
Tabela 3 – Parâmetros e coeficientes do modelo estimados para o produto 1.....	80
Tabela 4 – Previsões produto 1.....	81
Tabela 5 – Estimadores dos Parâmetros e intervalos de confiança 95% (prod. 2).....	84
Tabela 6 – Previsões produto 2.....	84
Tabela 7 – Estimadores dos Parâmetros e intervalos de confiança 95% (prod. 3).....	87
Tabela 8 – Previsões produto 3.....	88
Tabela 9 – Estimadores dos Parâmetros e intervalos de confiança 95% (prod. 4).....	91
Tabela 10 – Previsões produto 4.....	91
Tabela 11 – Estimadores dos Parâmetros e intervalos de confiança 95% (prod. 5).....	94
Tabela 12 – Previsões produto 5.....	95
Tabela 13 – Estimadores dos Parâmetros e intervalos de confiança 95% (prod. 6).....	98
Tabela 14 – Previsões produto 6.....	98
Tabela 15 – Estimadores dos Parâmetros e intervalos de confiança 95% (prod. 7).....	101
Tabela 16 – Previsões produto 7.....	102
Tabela 17 – Estimadores dos Parâmetros e intervalos de confiança 95% (prod. 8).....	105
Tabela 18 – Previsões produto 8.....	105
Tabela 19 – Estimadores dos Parâmetros e intervalos de confiança 95% (prod. 9).....	108
Tabela 20 – Previsões produto 9.....	109
Tabela 21 – Estimadores dos Parâmetros e intervalos de confiança 95% (prod. 10).....	112
Tabela 22 – Previsões produto 10.....	112
Tabela 23 – Regressão produto 1.....	116

Tabela 24 – Regressão produto 2.....	118
Tabela 25 – Regressão produto 3.....	119
Tabela 26 – Regressão produto 4.....	121
Tabela 27 – Regressão produto 5.....	122
Tabela 28 – Regressão produto 6.....	124
Tabela 29 – Regressão produto 7.....	125
Tabela 30 – Regressão produto 8.....	127
Tabela 31 – Regressão produto 9.....	128
Tabela 32 – Regressão produto 10.....	130

Lista de Abreviaturas e Siglas

ACF	Autocorrelation function
AED	Amortecimento Exponencial Duplo
AES	Amortecimento Exponencial Simples
AR	Autorregressivo
ARIMA	Modelo Autorregressivo Integrado de Média Móvel
ARMA	Modelo Autorregressivo de Média Móvel
FAC	Funções de Autocorrelação
FACP	Funções de Autocorrelação Parcial
I	Integração
IPCA	Índice Nacional de Preços ao Consumidor Amplo
MA	Modelo de Média Móvel
MAD	Desvio Médio Absoluto
MAPE	Erro Percentual Absoluto Médio
PACF	Partial Autocorrelation Function
PIB	Produto Interno Bruto
RN	Redes Neurais
SEBRAE	Serviço Brasileiro de Apoio às Micro e Pequenas Empresas
SEH	Suavização Exponencial com Tendência – Método de Holt
SKUs	Unidade em Estoque Apropriado

SUMÁRIO

1 INTRODUÇÃO	18
1.1 Problemática	24
1.2 Objetivos da pesquisa	24
1.3 Justificativa.....	25
1.4 Classificação metodológica da pesquisa.....	26
1.5 Estrutura do Trabalho	27
2 PREVISÃO DE DEMANDA.....	28
2.1 Previsão de demanda	28
2.1.1 Importância da previsão de demanda	31
2.1.2 Padrões de demanda	32
2.1.3 Métodos de previsão de demanda.....	33
2.1.4 Escolha do sistema de previsão de demanda	34
2.1.5 Controle do modelo de previsão de demanda.....	36
2.1.6 Custo de previsão de demanda	37
2.2 Métodos de previsão de demanda.....	37
2.2.1 Métodos Qualitativos.....	37
2.2.2 Métodos Quantitativos.....	40
2.2.2.1 Séries temporais ou de projeção histórica	41
2.2.2.2 Métodos causais ou multivariáveis.....	43
2.3 Métodos básicos de previsão de demanda.....	46
2.3.1 Média simples.....	48
2.3.2 Média Móvel	49
2.3.3 Média Móvel Dupla.....	50
2.3.4 Amortecimento Exponencial Simples (AES).....	52
2.3.5 Amortecimento Exponencial Duplo (Modelo De Brown)	54
2.3.6 Suavização Exponencial com Tendência - Método de Holt (SEH).....	54
2.3.7 Suavização Exponencial com tendência e sazonalidade – Modelo Holt Winters	55
2.3.8 Modelos ARIMA de BOX e JENKINS.....	56
2.4 Erros de previsão de demanda	60
2.5 Sazonalidade.....	63
3 METODOLOGIA	65
3.1 Materiais e métodos.....	68
4 ESTUDO DE CASO.....	69
4.1 Caracterização da empresa	69
4.2 Coleta dos dados.....	70

4.3 Análise dos dados e discussões dos resultados.....	73
5 CONSIDERAÇÕES FINAIS	132
REFERÊNCIAS	135

1 INTRODUÇÃO

Atualmente a gestão de estoques é um tema de extrema importância e fundamental para as organizações que buscam melhores alternativas para continuarem se destacando no mercado globalizado e competitivo (SANTOS, 2014).

O processo de globalização tomou conta do mundo empresarial e exigiu das organizações maior competitividade, para conseguirem sobreviver no mercado global. Esta sobrevivência depende de como planejar e coordenar todas as atividades necessárias para atingir os níveis desejados de qualidade e serviços prestados, em um mercado com uma quantidade crescente de exigências (GARCIA, 2011). Para Pellegrini e Fogliatto (2001, p. 44) “a qualidade da tomada de decisão tem relação direta com os dados disponíveis para o tomador de decisão e com sua habilidade em extrair destes dados informações relevantes.”

Uma programação de produção eficaz é aquela que deve decidir o quanto, como e em quanto tempo produzir e quais recursos serão utilizados nos processos. Para obter as informações referentes a esse processo é importante realizar uma previsão de demanda, que será útil no fornecimento dos dados necessários para combinar a capacidade de produção com a demanda a ser oferecida. A não acuracidade da previsão de demanda resulta em um super ou subdimensionamento da planta produtiva, o que levará a perdas financeiras. (ARAÚJO; ADISSI, 2004).

Segundo Horngren (2004), o planejamento é a chave para uma ótima gestão, seja para pequenas empresas familiares, grandes corporações, agências governamentais e organizações sem fins lucrativos, ou simplesmente para os indivíduos, ou para a vida pessoal. Corroboram Queiroz e Cavalheiro (2003) apresentando que o planejamento da produção tem a previsão de demanda como um dos seus principais subsídios.

O orçamento empresarial tem como foco principal utilizar recursos disponíveis de forma eficaz, tornando-se um plano de negócios formal e não deve ser compreendido como limitação de gastos, mas como forma de focalizar a atenção nas operações e finanças da empresa, adiantando os problemas potenciais e as vantagens, possibilitando aos gestores tomar atitudes para evitar os problemas ou usar sabiamente as vantagens (HORNGREN, 2004).

Para Queiroz e Cavalheiro (2003) é função da previsão o fornecimento de informações sobre futuras demandas possibilitando subsídios para um planejamento com antecedência permitindo recursos produtivos disponíveis na quantidade, momento e qualidade adequados.

De acordo com Mancuso e Werner (2014), a previsão de demanda é um dos fatores

principais para a eficiência do gerenciamento das empresas, pois afeta diretamente a lucratividade do negócio, e quanto maior a acurácia da previsão de demanda melhor será o desempenho organizacional. Gurgel (2015, p. 16) confirma que por “[...] meio desta ferramenta pode ser feito o planejamento orçamentário e de capital, possibilitando melhor alocação de recursos físicos nos processos operacionais.”

As técnicas de previsão de demanda servem como alicerce para um planejamento estratégico de produção (TUBINO, 2008), buscando antecipar a utilização dos bens de produção assim como seus insumos, fazendo com que muitas empresas consigam atingir esta diferenciação que traga resultados positivos para a empresa.

Para Moreira (2001), tanto quanto para os próximos dias ou semanas, há necessidade de se planejar para anos futuros, embora o grau de detalhe seja diferente nos dois casos. A previsão dos dados é inversamente proporcional ao período que se deseja prever, ou seja, previsões a longo prazo são mais incertas que as previsões a curto prazo.

Sendo assim, a gestão da demanda representa uma atividade fundamental tanto para o Planejamento da Produção como para o controle eficiente dos estoques. Por meio das técnicas de previsão, a tomada de decisão é facilitada, proporcionando a utilização de todos os recursos da fábrica de forma eficaz (FERNANDES; GODINHO, 2010).

No caso da indústria de alimentos, o setor corresponde com certa representatividade na economia nacional e, como demais segmentos, requer planejamento em sua produção, estando esses sujeitos a fatores sensíveis como a sazonalidade de oferta e de demanda, sendo perecíveis e de acentuada diversidade. As organizações, de forma geral, precisam ter conhecimento para direcionar sua capacidade produtiva de forma conseguir um equilíbrio entre a oferta e a demanda. O papel de fornecer subsídios para o planejamento estratégico da organização, ou seja, das previsões se faz necessário em qualquer ramo de negócios, permitindo aos administradores anteciparem o futuro e planejarem de forma mais adequada as suas ações (QUEIROZ; CAVALHEIRO, 2003).

Cecatto e Belfiore (2015, p. 404) compreendem que existe uma necessidade em conhecer o desempenho das indústrias do setor alimentício no Brasil em termos de planejamento de demanda, como meio para enfrentar mercados competitivos e em expansão. A importância do ramo alimentício é reflexo do crescimento da indústria e tem como consequência “o aumento do volume de operações em agronegócios (produtores de matéria-prima), na distribuição atacadista e varejista, além das empresas de embalagens.” As indústrias de alimentos representam um segmento produtivo com significativa participação no crescimento econômico.

A literatura tem apresentado diversos trabalhos abordando o tema previsão de demandas analisando diversos produtos e segmentos, tais como: cervejas (CALÔBA; CALÔBA; SALIBY, 2002; SCIPIONI, T.; SELBITTO, 2015); alimentos e bebidas (QUEIROZ, CAVALHEIRO; VIEIRA, 2003; VEIGA; VEIGA; DUCLÓS, 2010); alimentos (CECATTO; BELFIORE, 2015); atividades de abate, industrialização e comércio de produtos suínos (PELLEGRINI; FOGLIATTO, 2001) carnes (ZANELLA; VIEIRA; BARICHELLO, 2016); indústria de fertilizantes (FARIAS; NOGUEIRA NETO; NOGUEIRA, 2006); indústria de equipamentos para automóveis (BACO; PAIVA; LIMA, 2006); empresa fabricante de itens eletromecânicos. (ZAN; SELBITTO, 2007); indústria metal mecânica (YOKOYAMA; TAKEDA, 2014); indústria têxtil (EKAMI; MING, 2014); embalagens de computadores (OLIVEIRA; CARVALHO, 2013); consumo de adesivo em empresa gráfica (PAGANELLI et al., 2015); implementos agrícolas (BASSETO; BORGES; VINCENZI, 2015); empresa do setor cerâmico (GURGEL et al. 2015); gestão de estoques (MORAIS; SOUZA; MORAIS, 2015); indústria de autopeças (GOMES; SOUSA; PIATO, 2015), como resumidos a seguir:

Calôba, Calôba e Saliby (2002) avaliaram a complementação do uso de técnicas de previsão de vendas com Redes Neurais Artificiais. Analisaram a demanda industrial no setor de cerveja da Austrália por duas diferentes técnicas de previsão, e observaram que a adição de Redes Neurais ao método de decomposição clássica alcançou resultados superiores. O método Redes Neurais (RN) e decomposição alcançou não só a menor média entre os três, como também o menor desvio-padrão da amostra de erros mensais de previsão. Concluíram que a Rede Neural contribuiu para o problema de previsão, reduzindo o erro de uma série já tratada nos domínios do tempo e da frequência em 10%.

No mesmo segmento, Scipioni e Sellitto (2015) identificaram a metodologia de previsão de demanda para produtos (embalagens de cerveja em lata de 473 ml, em caixas de 12 unidades; cerveja em lata de 269 ml, em caixas de 12 unidades; e cerveja em lata de 350 ml, em caixas de 12 unidades) de uma empresa distribuidora de bebidas. Usaram séries temporais. Observaram que o primeiro produto seguiu uma tendência de decréscimo, enquanto que os outros dois oscilaram ao redor de uma média constante.

Queiroz, Cavalheiro e Vieira (2003) apresentaram a proposta de um método para gerar dados de previsão da demanda, da área de alimentos, em três etapas: análise dos dados históricos de demanda, verificação da sazonalidade e aplicação do modelo matemático. As previsões obtidas com o método mostraram previsibilidade igual ou melhor do que os métodos clássicos de previsão de demanda que incluem a sazonalidade.

Veiga, Veiga e Duclós (2010) apresentaram um estudo de caso objetivando definir o modelo quantitativo de previsão de demanda de maior grau de acurácia e verificar a influência da acuracidade da previsão de demanda no desempenho financeiro de uma organização. Valeram-se de dados históricos de demanda de cinco grupos de produto (A, B, C, D e E), no período de 2004 a 2008. Observaram que se a empresa empregasse o modelo ARIMA para os grupos A, B e E, o modelo de Holt para o grupo D e o modelo de Winter para o grupo C, o faturamento poderia ser aumentado em, aproximadamente, dois milhões e oitocentos mil reais anuais.

Cecatto e Belfiore (2015) fizeram um levantamento das práticas de previsão de demanda que vêm sendo utilizadas pelas indústrias de alimentos. Utilizaram aplicação de questionário 450 empresas do setor encontradas na Associação Brasileira das Indústrias da Alimentação (ABIA). Os resultados mostram que o modelo de análise histórica é o mais utilizado, e o fator para essa escolha está relacionado ao tipo de produto e tempo despendido.

Pellegrini e Fogliatto (2001) apresentaram um procedimento para a estruturação de um sistema de previsão de demanda de produtos (atividades de abate, industrialização e comércio de produtos suínos) e serviços, objetivando propor uma metodologia para utilizar técnicas de previsão de demanda no apoio à tomada de decisões gerenciais. No procedimento proposto são indicadas as diretrizes para a implementação de técnicas quantitativas de previsão de demanda.

Zanella, Vieira e Barichello (2016) analisaram os métodos de previsão de demanda utilizados em uma agroindústria de carnes e constataram a utilização de métodos tanto quantitativos como qualitativos, comprovando a importância das previsões de demanda para o planejamento da empresa.

Farias, Nogueira Neto e Nogueira (2006); apresentaram um comparativo de análises quantitativas das séries sazonais relacionadas à demanda nacional de fertilizantes e à demanda de três produtos de um complexo industrial (indústria de fertilizantes) de fosfatados da região sudeste. Aplicaram modelos clássicos de avaliação da série sazonal, comparando-se seus coeficientes de sazonalidade, tendência e periodicidade, buscando atenuar os efeitos da incerteza nos períodos seguintes.

Baco, Paiva e Lima (2006) discutem os principais motivos que levam uma indústria de equipamentos para automóveis a investir em um sistema de previsão de demanda, e quais os benefícios. Apresentam os resultados obtidos de uma comparação de diversos modelos de previsão, entre eles o de suavização exponencial, ARIMA e SARIMA, os quais foram aplicados a dados reais de demanda de matéria prima para fabricação de anéis de pistão.

Zan e Sellitto (2007) apresentaram um estudo triplo em que foram aplicadas técnicas de previsão de demanda a três produtos de empresa fabricante de itens eletromecânicos, com comportamento tendencial positivo, aleatório e sazonal. Os resultados obtidos foram satisfatórios, se comparados à demanda real e servem para avaliar o desempenho do processo e propor modificações no atual sistema. O período de previsão de trinta e seis meses mostrou-se adequado para as aplicações.

Yokoyama e Takeda (2014) testaram os métodos quantitativos de previsão de vendas de séries temporais Média Móvel Simples, Suavização Exponencial, Suavização Dupla (método de *Holt*), Suavização Tripla (método de *Holt-Winters* multiplicativo e aditivo), Decomposição clássica (aditiva e multiplicativa) e Regressão Linear Simples para verificar a contribuição para uma previsão mais precisa para determinada família de produtos (selecionados por meio da classificação ABC) de uma indústria do ramo metal-mecânico. Como resultado foi que o método *Holt-Winters* multiplicativo conseguiu ser mais assertivo e se mostrou o mais adequado para a previsão dos produtos selecionados.

Ekami e Ming (2014) avaliaram a aplicabilidade da previsão da demanda como ferramenta de otimização na indústria têxtil a fim de tornar as empresas mais competitivas, minimizando os riscos aos negócios e maximizando a rentabilidade da empresa. A hipótese inicial foi comprovada de que os modelos de previsão podem ser usados na indústria da confecção, apesar da brevidade do ciclo de vida de seus produtos e dos efeitos da sazonalidade.

Oliveira e Carvalho (2013) utilizaram métodos quantitativos de previsão de demanda para auxiliar na tomada de decisão e manter controle nos níveis de estoques de insumos reduzidos para caixas de armazenagem de computadores. As técnicas utilizadas foram Média Móvel, Média Móvel Ponderada e Regressão Linear. Com os resultados determinaram que as subjetividades das previsões de demanda para controle de estoques exigem que os métodos sejam monitorados com uma certa frequência.

Paganelli et al. (2015) apresentaram a proposta de um método quantitativo de previsão de demanda de séries temporais que com menores erros de previsão para o consumo de adesivo comum de uma gráfica. Os métodos quantitativos de previsão de séries temporais aplicados foram a Suavização Exponencial Simples, Método de *Holt* e Método de *Holt-Winters* (multiplicativo e aditivo). O Modelo Sazonal Aditivo de *Winters* apresentou o menor MAPE, porém não se descartou a aplicação dos demais métodos.

Basseto, Borges e Vincenzi (2015) buscaram prever a quantidade estimada de venda de um modelo de peças para implementos agrícolas, para determinar as previsões futuras.

Utilizaram o método *Holt-Winters*, através dos modelos aditivo e o multiplicativo para se determinar a previsão de demanda que possibilitou indicar determinante quanto sua eficiência para fazer previsão. Os valores do EPAM foram altos, pelo fato do implemento agrícola ter sazonalidade durante o ano pelas questões de plantio, clima (muita chuva, seca ou geada), refletindo diretamente nas vendas.

Gurgel et al. (2015) desenvolveram um modelo de previsão de demanda em uma pequena indústria do setor cerâmico, avaliando sua capacidade produtiva para identificar oportunidades de investimento. Aplicaram o método de previsão que analisou a sazonalidade e tendência, que permitiram desenvolver um modelo de previsão de demanda com dados confiáveis e reais, demonstrando que o crescimento da demanda será acompanhado pelo crescimento da produção cerâmica.

Morais, Souza e Moraes (2015) estudaram a aderência de quatro modelos de previsão de demanda (média móvel, suavização exponencial, método de Winter e modelo de Croston) ao comportamento intermitente da demanda de um item de estoque por meio do desvio absoluto médio. Utilizaram-se dados de uma importadora de itens mecânicos para a construção e manutenção de máquinas industriais. O modelo de Croston foi o que apresentou o melhor resultado, sendo o mais adequado para a previsão de demanda.

Gomes, Sousa e Piatto (2015) apresentam os principais fatores qualitativos que influenciam a previsão de demanda e sua aplicação em uma indústria do setor de autopeças de uma empresa na área B2B. Identificaram quatro grupos de fatores qualitativos que influenciam a previsão de demanda, dentro de cada grupo o estudo propõe um conjunto de variáveis.

Conforme estudos apresentados, além de verificar a usabilidade em diversos segmentos, que no caso do mercado de alimentos ocorre situações de complexidade, sazonalidade e perecibilidade, o que requer aplicação de um método de previsão mais adequado.

O trabalho desenvolvido nessa pesquisa e que envolve métodos de previsão de demanda tem como ambiente uma empresa de médio porte que atua no segmento alimentício na produção de óleos e gorduras vegetais hidrogenadas refinado. A seguir aborda-se o problema dessa pesquisa.

1.1 Problemática

Atualmente, na empresa estudada, os responsáveis pelo planejamento e controle de produção e os gestores pela área comercial utilizam apenas experiências e dados dos vendedores quanto a pedidos confirmados ou perspectivas de vendas para previsão da demanda.

Conforme Slack et al. (2007), sem uma estimativa da demanda futura não é possível planejar efetivamente para futuros eventos, somente reagir a eles. Diante de um futuro incerto, as previsões consistem em tentativas de obter resultados estimados o mais próximo possível da realidade. Desse modo, surgem os modelos estatísticos de previsão que buscam, no comportamento histórico, respostas para os acontecimentos futuros (WALTER et al., 2013), contribuindo, assim, nas previsões e nos processos de tomada de decisão (PANDEY; SOMANI, 2013).

Com base nestes questionamentos, surge a pergunta que norteará a pesquisa: como melhorar o processo de previsão de demanda de uma empresa do setor de alimentos?

Diante disso, este trabalho buscou encontrar, por meio da aplicação de previsões de demanda baseado em métodos quantitativos, modelos que represente o comportamento dos dados referentes às vendas dos principais produtos do setor de fabricação de óleos e gorduras vegetais analisada, apresentando uma ferramenta para projetar o futuro em curto prazo. A modelagem quantitativa do comportamento da demanda permite previsões mais ajustadas quando comparadas com as previsões baseadas unicamente nas experiências dos gestores.

Por meio dessas ferramentas, os gestores poderão otimizar os estoques de matéria-prima e materiais de consumo, utilizar de forma eficiente a capacidade das máquinas, prever alterações na demanda e sua influência na necessidade de mão de obra, tornando a gestão da organização mais eficaz e competitiva.

1.2 Objetivos da pesquisa

Este trabalho tem como objetivo principal, identificar, analisar e discutir a adequação dos modelos de previsão de demanda envolvendo uma empresa do setor de alimentos a fim de auxiliar os gestores na tomada de decisões, na busca de otimizar os recursos disponíveis na empresa, como forma de aumentar a competitividade da organização, aproveitar as oportunidades e minimizar os riscos inerentes ao mercado de atuação.

E como objetivos específicos:

- a) Selecionar os produtos a serem analisados;
- b) Testar técnicas de previsão demanda;
- c) Discussão da adequação dos modelos de previsão de demanda quantitativo mais adequado.

1.3 Justificativa

O processo de globalização tem pressionado as empresas a buscarem maior competitividade, como forma de sobrevivência no mercado, exigindo decisões eficazes por parte dos gestores. Muitas empresas, precisam enfrentar novos e crescentes critérios para concorrer e garantir a própria sobrevivência. Neste contexto, a previsão de demanda se tornou um dos principais fatores na gestão das empresas, revelando-se como uma alternativa estratégica para lidar com as oscilações da demanda e, assim, evitar prejuízos (MANCUSO; WEBER, 2014).

Para Slack, Chambers e Johnson (2007), conhecer a demanda possibilita que a organização reduza custos e melhore os serviços com a capacidade sendo bem mais utilizada e o lucro potencial melhorado.

Diante disso, a previsão é uma estimativa do que se espera que aconteça no futuro, representando um papel importante nas áreas funcionais da gestão da empresa, ficando intimamente ligado ao planejamento e ao orçamento empresarial (GUPTA, 2013).

Em complemento, Walter et al. (2013) mencionam que a previsão não se trata de um fim em si, mas de um meio capaz de fornecer informações para a tomada de decisões, com base em objetivos específicos.

Dessa forma, a previsão de demanda possibilita o planejamento das diversas áreas da empresa, mediante análise de dados passados ou históricos, podem ser realizadas previsões de demanda de curto prazo, as quais fornecem informações necessárias aos gestores na tomada de decisões.

Modelos de previsão de demanda assumem papéis importantes para teoria e prática, pois para obterem oportunidades de mercado e alcançar demandas de longo prazo, as empresas devem frequentemente ajustar sua capacidade de produção (ZHANG et al., 2012).

Cada vez mais as empresas são desafiadas tanto pela complexidade provocada pela variação de demanda de seus clientes, como pela acirrada concorrência imposta pelo mercado. Assim, faz-se necessário determinar políticas otimizadas de ajuste da capacidade para

equilibrar demanda com a oferta viabilizada pela sua capacidade de produção (LINGITZ et al., 2013; ZHANG et al., 2012).

Portanto, determinar um nível ótimo de capacidade para atender a demanda é fundamental para o desempenho do sistema produtivo, ao passo que o desequilíbrio entre estas pode provocar perdas econômicas para a organização. Assim, o desafio repousa sobre harmonizar o grau de capacidade de produção com o nível de demanda do mercado, visando a maximização dos lucros (HO; FANG, 2013).

Isso é motivado pela importância que estas pesquisas podem proporcionar nos aspectos gerenciais das empresas, como a possibilidade de minimizar os impactos gerados pela complexidade das relações, podendo integrar situações a nível global, referente aos custos operacionais com estoques, vulnerabilidade e possibilidade de interrupção da demanda (FAHIMNIA et al., 2015).

Nesse sentido, Todd, Crook e Lacchoetz (2013), dizem que pesquisas adicionais nesta área devem ser realizadas para melhorar o processo dos resultados e dos controles da empresa. Ampliando a discussão, Librantz et al. (2010), salientam que a exploração de distintas estratégias que permitam avanços nos processos da empresa e em seus controles é uma técnica empregada pelas organizações para alcançar vantagens sobre seus concorrentes.

Este estudo, pretende analisar por meio de modelos apropriado de previsão de demanda, proporcionando ao gestor da empresa atualizar as informações decorrentes de alterações do mercado, sustentar a tomada de decisões pelo uso da ferramenta de previsões e planejar ações nas diversas áreas afetadas, com o objetivo de otimizar recursos e atender aos clientes, melhorar a competitividade da empresa no mercado, que atualmente, não utiliza nenhum método quantitativo de previsão de demanda.

Do ponto de vista profissional, este trabalho representa uma valiosa fonte de informações que deverá direcionar os planos de produção da empresa. E do ponto de vista acadêmico, busca-se discutir e contribuir com o acervo acadêmico, retratando a aplicação de alguns conceitos de maneira prática e próxima daquilo que é a realidade da empresa.

1.4 Classificação metodológica da pesquisa

O presente estudo foi desenvolvido por meio de um levantamento bibliográfico retrospectivo de natureza aplicada, com objetivo descritivo, forma de abordagem quantitativa e adotado como procedimento técnico estudo de caso.

Gil (2010) apresenta como principal vantagem da pesquisa bibliográfica permitir ao investigador a cobertura de fenômenos mais amplos.

Alguns aspectos caracterizam o estudo de caso como uma estratégia de pesquisa: permite o estudo de fenômenos em profundidade dentro de seu contexto; é especialmente adequado ao estudo de processos e explora fenômenos com base em vários ângulos. Conforme Gil (2010), os estudos de caso podem ser constituídos tanto de um único, quanto de múltiplos casos. Justifica-se a utilização de um único caso quando este é singular ou extremo, como, por exemplo, uma empresa que apresenta características peculiares referente à solução de seus conflitos de trabalho ou problemas administrativos peculiares.

O detalhamento da metodologia e os passos adotados para a execução desse trabalho serão apresentados na seção 3 – Metodologia.

1.5 Estrutura do Trabalho

O texto está dividido em 5 seções. Nesta primeira seção, denominada Introdução, foram apresentados os seguintes tópicos da pesquisa: contextualização, objetivo geral, objetivo específico, justificativa, classificação metodológica da pesquisa e estrutura do trabalho.

A seção 2, apresenta a revisão da literatura com relação ao tema e sua importância, padrões, métodos, como escolher um sistema adequado de previsão de demanda. Os métodos qualitativos são descritos e os quantitativos são exemplificados por meio de equações. Essa seção traz ainda os métodos mais usualmente utilizados, relatando os erros de previsão de demanda. E finaliza abordando aspectos de sazonalidade, importante para o ramo alimentício.

A seção 3, apresenta o método utilizado nesse trabalho, assim como as etapas em que se organizou o desenvolvimento do estudo de caso.

Na seção 4, é detalhado cada etapa de desenvolvimento do estudo de caso realizado na empresa do setor de alimentos localizado no interior do estado de São Paulo.

Finalizando a pesquisa na seção 5, apresenta-se as considerações finais e após as referências bibliográficas.

2 PREVISÃO DE DEMANDA

Essa seção tem como objetivo fornecer o suporte teórico para o desenvolvimento dessa pesquisa, portanto, aborda-se o conceito de previsão de demanda, sua importância, os padrões de demanda e os métodos de previsão.

2.1 Previsão de demanda

Há milhares de anos grandes civilizações valiam-se de previsões do futuro como forma de aconselhamento para tomada de decisão, e atualmente volta a ter a importância no plano de gestão e planejamento das organizações, diante dos seus benefícios (RIBEIRO, 2009), tendo em vista que “uma previsão é um prognóstico de eventos futuros, usado para propósito de planejamento.” (KRAJEWSKI; RITZAMN; MALHOTRA, 2009, p. 437).

As atuais condições de negócios, inconstantes decorrente da competição global, das rápidas mudanças tecnológicas e das preocupações ambientais exercem pressão sobre a capacidade de gerar previsões precisas pelas empresas. Sendo que, a previsão da demanda ajuda no processo de desenvolvimento das organizações, coloca-a, quando possuidora de estrutura organizada de previsão da demanda, um passo à frente das demais, e levando-a a um nível competitivo satisfatório (BALLOU, 2006).

Na busca de adequar recursos e estratégias operacionais se faz necessário antever o comportamento do mercado em um horizonte de tempo futuro, requisito este da gestão em qualquer ambiente de negócios, tornando adequada a configuração das demandas dos clientes e da entrega de serviços planejados (GONÇALVES, 2013).

Compreende-se por demanda a disposição dos clientes ao consumo de bens e serviços oferecidos por uma organização. Essa recebe influência de diversos fatores que envolvem desde condições macroeconômicas até questões operacionais conforme a disponibilidade do produto e preço no ponto de venda (MESQUITA, 2008).

As demandas diferenciam-se em duas situações: demanda pontual e demanda repetitiva.

- **Demanda pontual** – ocorre de forma concentrada em determinado tempo e depois diminui significativamente. Com base numa previsão o gestor decide quanto adquirir do produto.
- **Demanda repetitiva** – pode ser classificada como dependente e independente. A demanda dependente está correlacionada com a demanda do produto

acabado, ou seja, refere-se à demanda dos itens componentes do produto final. A independente, é aquela que depende das condições de mercado e que está fora do controle da empresa (MESQUITA, 2008). Portanto, a demanda independente deve ser prevista, enquanto que a dependente deverá ser calculada.

Previsão pode ser definida como uma estimação do valor de uma variável (ou conjunto de variáveis) em algum momento futuro. As previsões são essenciais para adequar recursos em todas as vertentes, que compreendem: dimensionamento de capacidade; cálculo de necessidades de capital de giro; adequação de estoques como meio de suprir compromisso de demanda de clientes, determinação do volume de mão-de-obra necessário para prestação de serviço logísticos de qualidade; e adequação de frotas de veículos para distribuição física ao atendimento dos clientes e do mercado (GONÇALVES, 2013).

A importância da previsão de demanda nesses níveis dentro de uma organização é reconhecida por diversas empresas, pois trata-se de requisitos de importância fundamental para a tomada de decisões periódicas que envolvem seleção de processo, planejamento de capacidade, melhorias de *layout*, e de decisões contínuas sobre planejamento da produção, da programação e do estoque (DAVIS; AQUILANO; CHASE, 2001).

Tubino (2000) apresenta cinco etapas básicas para um processo de previsão:

- 1) **Definição de objetivo do modelo:** corresponde a definição do porquê da previsão;
- 2) **Coleta e análise dos dados históricos:** requer cuidados, ou seja, quanto mais dados coletados e analisados mais confiável será a técnica de previsão; os dados coletados deverão buscar a caracterização da demanda pelos produtos da empresa, que pode diferir das vendas passadas; em caso de variações da demanda, os valores empregados devem ser médios; alertar-se quanto ao período de consolidação dos dados que influenciam na escolha da técnica de previsão;
- 3) **Seleção da técnica de previsão:** requer ponderação no custo e acuracidade. A precisão acompanha o custo, ou seja, quanto mais preciso mais caro, o que torna viável para questões estratégicas gastar mais e correr menos risco, e em caso de questões operacionais a situação se inverte;
- 4) **Obtenção das previsões:** devem ser analisados fatores como disponibilidade de dados históricos; disponibilidade de recursos computacionais; experiência

passada com a aplicação de determinada técnica; disponibilidade de tempo para coletar, analisar e preparar os dados e a previsão; período de planejamento para o qual necessitamos da previsão;

- 5) Monitoramento do modelo:** requer monitoramento da extensão do erro entre a demanda real e a prevista, como meio de verificação se a técnica e os parâmetros empregados continuam válidos. Em casos críticos se faz necessário um novo exame dos dados e escolha de nova técnica de previsão.

Para Martins e Laugeni (2005, p. 226) previsão de demanda constitui-se de um processo metodológico para determinar dados futuros baseando-se em “[...] modelos matemáticos ou econométricos ou ainda em modelos subjetivos apoiados em uma metodologia de trabalho clara e previamente definida.” Queiroz, Cavalheiro e Vieira (2003) alertam que a previsão, a qual definem como ferramenta de auxílio à decisão, não substitui o parecer de analistas, que está sujeito a acontecimentos políticos, econômicos e ou sociais que podem influenciar o comportamento dos consumidores.

Por tratar-se de uma visão antecipada de possíveis ocorrências de fatos ou situações também é passível de imperfeições, que estão respaldadas em dois fatores distintos: o primeiro envolve a qualidade do modelo a ser adotado. Isso porque qualquer modelo reflete estimativas baseadas e premissas. O segundo relaciona-se ao mundo real, envolvendo o mercado reinante (GONÇALVES, 2013).

Sobre as imperfeições, Baco, Paiva e Lima (2006, p. 5) alertam sobre a importância da determinação dos erros e, dado a essa importância tornam-se associados a própria previsão, “são erros que validam e que dizem o quão razoável é a previsão.” O erro constitui-se da diferença entre um valor conhecido, real e um valor previsto e, quando de seu aumento prediz imperfeições ou alerta sobre o modelo de previsão não estar sendo usado adequadamente, ou ele deixou de ser válido.

Os autores mencionam duas maneiras de se abordar uma previsão: a abordagem *Top-Down* e a abordagem *Botton-Up*, cada uma com suas características, vantagens e desvantagens.

A abordagem *Top-Down* consiste em fazer uma previsão de vendas de um produto a nível nacional e então derivar essas previsões para um nível regional, usando como base de rateio as vendas históricas dessas regiões. Muito adequada para produtos de demanda estável ou de variação uniforme.

Abordagem *Botton-UP* consiste em fazer várias previsões a nível regional, separadamente, e depois compor uma previsão nacional com essas bases. Possibilita descobrir níveis de demanda em segmentos de mercados específicos, porém demanda um sistema de armazenamento e recuperação de dados muito competente,

em que a inclusão de fatores não sistemáticos sempre é difícil. (BACO; PAIVA; LIMA, 2006, p. 5)

2.1.1 Importância da previsão de demanda

Crum e Palmatier (2003), Arnold (2006) e Barbosa e Chaves (2014) alertaram sobre a importância do gerenciamento da demanda na competitividade do sistema produtivo, conduzindo questões do tipo, quanto, quando e o que deve-se produzir, direcionando para melhorias de técnicas de previsão e posicionando a empresa em relação às incertezas futuras.

Bean (1994) identificou que o gerenciamento da cadeia de demanda possibilita a redução do desemprego, levando ao aumento da riqueza da nação.

Conforme Krajewski, Ritzamnn e Malhotra (2009) normalmente a previsão de demanda total procede do departamento de marketing, isso porque está mais próximo dos clientes externos, no entanto, os clientes de toda a organização também são dependentes de previsões para formularem e executarem seus planos, pois constituem-se de informações críticas para planos de negócios, planos anuais e orçamentários.

Assim, a importância da previsão de demanda reside em desempenhar seu papel em diversas áreas na gestão de organizações, a saber, área financeira, para projetar fluxos de caixas e requisitos capitais, quando do planejamento da necessidade de recursos; área de recursos humanos, quando do planejamento de alteração no nível de força de trabalho; e, área de vendas, quando do agendamento de promoções. As previsões são requeridas também na operacionalização de vários aspectos de gerenciamento da produção, isso é, na gestão de estoques e no desenvolvimento de planos agregados de produção (PELLEGRINI; FLOGLIATTO, 2001).

Ballou (2006) defende ser a previsão dos níveis de demanda como de extrema importância para a organização num todo, já que proporciona a entrada básica para o planejamento e controle das diversas áreas funcionais. Para o autor, os volumes de demanda e o momento em que ocorrem interferem nos índices de capacidade, nas necessidades financeiras e na estrutura geral de negócio, seja ele qual for.

Conforme relacionam Heizer e Render (1996) as previsões auxiliam na produção, na capacidade e nos sistemas de programação da empresa além de servirem como informações para o planejamento financeiro, de marketing e de pessoal. Complementando, Miyata (2014) diz que constitui-se na única estimativa da demanda até que a demanda real se torne conhecida.

2.1.2 Padrões de demanda

A tarefa de prever a demanda por vezes torna-se um desafio diante da variação que ocorre da demanda por serviços e bens, ainda que por vezes os padrões possam ser mais previsíveis. A previsão de demanda em alguns casos requer descobrir os padrões subjacentes das informações disponíveis (KRAJEWSKI; RITZAMN; MALHOTRA, 2009).

Os padrões são formados por ocorrências repetidas coletadas mediante observações de demanda para um serviço ou produto, e são denominados de séries temporais. São cinco os padrões básicos da maioria das séries temporais de demanda:

- **Horizontal** – dá-se quando da flutuação de dados em torno de uma média constante;
- **Tendencial** – ocorre quando do aumento ou redução sistemática na média das séries ao longo do prazo;
- **Sazonal** – quando da ocorrência de aumento ou redução na demanda respeitando possível repetição, que depende de hora, dia, semana, mês ou estação;
- **Cíclico** – corresponde a aumentos ou reduções graduais menos previsíveis na demanda por prazos mais longos de tempo, podendo ser anos ou décadas. Esse padrão demanda de duas influências: ciclo econômico – propenso a variações extremas, como por exemplo se a economia passar de uma recessão à uma expansão ao longo de vários anos; ciclo de vida do serviço ou produto - que reflete as fases da demanda do crescimento ou declínio. Ambos os ciclos compreendem graus de dificuldade de prever, pois, no caso do econômico, é afetado por eventos nacionais ou internacionais (eleições presidenciais, distúrbios políticos, etc), no caso do ciclo de vida, por estar atrelado algumas vezes a previsão com base na história da demanda de um produto, para lançamento de um novo ou substituto;
- **Aleatório** – compreende a variação imprevisível da demanda. Resulta de causas eventuais, o que impede sua previsão. Essa variável aleatória constitui-se de um aspecto que tende a tonar todas as previsões incorretas.

Os quatro primeiros padrões de demanda citados se combinam em graus variados para definição do padrão de tempo fundamental de demanda para um produto ou serviço.

Poli (2014) ao descrever os modelos de séries históricas e média móvel, simplificando, traz que a demanda é frequentemente dividida entre quatro componentes. Esses componentes são descritos por Chopra e Meindl (2011) e por Taylor (2005), sendo que os três primeiros componentes descritos são sistemáticos, ou seja, possuem um comportamento que pode ser previsto:

- Componente de nível: o qual corresponde à demanda atual;
- Componente sazonal: diz respeito ao efeito da variação periódica da demanda;
- Componente de tendência: corresponde ao resultado da dinâmica reconhecível de crescimento ou decréscimo da demanda;
- Componente aleatório: não passível de previsão.

2.1.3 Métodos de previsão de demanda

Poli (2014) informa sobre a existência de uma variedade de métodos para realizar estimativas de demanda, cabendo ao gestor e a equipe técnica a escolha do mais conveniente. O quadro 1 apresenta a classificação dos Métodos para Classificação da Demanda.

Quadro 1 - Classificação dos Métodos para Classificação da Demanda

Julgamento	Informacional	Séries Temporais	Causais
<ul style="list-style-type: none"> • Analogia Histórica • Extrapolação direta • Delphi • Cenários • Workshop de experts 	<ul style="list-style-type: none"> • Dados secundários • Pesquisa de mercado 	<ul style="list-style-type: none"> • Média móvel • Extrapolação de tendências • Decomposição de componentes • ARIMA 	<ul style="list-style-type: none"> • Correlação • Regressão • Econometria • Autoregressão

Fonte: Poli (2014, p. 44).

Para Queiroz, Cavalheiro e Vieira (2003) os métodos de previsão podem ser classificados com base em diversos critérios, mas a mais comum das classificações leva em consideração o tipo de abordagem utilizada para previsão, isso é, o tipo de instrumento e conceitos que formam a base da previsão (QUEIROZ, CAVALHEIRO; VIEIRA, 2003).

Corroborando com Gonçalves (2013), Pellegrini e Flogliatto (2001); Queiroz e Cavalheiro (2003) informam que as previsões de demanda são elaboradas utilizando além dos métodos quantitativos e qualitativos, também a combinação de ambos. No entanto, Poli (2014) informa que essa divisão entre métodos qualitativos e quantitativos não se faz

absoluta, e justifica esse parecer, pois, os primeiros podem usar como apoio informações quantitativas e os segundos podem requerer julgamentos como, o nível de precisão buscado ou variáveis a serem consideradas.

2.1.4 Escolha do sistema de previsão de demanda

A escolha do sistema de previsão deve ser decorrente de análises dos problemas de gerenciamento de operações. Assim, são três as decisões a serem tomadas antes da escolha: o que prever; qual a técnica de previsão usar; e qual o *software* usar (KRAJEWSKI; RITZAMN; MALHOTRA, 2009). A seguir essas decisões são detalhadas.

Com relação ao que prever, observa-se a demanda total para grupo ou agrupamentos e em seguida prever serviços ou produtos individualmente é um caminho mais fácil. Sendo que selecionar a unidade correta de medida (unidade de produtos ou serviços ou horas máquina) para fazer as previsões é tão importante quanto a escolha do método a ser empregado.

Os erros de previsão para produtos individuais podem ser maiores que os previstos em demanda total. Quando as empresas utilizam-se do processo “agregação” estão passíveis de maior precisão. Ocorre que muitas empresas valem-se de sistemas de dois níveis, primeiro preveem com base nas famílias de serviços ou bens com requisitos de demanda semelhantes e de processamento, trabalho e materiais comuns, para então partir para previsões para produtos individuais, os *Stock-Keeping Unit* (SKUs) ou unidade em estoque apropriada. A abordagem em dois níveis mantém a coerência entre planejamento nas fases finais da fabricação (requerendo previsão de unidade) e de longo prazo para vendas, lucro e capacidade (requerendo previsão de famílias de produto). O quadro 2 demonstra exemplos de aplicação de previsão de demanda e o horizonte de planejamento de cada uma.

Quadro 2 – Aplicação de previsão de demanda

Horizonte de tempo			
Aplicação	Curto prazo (0 a 3 meses)	Médio prazo (3 meses a 2 anos)	Longo prazo (mais de 2 anos)
Quantidade prevista	Serviços ou produtos individuais	Vendas totais Grupos ou famílias de serviços ou produtos	Vendas totais
Área de decisão	Administração de estoques Programação de montagem final Programação da força de trabalho Programação mestre da	Planejamento de pessoal Planejamento de produção Programação mestre de produção Compra Distribuição	Localização de instalação Planejamento de capacidade Administração de processo

	produção		
Técnica de previsão	Séries temporais Causal	Causal Avaliação	Causal Avaliação

Fonte: Krajewski, Ritzamn e Malhotra (2009, p. 439).

Os *Skus* são indicados como unidade inicial de medida, tendo em vista que as previsões mais úteis para planejar e analisar problemas de operações iniciam-se com unidade de serviço, produto, pacotes expressos a despachar para entrega ou clientes requerendo serviços de manutenção ou consertos por exemplo. “Prever o número de unidade de demanda, em seguida converter essa estimativa em estimativas de receita de vendas multiplicando-as pelo preço” mostra ser o melhor método. (KRAJEWSKI; RITZAMN; MALHOTRA, 2009, p. 437). Conforme os autores é possível prever horas máquina ou horas de trabalho padrão requeridas de cada um dos recursos críticos, se empregado padrões históricos o sucesso será mais garantido.

Com relação à escolha da técnica de previsão, observa-se que o intuito de um especialista é o de desenvolver uma previsão útil com base nas informações disponíveis, valendo-se da técnica mais apropriada conforme o padrão de demanda requer. São dois os tipos de técnicas de previsão para prever uma demanda: **métodos qualitativos** (vale-se de pesquisas, opiniões e estimativas de força de venda convertendo-as em estimativas quantitativas) e **métodos quantitativos** (vale-se de dados históricos sobre variáveis independentes, propagandas, condições econômicas e ações de concorrentes para prever), métodos de previsão (KRAJEWSKI; RITZAMN; MALHOTRA, 2009), estes serão tratados no próximo item. Conforme Pelleggrini e Fogliatto (2001) a elaboração de um sistema quantitativo requer conhecimentos e habilidades em 4 áreas básicas: na aplicação dos métodos; dos procedimentos para a seleção do método mais adequado; na aplicação; e suporte organizacional para adaptação e uso dos métodos requeridos.

Deve-se levar em conta para a escolha da abordagem da técnica o horizonte de tempo que a decisão requer para previsão que variam de curto, médio ou longo prazos. Há também o envolvimento entre custos e precisão da previsão que diz respeito ao custo de *software*, tempo requerido para formulação da previsão e treinamento a ser despendido ao pessoal (KRAJEWSKI; RITZAMN; MALHOTRA, 2009).

Quanto à escolha do *software*, observa-se que quando a empresa necessita preparar previsão para centenas ou milhares de produtos ou serviços repetidamente, os computadores

são uma necessidade. O *software* facilita a trabalho de coordenar as previsões entre fornecedores e varejistas.

Geralmente pacotes de *software* podem ler entradas de dados de arquivos de planilha eletrônica, traçar gráficos de dados e previsão além de outros recursos.

2.1.5 Controle do modelo de previsão de demanda

Selecionado o modelo de previsão que melhor se ajusta aos dados, este é utilizado para prever os valores dos próximos períodos. É importante garantir periodicamente que o modelo selecionado continue a representar a demanda de vendas, portanto, é fundamental que utilizem ferramentas para acompanhar o modelo selecionado. As duas ferramentas para controle do modelo de previsão escolhidos foi baseado nos autores Martins; Laugeni (2005), Davis; Aquiliano; Chase (2001), e são os seguintes:

- a) **Sinal de Acompanhamento:** é a medição que indica se a média prevista está mantendo-se com qualquer mudança ascendente ou descendente da demanda. Pode ser definido como o número de desvios médios absolutos, nos quais o valor previsto está acima ou abaixo da ocorrência real (DAVIS; AQUILANO; CHASE, 2001).

Em um modelo de previsão de demanda perfeito, a soma dos erros de previsão real seria zero, isto é, o sinal de acompanhamento também seria zero, indicando um modelo não distorcido, nem acima e nem abaixo da demanda real (DAVIS; AQUILANO; CHASE, 2001).

$$SA = \frac{SAE}{DAM} \quad (1)$$

Onde:

SA : sinal de acompanhamento, monitoramento ou rastreamento;

SAE : soma acumulada dos erros;

DAM : desvio absoluto médio.

- b) **Sinal de Trigg:** procura corrigir a distorção causada pelo sinal de acompanhamento, pois este deve ser calculado para cada período, de forma a evitar que os desvios acumulados cresçam demasiadamente, caso o modelo selecionado não mais seja adequado. Assim, o desvio absoluto médio pode ser

continuamente atualizado, usando uma técnica de media exponencial (MARTINS; LAUGENI, 2005; DAVIS; AQUILANO; CHASE, 2001):

$$TST_t = \frac{EAM_t}{DAM_t} \quad (2)$$

Onde:

TST_t : sinal de Trigg;

EAM_t : erro médio exponencial no período t ;

DAM_t : desvio absoluto médio no período t .

2.1.6 Custo de previsão de demanda

Ao aplicar mais recursos financeiros para a previsão, pela utilização de métodos mais complexos e caros, atinge-se maior acurácia na previsão. Isso acarreta maior certeza na tomada de decisão do gestor da empresa.

Por outro lado, se forem utilizados modelos muito sofisticados, cuja compreensão se restringe a especialistas, os recursos financeiros adicionais aplicados para melhorar a acurácia do modelo de previsão podem não trazer retorno à empresa, ou seja, o custo para melhorar a previsão pode não se justificar economicamente.

Dentre os custos a que se implica com uma previsão de vendas de acurácia baixa, podem ser citados: o custo de estoque de produto fabricado em quantidade superior à necessária, custo do não atendimento do cliente por falta de produto fabricado, alto nível de estoque e compras de emergência, gerando maior custo de transporte (FLEURY; WANKE; FIGUEIREDO, 2003).

2.2 Métodos de previsão de demanda

2.2.1 Métodos Qualitativos

Chopra e Meindl (2011, p. 178) afirmam que os métodos de previsão qualitativos são essencialmente subjetivos e contam com o uso de informações de especialistas para definir o julgamento da demanda futura. Farias et al., justificam essa afirmativa expondo que os

métodos qualitativos apoiam-se no julgamento e na opinião de especialistas para fazer a previsão. São mais apropriados quando existem poucos dados históricos disponíveis ou quando os especialistas têm inteligência de mercado, crucial para a realização das previsões.

Conforme Queiroz e Cavalheiro (2003) os métodos qualitativos fundamentam-se em opiniões de especialistas, sendo vulneráveis a tendências que podem comprometer a confiabilidade de seus resultados.

Krajewski, Ritzamn e Malhotra (2009) descrevem quatro métodos qualitativos: 1- estimativa de força de vendas; 2 – júri de executivos; 3 – pesquisa de mercado; e 4 – método Delphi. Farias, Nogueira Neto e Nogueira (2006) e Rosseto et al. (2011) também destacam alguns métodos qualitativos.

▪ **Pesquisa de equipe de vendas**

A pesquisa de equipe de vendas, envolve estimativas de vendas regionais futuras que são combinadas formando uma estimativa de vendas única para toda região, a ser transformada pelos executivos em uma previsão de vendas assegurando estimativas reais (FARIAS; NOGUEIRA NETO; NOGUEIRA, 2006). Krajewski, Ritzamn e Malhotra (2009) ressaltam como vantagens dessa abordagem:

- O conhecimento da força de vendas sobre quais e quanto serviços e produtos poderão ser adquiridos pelos clientes no futuro próximo;
- As informações provindas de áreas ou regiões que formam as áreas de vendas podem ser úteis na administração dos estoques, distribuição e preenchimento de vagas para a força de vendas; e,
- As informações individuais de membros da força de vendas podem ser combinadas para uma previsão regional ou nacional.

Entretanto, algumas desvantagens se relacionam:

- Inclinações individuais da equipe podem influenciar demais membros da equipe;
- Falta de percepção pela equipe de vendas quanto ao que o cliente quer (desejos) e o que ele precisa (necessidades);
- Quando a empresa utiliza das vendas individuais para mensurar o desempenho, pode ocorrer menosprezo pela equipe nas suas previsões de forma que seu desempenho pareça satisfatório quando superar suas projeções, ou ainda dispensar esforços apenas para alcançar as vendas mínimas requeridas (KRAJEWSKI; RITZAMN; MALHOTRA, 2009).

- **Consenso do comitê executivo**

No método consenso de comitê executivo, executivos de diversos departamentos unidos de discernimento juntam-se formando um comitê responsável para desenvolver uma previsão de vendas (FARIAS; NOGUEIRA NETO; NOGUEIRA, 2006). De acordo com Krajewski, Ritzamn e Malhotra (2009) o conhecimento técnico e experiência desses membros juntam-se para levar a uma única previsão, podendo também modificar uma previsão já existente ou mesmo para levar em conta circunstâncias incomuns (eventos internacionais inesperados, nova promoção de vendas, etc). O importante é que haja um consenso entre os membros sobre uma única previsão.

- **Pesquisa de mercado**

A técnica busca identificar os desejos e necessidades dos consumidores, tendo em vista serem eles a determinarem a demanda (ROSSETTO et al., 2011). Na pesquisa de mercado, questionários, entrevistas (de campo ou telefônicas) formam base para suposição de mercados atuais (FARIAS; NOGUEIRA NETO; NOGUEIRA, 2006). Conforme Rossetto et al. (2011), a pesquisa de mercado requer um conhecimento técnico especializado além de exigir cuidado no planejamento, pois é necessário que se monte a estrutura de pesquisa, estabeleçam-se os instrumentos de coleta de dados, crie-se um plano de execução e interpretem-se os resultados de maneira precisa.

- **Método Delphi**

O Método Delphi é um meio para alcançar o consenso dentro do comitê, possibilitando obter uma previsão que seja de acordo com a maioria dos participantes (FARIAS; NOGUEIRA NETO; NOGUEIRA, 2006). É uma forma de previsão útil quando não se dispõe de dados históricos ou quando falta experiência dos gerentes para fundamentar as projeções.

O método Delphi é descrito por Krajewski, Ritzamn e Malhotra (2009, p. 441),

Um coordenador envia perguntas para cada membro do grupo de especialista externos, que podem nem mesmo saber quem mais está participando. O coordenador prepara um resumo estatístico das respostas específicas. O relatório é enviado ao mesmo grupo para outra rodada e os participantes podem escolher modificar suas respostas anteriores. Essas rodadas continuam até que seja obtido um consenso.

Os autores ressaltam que esse método pode ser empregado na formulação de visões de longo alcance de demanda de projeto e projeções de vendas de novos, ou mesmo para previsões tecnológicas.

- **Analogia histórica**

A analogia histórica quer dizer, semelhança, afinidade e relação (ROSSETTO et al., 2011). Conforme Farias, Nogueira Neto e Nogueira (2006) vale-se de vendas já efetuadas de um produto durante etapas do seu ciclo de vida para estimar vendas de produtos similares, podendo mostrar-se útil na previsão de vendas de novos produtos. Rossetto et al. (2011) acrescenta que esse modelo é mais comumente utilizado para lançamentos de novos produtos, já que visa comparar os produtos que pretende prever com um similar, compreendendo que a demanda do produto em questão será similar à do produto que já está no mercado, portanto esse método é importante para planejar um novo, já que a previsão é feita para este novo produto com base na trajetória do similar.

- **Pesquisa de clientes**

A pesquisa de clientes ocorre individualmente para identificar a quantidade de produtos da empresa têm a pretensão de comprar futuramente (FARIAS; NOGUEIRA NETO; NOGUEIRA, 2006).

2.2.2 Métodos Quantitativos

Makridakis, Wheelwright e Hyndman (1998), Pellegrini e Fogliato (2001), Queiroz e Cavalheiro (2003) denominam os métodos quantitativos de métodos de *forecasting*,¹ por terem como base a análise de séries temporais (dados que descrevem a variação da demanda ao longo do tempo).

Para os autores, por meio dessa técnica pode-se extrair dos dados passados sobre um processo de demanda, informações permitindo a modelagem matemática de seu comportamento. A suposição de uma continuidade nesse comportamento permite a realização de previsões, cuja qualidade e precisão são muito superiores àquelas das previsões feitas

¹ “Na visão adotada pela APICS (2008; 2012), *forecast management* refere-se à administração do processo de previsões e inclui elaboração, verificação, correção, utilização, determinação do horizonte e nível de agregação; *forecasting* é o processo de realizar previsões e inclui as ferramentas, as técnicas e os métodos de previsões; e o termo *forecast* é definido como a estimativa projetada da demanda futura.” (BARBOSA, CHAVES, 2014, p. 106).

intuitivamente. (PELLEGRINI; FOGLIATO, 2001; QUEIROZ; CAVALHEIRO, 2003). Quando atualizados, os modelos passam a refletir as alterações do processo, possibilitando novas tomadas de decisão (PELLEGRINI; FOGLIATTO, 2001).

Jacob e Costa (2011), Pellegrini e Fogliatto (2001) corroboram com Makridakis, Wheelwright e Hyndman (1998) quando do alerta sobre três condições para a aplicabilidade de um sistema quantitativo, a saber: disponibilidade de informações históricas; possibilidade da transformação das informações históricas em dados numéricos; e suposição da repetição de padrões observados em dados passados no tempo futuro.

Quando se trata de novos produtos ou quando se espera que a tecnologia mude, os arquivos históricos podem ser inexistentes, ou ainda podem existir, mas não serem tão úteis quanto certos eventos (lançamentos ou pacotes especiais) que são refletidos nos dados anteriores ou quando da espera de eventos futuros (KRAJEWSKI; RITZAMN; MALHOTRA, 2009). Os autores ressaltam que em alguns casos os métodos quantitativos de avaliação são as únicas formas de fazer uma previsão, enquanto que em outros podem ser usados para modificar previsões geradas pelos métodos qualitativos, buscando prever eventos específicos. Também podem ser empregados para ajustar arquivos de dados históricos a serem analisados com método quantitativos visando reduzir o impacto de eventos específicos do passado.

Quanto aos modelos de previsão quantitativos ou de projeção histórica, Queiroz e Cavalheiro (2003), relacionam que a lógica dos métodos é determinada e as operações são matemáticas, e juntamente com Farias, Nogueira Neto e Nogueira (2006) descrevem os modelos clássicos mais utilizados: modelos de séries temporais e os modelos causais.

2.2.2.1 Séries temporais ou de projeção histórica

Modelos de séries temporais computam vários dados históricos de demanda e os usam para prever uma demanda futura que geralmente é usada em previsões com curto horizonte de tempo (BACO; PAIVA; LIMA, 2006).

Os métodos de previsão estatística, em sua maioria tem como base a utilização dos dados históricos a partir de uma série de tempo ou série temporal. “Uma série temporal é um conjunto de valores observados em momentos distintos e sequencialmente ordenados no tempo” (CASTANHEIRA, 2013, p. 138).

Matematicamente uma série temporal pode ser representada por:

$$Y = F(t) \quad (3)$$

Onde:

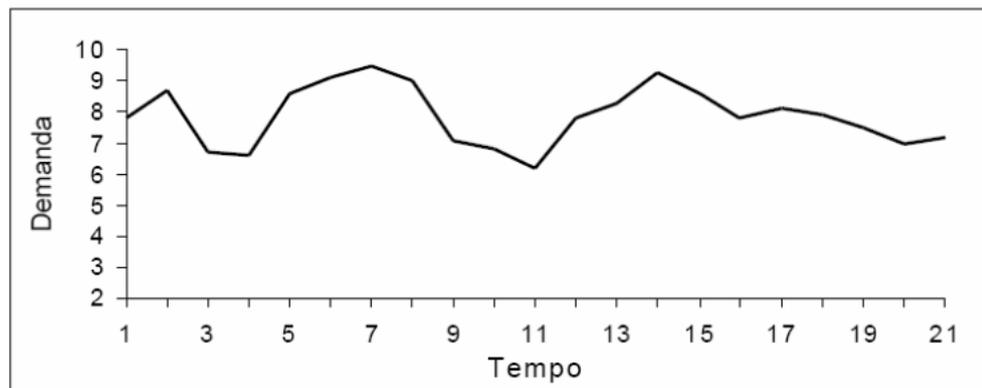
Y : Variável dependente em estudo;

F : Método que relaciona o valor de Y com a data de referência;

t : data de referência.

Levine, Berenson e Stephan (2000) afirmam que uma “série temporal é um conjunto de elementos numéricos obtidos durante períodos regulares ao decorrer do tempo”, como representado no exemplo na figura 1.

Figura 1 – Exemplo série temporal



Fonte: Levine, Berenson e Stephan (2000, p. 630)

Graficamente, série temporal é representada por um gráfico de linha no qual o eixo horizontal (eixo x) refere-se ao tempo e o eixo y (vertical) corresponde a variável (CASTANHEIRA, 2013).

Na análise da série temporal identificam-se fatores influenciadores de valores da série tendo como componentes básicos: tendência secular (T); variações sazonais (S); flutuações cíclicas (C); e variações aleatórias ou irregulares (I) (CASTANHEIRA, 2013).

Determinar a magnitude dos componentes usando esse conhecimento para o propósito da revisão é o objetivo da análise de séries temporais (QUEIROZ; CAVALHEIRO; VIEIRA, 2003). Sendo que, os métodos temporais se valem de informações históricas a respeito apenas da variável dependente. Baseiam-se na suposição que o padrão anterior da variável dependente continuará ocorrendo. “A análise de série temporal identifica os padrões de

demanda subjacentes que se combina para gerar um padrão histórico observado da variável dependente e, em seguida, desenvolve um modelo para replicá-lo.” (KRAJEWSKI; RITZAMN; MALHOTRA, 2009, p. 442).

Gonçalves (2004) descreve que o método quantitativo se vale de técnicas para elaboração da previsão.

Ritzman e Krajewski (2004) fazem um alerta quanto a importância da escolha do tipo de técnica a ser empregada, tendo em vista a necessidade de se optar entre precisão e custos de previsão. O que se requer é desenvolver uma técnica de previsão adequada para as diferentes características de demanda. Outro fator importante quando da escolha da técnica é o horizonte de tempo, isto é, se as projeções são de curto, médio ou longo prazo.

2.2.2.2 Métodos causais ou multivariáveis

Modelos causais procuram relacionar a demanda com algum fator fundamental ou de meio ambiente e, através de causa-efeito, poder prever a demanda de acordo com o comportamento desse fator fundamental. Geralmente é usada em previsões para grandes horizontes de tempo (BACO; PAIVA; LIMA, 2006).

Os métodos de previsão causais estudam a correlação entre uma variável de resposta e outras variáveis independentes (BALLOU, 2006), procuram determinar a demanda a partir da relação de variáveis como renda, crescimento do PIB, etc. (POLI, 2014). Buscam estabelecer uma relação entre a demanda e fatores conjunturais e/ou externos.

Emprega-se os métodos causais quando há disponibilidade de dados históricos e as relações entre o fator a ser previsto e outros fatores externos ou internos são passíveis de identificação. As relações expressam-se em termos matemáticos e por vezes são complexas. Os métodos causais constituem as ferramentas de previsão sofisticadas e são eficientes para prever pontos de inflexão na demanda e na preparação de previsão a um longo prazo (RITZAM; KRAJEWSKI, 2004).

Os principais métodos causais são: Regressão Linear Simples²; Regressão Múltipla e Métodos Econométricos (BALLOU, 2006).

Análise de regressão: assemelha-se ao método dos mínimos quadrados das séries temporais, podendo apresentar múltiplas variáveis (FARIAS; NOGUEIRA NETO;

² “A regressão linear é utilizada tanto para previsões de séries temporais como para previsões baseadas em relacionamentos causais. Se a variável dependente altera-se em função do tempo, refere-se à análise de séries temporais. Se a variável dependente muda devido a alterações ocorridas em outra variável independente, então trata-se de um relacionamento causal.” (YOKOYAMA; TAKEDA, 2014, p. 4).

NOGUEIRA, 2006). Ocorre um relacionamento entre a variável dependente com uma ou mais variáveis dependentes por meio de uma equação linear (RITZAM; KRAJEWSKI, 2004).

No **modelo de regressão linear simples**, a variável dependente é função de somente uma variável independente, o que torna a relação teórica uma linha reta, onde:

$$y_i = \beta_0 + \beta_1 x_i + \varepsilon_i \quad (4)$$

Onde:

y_i : variável dependente;

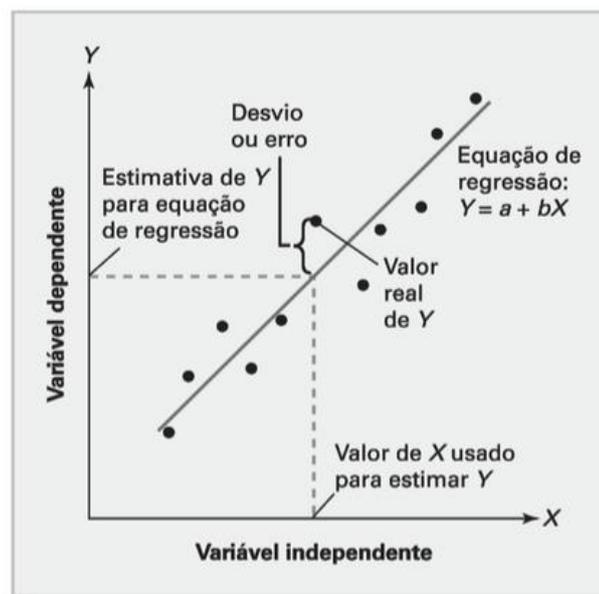
x_i : variável independente;

β_0 e β_1 : coeficientes de regressão;

ε_i : erros aleatórios.

A linha de linear está relacionada com os dados e tecnicamente a linha de regressão minimiza o quadrado das diferenças com os dados reais, como indicado na figura 2:

Figura 2 - Linha de regressão linear em relação aos dados reais



Fonte: Ritzam e Krajewski (2004, p. 267)

A análise de regressão linear tem como objetivo determinar os valores de a e b que minimizem a soma dos quadrados dos desvios dos dados reais em relação a linha. Os programas de computadores têm essa finalidade, que para qualquer conjunto de informações Y

e X , calcula os valores de a e b fornecendo medidas da previsão dos dados previstos. Comumente indica-se três medidas: o coeficiente de correlação da amostra, o coeficiente de determinação da amostra e o erro-padrão da estimativa, são indicadores da qualidade da regressão (RITZAM; KRAJEWSKI, 2004).

O **método de regressão múltipla** apresenta uma hipótese que relaciona uma variável dependente com diferentes variáveis independentes. Definida a hipótese do método, o próximo passo é obter dados para cada variável independente, de preferência uma série temporal para cada variável. Para elaboração do modelo de regressão será necessário relacionar uma lista de variáveis que influenciam Y . A lista inicial de variáveis independentes é organizada na experiência de especialistas, na disponibilidade dos dados e em restrições de tempo e custo. Constantemente uma combinação de procedimentos é utilizada para obter a lista final de variáveis explanatórias (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998).

A forma funcional do modelo de regressão é gradativamente desenvolvida em conjunto com o desenvolvimento da lista de variáveis e finalmente os parâmetros do modelo são estimados usando dados coletados para este propósito (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998). O modelo de regressão linear múltipla descreve uma variável dependente como função de várias variáveis independentes. A equação do modelo é dada por:

$$Y_i = \beta_0 + \beta_1 X_{1,i} + \beta_2 X_{2,i} + \dots + \beta_k X_{k,i} + e_i \quad (5)$$

Onde:

Y_i : variável dependente;

X_i : variáveis independentes;

β_i : coeficientes de regressão;

ϵ_i : erros aleatórios.

Entendendo as vantagens e desvantagens do método de Análise de Regressão pode-se direcionar melhor sua aplicação a situações em que o método é mais útil: previsões em nível corporativo; previsões de médio e longo prazo; e para situações nas quais grandes quantidades

de informações sobre variáveis causais estão disponíveis (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998).

Os métodos quantitativos representem baixo grau de precisão, ainda assim têm sido os mais utilizados na previsão de demanda, que na justificativa de Pellegrini e Fogliatto (2001) relaciona-se ao fato de as previsões por eles geradas corresponderem às metas de demanda estabelecidas pelas empresas. No entanto, a vulnerabilidade decorrente da escassa fundamentação prática dessas previsões, pode explicar, em grande parte, a baixa precisão dos resultados oferecidos pelos métodos qualitativos.

2.3 Métodos básicos de previsão de demanda

A literatura apresenta dezenas de métodos para cálculo (dos mais simples aos mais complexos), porém, os métodos simples têm mostrado resultados tão bons quanto os mais complexos, isso porque, a complexidade dos modelos de previsão não diminui a margem de erro (MAKRIDAKIS; HOGART, 1981).

Os métodos mais utilizados, segundo Ribeiro (2009) são: Média Simples, Média Móvel, Média Móvel Dupla, Amortecimento Exponencial Simples, Amortecimento Exponencial Duplo (Modelo De Brown), Amortecimento Exponencial - Método De Holt, Amortecimento Exponencial – Modelo de Winters, Modelos ARIMA (modelo de média móvel integrada autorregressiva) de BOX e JENKINS (Modelo Autorregressivo (AR); Modelo de Médias Móveis (MA); Modelos Autorregressivos de Médias Móveis (ARMA); Identificação; Modelos Sazonais).

Inicialmente, considera-se um modelo bem simples de séries temporais dado por médias móveis para ser usado em previsão (ver por exemplo, MORETTIN e TOLOI, 1987). O modelo de médias móveis considera uma série temporal Z_1, Z_2, \dots, Z_n , estacionária e localmente constante, composta de seu nível e um ruído adicional definido por,

$$Z_t = \mu_t + a_t \quad (06)$$

onde $t = 1, 2, \dots, n$; $E(a_t) = 0$; $\text{var}(a_t) = \sigma_a^2$ e μ_t é um parâmetro desconhecido que varia com o tempo. A técnica de média móvel consiste em calcular a média aritmética das k observações mais recentes, ou seja,

$$M_t = (Z_t + Z_{t-1} + \dots + Z_{t+k-1})/k \quad (07)$$

O comprimento da média é dado por k . Assim, M_t é uma estimativa de μ_t que não leva em consideração as observações mais antigas, somente as últimas k observações onde a cada período a observação mais antiga é substituída pela mais recente, calculando-se uma média nova.

A previsão dos h valores futuros é dada pela última média móvel calculada, isto é,

$$\hat{Z}_t(h) = M_t \quad (08)$$

ou,

$$\hat{Z}_t(h) = \hat{Z}_{t-1}(h+1) + (Z_t - Z_{t-k})/k \quad (09)$$

para todo $h > 0$. Observa-se que a equação acima corrige a previsão de Z_{t+h} a cada instante, ou seja, a cada nova observação na série, Z_{t+h} é atualizado.

Assumindo que os ruídos a_t tem uma distribuição normal com média igual à zero e variância igual à σ_a^2 , implica que a previsão $\hat{Z}_t(h)$ tem uma distribuição normal com média igual à μ_t e variância igual à σ_a^2/k . Portanto, um intervalo de confiança para μ_t com coeficiente de confiança igual à $100(1-\alpha)\%$ é dado por,

$$(\hat{Z}_t(h) - z_{\alpha/2}\sigma_a/\sqrt{k} ; \hat{Z}_t(h) + z_{\alpha/2}\sigma_a/\sqrt{k}) \quad (10)$$

onde $z_{\alpha/2}$ é o quantil de uma distribuição normal padrão.

Consul e Werner (2010) relatam que como um meio de aumentar a acurácia das previsões realizadas, surgiu a combinação de previsões. Assim, ocorre a possibilidade de identificar diversos modelos que contribuam para a previsão desejada, combinando os resultados obtidos, ajustando os métodos adequadamente e buscando diminuir os erros de previsões.

Consul e Werner (2010, p. 4) corroboram com Armstrong (2001) ao afirmarem que “A combinação de previsões é vantajosa em situações como de incerteza sobre qual método pode projetar os valores da série de forma mais precisa, ou ainda quando se espera que o futuro apresente turbulências.” A equação 11 descreve a combinação de duas previsões. Primeiramente a combinação de previsões: média aritmética e variância mínima.

$$Fc = wF_1 + (1 - Y) F_2 \quad (11)$$

Onde:

F_1 e F_2 : previsões a serem combinadas e

w : peso da previsão.

Conforme os autores, apesar de a média aritmética ser um método simples, é um método robusto de combinação, mostrando-se um modelo, entre outros, com melhor desempenho, sendo que os pesos atribuídos aos modelos de previsão não diferem (CONSUL; WERNER, 2010).

Para o método da variância mínima, os autores relatam que os pesos dados a cada previsão são determinados de forma a tornar mínimo o erro da variância da combinação (CONSUL; WERNER, 2010). O método pode ser descrito pela equação (12).

$$W = \frac{\alpha_2^2}{\alpha_1^2 + \alpha_2^2} \quad (12)$$

Onde:

α_1^2 e α_2^2 : variâncias dos erros das previsões.

2.3.1 Média simples

Refere-se ao método mais simples da previsão. Pressupõe-se que a média aritmética simples é uma boa estimativa de previsão para modelos constantes. No entanto, não se mostra adequado o uso em série com tendência e sazonalidade, já que estes componentes poderão distorcer a média, levando a um nível de erro maior. Ocorre que neste modelo a média responde muito lentamente as alterações recentes no nível da série, levando a gerar problemas de falta de produtos. Como característica, o modelo de média simples apresenta em todas as ocorrências o mesmo peso ou importância no cálculo de previsão, tornando-se inoportuno se a meta for dar as observações mais antigas menor impacto.

Representa-se com a fórmula:

$$P_{t+1} = \frac{\sum_{i=1}^n R_i}{n} \quad (13)$$

Onde:

P_{t+1} : Previsão para o período t+1;

R_t : Demanda real ocorrido em t;

n : Número total de registros ou ocorrências passadas.

2.3.2 Média Móvel

No modelo de média móvel a previsão é a média dos últimos valores de demanda e, o padrão de demanda deve se manter para sua correta aplicação. Ballou (2006, p. 246), afirma que “cada ponto de uma média móvel numa série de tempo é a média aritmética ou ponderada de um número de pontos consecutivos das séries, na qual o número de pontos de dados é escolhido de forma a eliminar os efeitos da sazonalidade e irregularidade.”

Esse modelo corresponde a uma variação da média simples, sendo indicado para previsões de curto prazo onde as componentes de tendência e sazonalidade são inexistentes ou possam ser desprezadas.

A equação (14) representa o modelo:

$$F_t = \frac{D_{t-1} + D_{t-2} + \dots + D_{t-n}}{n} \quad (14)$$

Onde:

F_t : previsão para o período t;

D_t : demanda no período t;

n : número de observações utilizadas.

Corresponde a uma variação da média simples. Indicado para previsões de curto prazo em que as componentes de tendência e sazonalidade são inexistentes ou possam ser desprezadas.

Este modelo atenua os dados históricos, com peso igual para cada informação dos períodos do passado.

2.3.3 Média Móvel Dupla

Para o cálculo desse modelo empregam-se etapas:

Calcula-se a média móvel de tamanho n :

$$M_t = \frac{R_t + R_{t-1} + R_{t-2} + (\dots) + R_{t-n}}{n} \quad (15)$$

Com o resultado obtido, calcula-se a média móvel dupla de tamanho n :

$$MMD_t = \frac{M_t + M_{t-1} + M_{t-2} + (\dots) + M_{t-n+1}}{n} \quad (16)$$

Dando continuidade, o nível é estimado somando-se a média móvel simples à diferença entre a média dupla e a simples:

$$a_t = M_t + (M_t - MMD_t) \quad (17)$$

Para incluir a tendência no cálculo, define-se um fator de ajuste, equivalente ao coeficiente angular de reta:

$$b_t = \frac{2}{n-1} (M_t - MMD_t) \quad (18)$$

A equação seguinte dará previsão futura:

$$P_{t+1} = a_t + b_t \quad (19)$$

Onde:

P_{t+1} : previsão para o próximo período;

n : é o número de períodos utilizados;

M_t : média móvel do período t ;

M : média móvel das médias móveis.

Assim como na média móvel, neste ocorre a necessidade de se definir a quantidade de períodos n mais adequada à série em questão (objetivando minimizar a soma quadrada dos erros da previsão do período seguinte). Um dos pontos negativo desse modelo são que as ocorrências possuirão o mesmo peso, independentemente da sua “idade”.

Para avaliação do ajuste do modelo de médias móveis aos dados de séries temporais temos alguns critérios:

- **Erro percentual absoluto médio (MAPE)**

Expressa precisão como porcentagem do erro dado por,

$$[\sum_{t=1}^n | (y_t - \hat{y}_t) / y_t | / n] \times 100 \quad (20)$$

onde y_t é uma observação, \hat{y}_t é o valor ajustado e n é o número de observações. Essa medida expressa precisão como porcentagem do erro. Como esse número é uma porcentagem, ele pode ser mais fácil de compreender do que outras estatísticas. Por exemplo, se o MAPE é 5, em média, a previsão está incorreta em 5%.

- **Desvio absoluto médio (MAD)**

Expressa precisão nas mesmas unidades dos dados, o que ajuda a conceituar a magnitude do erro dado por,

$$\sum_{t=1}^n | (y_t - \hat{y}_t) | / n \quad (21)$$

onde y_t é uma observação, \hat{y}_t é o valor ajustado e n é o número de observações. Os outliers (pontos discordantes) têm menor efeito sobre MAD do que sobre MSD.

- **Desvio quadrado médio (MSD)**

Outra medida comumente usada da exatidão dos valores de séries temporais ajustados é dada por,

$$\sum_{t=1}^n | (y_t - \hat{y}_t) |^2 / n \quad (22)$$

onde y_t é uma observação, \hat{y}_t é o valor ajustado e n é o número de observações. Os outliers (pontos discordantes) têm um maior efeito sobre MSD do que sobre MAD.

2.3.4 Amortecimento Exponencial Simples (AES)

Dependendo do valor da constante de suavização os valores mais recentes de demanda podem receber maior peso no cálculo da previsão. Quanto maior o valor da constante de suavização, maior é o peso da última observação de demanda.

“Os modelos de suavização exponencial são amplamente utilizados para previsão de demanda devido a sua simplicidade, facilidade de ajuste e boa precisão.” (PELLEGRINI; FOGLIATTO, 2001, p. 49). Esses modelos consistem em uma atribuição de um peso para cada valor da série temporal, de forma que os valores mais recentes recebem ponderações maiores: os pesos decaem exponencialmente em direção ao passado (PELLEGRINI; FOGLIATTO, 2001). No mesmo entendimento, Casaca (2008) diz ser uma característica do modelo ser aplicável a séries localmente estacionárias, ponderando todos os valores históricos da série com pesos sucessivamente menores à medida que estes se afastam do valor mais recente.

O AES corresponde a um método similar à média móvel, mas em sua base existe a diferenciação dos pesos aplicados aos valores da série histórica em função do tempo. Conforme Ribeiro (2009, p. 38),

As observações mais recentes da série terão uma importância maior na obtenção da previsão que os primeiros eventos. [...] o que pressupõe que os últimos eventos de uma série terão “informações mais atualizadas” sobre a demanda e, conseqüentemente, mais importância na previsão da demanda futura.

Segundo Casaca (2008, p. 18), o modelo de amortecimento exponencial simples é apropriado quando a procura não apresenta tendência ou sazonalidade.

Para Delurgio (1998, p. 154-155) que,

[...] as previsões através do AES exigem apenas três dados: a previsão mais recente, o valor real mais recente e uma constante de alisamento. A constante de alisamento, α , determina o peso dado às observações passadas mais recente se, por conseguinte, controla a taxa de alisamento ou da média. O seu valor está, geralmente, restrito ao intervalo[0;1].

Conforme Samohyl, Mattos e Rosa (2001) uma das vantagens é que esse modelo depende, diretamente, apenas do tempo (t) imediatamente anterior ao tempo $t + 1$, objeto da previsão, não havendo necessidade no armazenamento de dados. O que o caracteriza como um método que pode ser utilizado na identificação de um padrão relacionado com o tempo.

Outra particularidade desse modelo é que se faz necessário adotar valores para coeficientes de amortização ou regularização, podendo modificar o resultado de uma previsão.

Para Ribeiro (2009) a simplicidade e pequena necessidade de séries longas desses métodos os levam a serem considerados como alguns dos mais úteis, facilitando sua implementação.

A denominação exponencial, decorre de os pesos (α) decrescem exponencialmente, como uma progressão geométrica (α , $\alpha(1-\alpha)$, $\alpha(1-\alpha)^2$, $\alpha(1-\alpha)^3$), conforme os eventos vão ocorrendo ao longo do tempo, sendo que quanto maior o valor de α , maior a influência do evento mais recente na previsão final. Entretanto, quando do valor de α muito elevado pode levar a uma previsão muito sensível às variações aleatórias da demanda realizada, em prejuízo das mudanças estruturais. Em contra partida, valores muito baixo levarão a um modelo estável, resistente à aleatoriedade existente na série histórica.

Segundo Gaither e Frazier (2001), utilizando um exemplo para mensuração de ruído, ressalta que os valores para α utilizados na previsão são normalmente baseado em critérios de precisão, resposta de impulso e capacidade de atenuação de ruído. Ocorre que nem sempre os níveis mais elevados de α resultam em previsões mais acuradas, isso porque ocorre uma tendência em cada conjunto de dados de apresentar qualidade única, o que requer experimentação com níveis α (= 0,1, 0,2, e 0,3) diferentes como meio de buscar precisão na previsão. Os autores observam que quanto mais elevado for α tanto mais será elevado a resposta ao impulso, e menor sua capacidade de atenuação de ruído, e vice-versa. Quando $\alpha = 0,3$ a previsão dará uma resposta ao impulso mais elevada e uma capacidade de atenuação de ruído ligeiramente mais baixa, já que a curva exibirá uma variação maior de período a período.

Quando ocorre uma constância sobre um nível médio na série temporal, uma suavização exponencial simples pode ser usada para a previsão de valores futuros da série. Sua representação matemática pode ser dada pela equação abaixo.

$$F_t = \alpha D_t + (1 - \alpha) F_{t-1} \quad (23)$$

Onde:

F_t : previsão para o período t;

D_t : demanda no período t;

α : constante de suavização (valor entre 0 e 1).

2.3.5 Amortecimento Exponencial Duplo (Modelo De Brown)

O uso do Amortecimento Exponencial Duplo (AED) requer atenção aos valores iniciais “ A_0 ” e “ A'_0 ”, pois a utilização da primeira observação para estes valores implica em subestimar a tendência existente em uma série.

$$A_0 = a_0 - \frac{(1 - \alpha)}{\alpha} b_0 \quad \text{e} \quad A'_0 = a_0 - 2 \frac{(1 - \alpha)}{\alpha} b_0 \quad (24)$$

Onde:

a_0 : coeficiente linear da regressão dos valores da série (variável dependente) pelos números dos períodos (variável independente);

b_0 : coeficiente angular da regressão dos valores da série (variável dependente) pelos números dos períodos (variável independente).

2.3.6 Suavização Exponencial com Tendência - Método de Holt (SEH)

É um método de amortecimento, utilizado para as séries que apresentam tendência (mas não sazonalidade), no qual são adotadas duas constantes de amortecimento distintas, α e β , uma delas para estimação da tendência e a outra para o nível. Adiciona um componente relacionado à tendência de crescimento, ou seja, com uma constante extra para modelar a componente de tendência. É recomendada para séries que apresentam tendência.

Pode ser empregado em séries temporais com tendência linear e, emprega duas constantes de suavização, α e β (com valores entre 0 e 1), sendo representado por três equações (ARMSTRONG, 2001):

$$B_t = \alpha . D_t + (1 - \alpha) . (B_{t-1} + T_{t-1}) \quad (25)$$

$$T_t = \beta . (B_t - B_{t-1}) + (1 - \beta) . T_{t-1} \quad (26)$$

$$F_t (1 + K) = B_t + K . T_t, K = 1, 2, \dots \quad (27)$$

Onde:

D_t : demanda do período t ;
 B_t : base no final do instante t ;
 T_t : tendência no final do período t ;
 α : constante de suavização para base;
 β : constante de suavização para tendência;
 F_{t+k} : previsão para o período $t + k$.

Assim, as equações 17 e 18 fazem uma estimativa do nível e da inclinação da série temporal, respectivamente. Já a equação 19, calcula a previsão da demanda para os próximos p períodos (PELLEGRINI; FOGLIATTO, 2001).

2.3.7 Suavização Exponencial com tendência e sazonalidade – Modelo Holt Winters

Para Pellegrini e Fogliatto (2001) esses modelos descrevem dados de demanda nos quais se verifica a ocorrência de tendência linear, além de um componente de sazonalidade. Caracterizam-se pela ocorrência de padrões cíclicos de variação, que se reproduzem em intervalos constantes de tempo. Estão divididos em dois grupos: aditivo e multiplicativo.

No modelo aditivo, a amplitude da variação sazonal é constante ao longo do tempo; ou seja, a diferença entre o maior e menor valor de demanda dentro das estações permanece relativamente constante no tempo. No modelo multiplicativo, a amplitude da variação sazonal aumenta ou diminui como função do tempo. O modelo multiplicativo de Winters é utilizado na modelagem de dados sazonais onde a amplitude do ciclo sazonal varia com o passar do tempo. (PELLEGRINI; FOGLIATTO, 2001, p. 50).

Os modelos de Winters necessitam de valores iniciais de componentes (nível, tendência e sazonalidade) para dar início aos cálculos.

Para previsão de séries que apresentam tendências e sazonalidades.

Este método agrega ao modelo uma componente de sazonalidade e envolve três equações com três parâmetros de suavização que são associados a cada componente da série: nível, tendência e sazonalidade. Levando a considerar dois casos. Neste caso, é definido um índice de sazonalidade por período.

$$B_t = \alpha \cdot \frac{D_t}{I_t - L} + (1 - \alpha) \cdot (B_{t-1} + T_{t-1}) + (1 - \alpha) \cdot (B_{t-1} + T_{t-1}) \quad (28)$$

$$T_t = \beta \cdot (B_t - B_{t-1}) + (1 - \beta) \cdot T_{t-1} \quad (29)$$

$$I_t = \gamma \cdot \frac{D_t}{B_t} + (1 - \gamma) \cdot I_{t-1} \quad (30)$$

Onde:

D_t : demanda do período t;

B_t : base no final do instante t;

T_t : tendência no final do período t;

I_t : índice de sazonalidade no período t;

α : constante de suavização para base;

β : constante de suavização para tendência;

γ : constante de suavização para sazonalidade;

Ballou (2006) pontua que existem diversos modelos de projeção histórica, dentre eles relaciona: Distribuição de Poisson, Distribuição Binomial Negativa, Modelo Intermitente de Croston, Ajustes a Curva, Box Jenkins ou ARIMA (modelo auto-regressivo integrado de média móvel).

2.3.8 Modelos ARIMA de BOX e JENKINS

Os Modelos ARIMA (Modelos Autoregressivos Integrados de Média Móvel), ou modelos de Box e Jenkins, como também são conhecidos, são modelos matemáticos construídos por meio de um processo iterativo e tem como pressuposto que os valores de uma série temporal têm relação de dependência e, “cada valor pode ser explicado por valores prévios do dado da série.” (PELLEGRINI; FOGLIATTO, 2001, p. 51).

Através da combinação de termos de autorregressão (AR), integração (I) e médias móveis (MA), o método procura modelos capazes de representar a série temporal, possibilitando, assim, previsões adequadas em relação aos próximos valores da sequência (WERNER, 2004).

Segundo Ballou (2006) tem o objetivo de identificar o comportamento da autocorrelação entre os valores da série temporal. Sendo que as funções de autocorrelação (FAC) e autocorrelação parcial (FACP) são os principais recursos utilizados para a identificação e diagnóstico das séries onde se possa utilizar o Método ARIMA. Morettin e Tolo (2006) enfatizam que se determinada série apresenta uma FAC e uma FACP com características similares ao de um processo estocástico³, então é possível modelar a série por esse método.

Afonso, Moreira Filho e Novaes (2011) trazem como equação geral dos modelos de ARIMA a equação:

$$\begin{aligned}
 X_t - X_{t-d} &= W_t = \theta(W) + e_t - \theta(e) \\
 \Phi(W) &= \Phi_1 W_{t-1} + \Phi_2 W_{t-2} + \dots + \Phi_\rho W_{t-\rho} \\
 \Theta(e) &= \theta_1 e_{t-1} + \theta_2 e_{t-2} + \dots + \theta_\varrho e_{t-\varrho}
 \end{aligned} \tag{31}$$

Onde:

X_t : valores da série temporal x observados em um tempo t ;

e_t : erro associado aos valores observados no tempo t ;

ρ : ordem de um modelo autorregressivo de coeficientes θ ;

ϱ : ordem de um modelo de média móvel de coeficientes θ ;

d : ordem de integração do modelo ARIMA.

Pela equação se faz possível observar que os valores futuros de uma série temporal são supostos como associados aos valores passados da série (componentes autorregressivos) quanto aos erros das observações passadas (componente média móvel). (AFONSO; MOREIRA FILHO, NOVAES, 2011).

Uma classe de modelos muito usada para séries temporais é a classe de modelos ARIMA (*Autoregressive Integrated Moving Average*), usualmente conhecido como método de Box-Jenkins (BOX et al., 1994) tem boa precisão para previsão de curto prazo, mas com precisões menores para a previsão a longo prazo.

³ Pellegrini e Fogliatto (2001, p. 51) relacionam que “um processo estocástico é caracterizado por uma família de variáveis aleatórias que descrevem a evolução de algum fenômeno de interesse. Processos estocásticos que caracterizam os estudos de séries temporais descrevem a evolução temporal de um fenômeno de interesse.”

A análise de uma série temporal, no domínio do tempo, é realizada por um parâmetro conhecido como o coeficiente de correlação seriada ou o coeficiente de autocorrelação. Este parâmetro indica a dependência em valores sucessivos de uma série de tempo.

A maioria dos problemas de previsão envolve o uso de dados de séries temporais. (MONTGOMERY et al., 2008) sugere que os problemas de previsão são frequentemente classificados como de curto prazo, médio prazo e longo prazo.

A utilização das observações disponíveis em tempos t de uma série temporal são usadas para previsão do valor em algum momento futuro pode fornecer uma base para um planejamento econômico e de negócios; planejamento da produção; controle de estoque e produção e controle e otimização de processos industriais (BOX et al., 1994).

Geralmente, as previsões são feitas no momento t , tomando o mês atual Y_t e os meses anteriores Y_1, Y_2, \dots, Y_{t-1} , para prever em tempos futuros $F_{t+1}, F_{t+2}, \dots, F_{t+m}$ os valores de Y .

A modelagem estocástica de séries temporais hidrológicas tem sido muito utilizada para a gestão de sistemas de recursos hídricos, tais como dimensionamento de reservatórios e a ocorrência de eventos hidrológicos futuros. Por exemplo, modelos estocásticos são usados para gerar séries sintéticas de abastecimento de água que podem ocorrer no futuro e que são utilizadas para estimar a distribuição de probabilidade de parâmetros-chave de decisão, armazenamento. Além disso, modelos estocásticos podem ser usados para suprimentos e demandas de água em dias, semanas, meses e anos de antecedência (FORTIN et al., 2004).

A modelagem ARIMA é essencialmente uma abordagem exploratória orientada com uma flexibilidade de montar um modelo apropriado que é adaptado a partir da estrutura dos próprios dados. A natureza estocástica das séries temporais pode ser aproximadamente modelada com o auxílio da função de autocorrelação e função de autocorrelação parcial onde variáveis aleatórias, componentes periódicos, padrões cíclicos e correlação serial pode ser descoberto. Como resultado, as previsões dos valores da série podem ser facilmente obtidas com um bom grau de precisão (HO e XIE, 1998).

Embora a modelagem ARIMA seja sofisticada em teoria, com os recursos computacionais atualmente disponíveis a construção de modelos e, conseqüentemente as previsões, podem ser facilitadas especialmente usando softwares disponíveis (por exemplo, SAS, Statgraphics, Statistica e Minitab). O processo, é construído através da identificação do modelo, estimativa de parâmetros e verificação da adequabilidade do modelo proposto (HO e XIE, 1998).

Os modelos ARIMA contém três componentes, a saber: componente autorregressivo (AR), componente integrado (I) e componentes de médias móveis (MA). A parte AR descreve

a relação entre as observações atuais e as observações passadas. A parte MA representa a estrutura de autocorrelação do erro. O componente I representa o nível de diferenciação da série para eliminar a não-estacionaridade. Geralmente denota-se por ARIMA (p, d, q) em que p indica a ordem de auto-regressão, d denota ordem de diferenciação, q denota ordem de movimento médio.

- **Modelo AR**

Um modelo AR (p) expressa o valor atual de séries temporais como uma combinação linear de p valores anteriores e um termo de ruído branco (choque aleatório). Bell (1984) expressa o valor atual da série de tempo do modelo AR (p) como:

$$Y_t = \varphi_1 Y_{t-1} + \dots + \varphi_p Y_{t-p} + a_t \quad (32)$$

onde $\varphi_1, \dots, \varphi_p$ são parâmetros AR(p), a_t é o choque aleatório na distribuição normal com média zero e variância σ_a^2 no tempo t, e p é a ordem de AR (p).

- **Modelo MA**

O modelo MA (q) expressa o valor atual de uma série temporal como uma combinação linear do ruído corrente e q valores anteriores de ruídos brancos. A média (puramente) móvel (MA) é o modelo (BELL, 1984):

$$Y_t = a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q} \quad (33)$$

- **Modelo ARMA**

Para aumentar a flexibilidade na montagem de séries temporais reais, ambos os componentes autoregressivos e de médias móveis são combinados levando ao modelo ARMA (p, q) (BELL, 1984):

$$Y_t = \varphi_1 Y_{t-1} + \dots + \varphi_p Y_{t-p} + a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q} \quad (34)$$

O tipo misto de séries que é explicado por seus próprios valores defasados e por termos de ruído defasados é chamado de modelos ARMA (p, q). Se o processo for

estacionário, um modelo ARMA pode ser usado para representar os dados. Se não é estacionário, a diferenciação é aplicada para tornar o modelo estacionário e isso leva ao modelo ARIMA (AKGUN, 2003).

- **Modelo ARIMA**

A primeira destas condições implica que a série Y_t dada em (11) é estacionária. Na prática, a série Y_t pode não ser estacionária, mas com a primeira diferença $Y_t - Y_{t-1}$ estacionária; se $Y_t - Y_{t-1}$ não é estacionária, podemos precisar tomar a segunda diferença, $(Y_t - Y_{t-1}) - (Y_{t-1} - Y_{t-2})$ e assim sucessivamente.

Em geral, podemos precisar tomar a d -ésima diferença de Y_t (embora raramente d é maior do que 2). Assim, temos o modelo ARIMA(p, d, q) onde d é a ordem de diferenciação.

Assim, um modelo ARIMA(p, d, q) pode ser dado para $t = t+v$ por,

$$Y_{t+v} = \Phi_1 Y_{n+v-1} + \dots + \Phi_{p+d} Y_{n+v-p-d} + a_{n+v} - \theta_1 a_{n+v-1} - \dots - \theta_q a_{n+v-q} \quad (35)$$

- **Modelos ARIMA**

Nesta seção consideramos o ajuste de modelos ARIMA usando o software MINITAB[®] versão 16. Os resultados apresentados são relacionados aos melhores e mais parcimoniosos (menor número de parâmetros) modelos ajustados. Para a verificação da adequabilidade dos modelos foi considerado gráficos residuais (normalidade e variância constante), ACF (autocorrelation function), PACF (partial autocorrelation function) para os resíduos e testes de hipóteses qui-quadrados de Ljung-Box (1978).

2.4 Erros de previsão de demanda

A previsão de demanda, como já foi abordado, ajuda as empresas em seu processo de desenvolvimento, colocando-as a frente de seus concorrentes (BALLOU, 2006), no entanto, Samohyl, Souza e Miranda (2008) alertam sobre a imprecisão da previsão, pois essa pode implicar em custos empresariais relativamente altos, já que as discrepâncias entre valores reais e previstos no mercado podem causar problemas tanto ao cliente quanto aos acionistas. “Problemas com a falta de capacidade instalada ou, até mesmo com o seu excesso, no caso do superdimensionamento decorrente de previsões errôneas.” (SAMOHYL; SOUZA;

MIRANDA, 2008, p. 28). Em decorrência a isso, os custos da produção estarão acompanhando as falhas nas previsões, dificultando o desenvolvimento da empresa. O que leva a entender que o grande motivador de um projeto de previsão corresponde a economia que se dará quando da venda e da produção equilibrarem-se no mesmo patamar, que corresponde a resultado de previsões mais exatas. Nesse sentido, compreende-se que “[...] a sobrevivência, o crescimento e a lucratividade a longo prazo, bem como a eficiência e a eficácia a curto prazo dependem de previsões apuradas.” (GAITHER; FRAZIER, 2001, p. 86).

Por melhor que seja a técnica de previsão utilizada, sempre existirão erros. Fatores imprevisíveis como promoções, instabilidade do mercado, ações dos concorrentes, entre outros, podem fazer com que nossas previsões fiquem além do esperado. Por isso, deve-se estar atento ao mercado e preparados para eventuais distorções de valores das previsões. (ZAN; SELLITTO, 2007, p. 105).

“O monitoramento dos erros é de extrema importância para tornar o processo de previsão de demanda mais assertivo, reduzindo estoques e buscando o equilíbrio entre demanda e oferta, necessidades dos clientes e capacidade da organização.” (PEREIRA et al. 2015, p. 15)

É entendimento de Zanella, Vieira e Barichello (2015) ao concordarem com Miranda et al. (2011, p. 46) que:

[...] quanto maior o erro na previsão de demanda, maior será a dificuldade da empresa em se planejar nas diversas áreas funcionais que a compõe, podendo gerar perdas financeiras às empresas, reduzindo sua competitividade perante os concorrentes. Estas perdas financeiras podem advir, por exemplo, de excesso de estoques, de vendas perdidas, das ineficiências no planejamento e controle da produção e de problemas no fluxo de caixa.

Para Meijden, Nunen e Ramondt (1994) uma previsão mais acurada antecipa melhor a demanda do cliente, pois, a acuracidade da previsão influencia diretamente no nível de serviço oferecido ao consumidor, no estoque de segurança e no custo total da cadeia de suprimentos. Enquanto que o inverso, a previsão inadequada, compromete resultados da cadeia de suprimentos podendo gerar três situações: “*stockouts* (não atendimento de demanda), *backlogs* (demanda atendida com atraso) e/ou excesso de estoque. Estas situações, além de aumentar os custos do produto, comprometem o fluxo de caixa e a rentabilidade do negócio.” (VEIGA; VEIGA, DUCLÓS, 2010, p. 86).

Veiga, Veiga e Duclós (2010) nos mostra que em modelos temporais o componente aleatório corresponde a parte da previsão que abrange a medida de erro de uma previsão. Lembrando que é justamente eliminar o componente aleatório e estimar a componente

sistemático o objetivo da previsão, assim, a diferença entre a previsão de demanda e a demanda real é justamente o erro de uma previsão, logo, se o erro de uma previsão for zero, essa poderia ser considerada perfeita. Já o contrário, como alertam Xie, Lee e Zhao (2004) quando ocorre de o erro aumentar de zero para um valor positivo, haverá um aumento no custo total, na instabilidade da programação de produção e no nível de serviço.

Isso ocorre por que o índice positivo mostra uma melhora no nível de serviço do sistema gerando melhora na capacidade e produz uma quantidade de produtos além da necessária, mostrando um valor menor por unidade.

[...] o custo de uma unidade faltante é reduzido, mas os custos associados com o nível de inventário, assim como o custo total, se elevam acentuadamente. Quando ocorre um viés negativo, o custo total aumenta enquanto o nível de serviço diminui. Isto ocorre porque o sistema produz uma quantidade menor de produtos do que é realmente necessária. Nesta situação, o nível de serviço é reduzido e o custo de uma unidade faltante aumenta acentuadamente. (VEIGA; DUCLÓS, 2010, p. 90).

Para Krajewski, Ritsman e Malhorta (2009) a qualidade das previsões pode ser mensurada por indicadores.

O *Mean Absolute Deviation* (MAD) ou desvio médio absoluto mensura a dispersão do erro, como demonstra a equação (24).

$$MAD = \frac{\sum | E_t |}{N} \quad (36)$$

O *Mean Absolute Percent Error* (MAPE) ou erro percentual absoluto médio, é outro indicador para mensuração relacionado com o nível de demanda, empregado para adequar o desempenho de previsão e representa-se pela equação (25).

$$MAPE = \frac{(\sum | E_t | / D_t)(100)}{N} \quad (37)$$

Um outro indicador apresentado é o *Mean Percentual Error*, ou média percentual de erro, mais utilizado e mais preciso que os anteriores. Quando abaixo de 5%, indica uma previsão aceitável (SCIPIONI; SELLITTO, 2015). Representado pela equação (26).

$$MPE = \frac{1/n \sum^n (D_t - P_t)/D_t}{t - 1} \quad (38)$$

Conforme Veiga; Veiga e Duclós (2010) dentre as várias medidas de erro existente para a previsão de demanda, a mais popular é o erro percentual médio absoluto (MAPE), sendo calculado seguindo a equação (27):

$$MAPE = \frac{(\sum |E_t| / D_t)(100)}{n} \quad (39)$$

Paganelli et al. (2015) validam a afirmativa de Swamidass (2000) e confirmam que o MAPE resulta da média dos erros percentuais absolutos das previsões, e que essa medida de erro corresponde a soma dos erros percentuais sem considerar os sinais, impedindo que erros positivos anulem-se. Assim, quanto menor o MAPE, melhor será a previsão.

2.5 Sazonalidade

A expressão sazonal remete ao tempo de duração de uma estação, mas quando empregada aos negócios torna-se tão vital quanto complexa. Seu entendimento se dá quando do conhecimento da oferta e demanda de um produto. Pode ser definida “como o conjunto dos movimentos ou flutuações com período igual ou inferior a um ano, sistemáticos, mas não necessariamente regulares, que ocorrem numa série temporal.” (QUEIROZ; CAVALHEIRO, 2003, p. 2).

Gonçalves (2004) considera como um fenômeno sazonal ocorrências regulares de ano para ano estando associado a variações climáticas, eventos e convenções sociais, por exemplo, páscoa, natal, dia das mães, entre outros.

Quase todos os produtos e serviços possuem alguma sazonalidade na demanda. Em alguns casos, esta sazonalidade se estende aos insumos, principalmente quando estes são originários da agricultura sazonal. Estas flutuações na demanda podem ser previsíveis, contudo algumas são afetadas por variações inesperadas no clima e por evolução das condições econômicas. (SLACK; CHAMBERS; JOHNSON, 2007).

Para Mesquita (2016, p. 63) o padrão sazonal está presente em diversas atividades, nas quais destacam-se: “agricultura, pesca, turismo, construção civil, alguns ramos do comércio varejista, entre outras. ” Na agricultura está presente quando da atividade da colheita ou do plantio. “A sazonalidade é o resultado de causas naturais, econômicas, sociais e institucionais.” (QUEIROZ; CAVALHEIRO, 2003, p. 2).

Conforme Mesquita (2016, p. 64) poucos estudos relacionam a sazonalidade das vendas enaltecendo sua implicação sobre o desempenho da organização, sendo mais comum a localização de trabalhos que apresentem métodos para realizar previsões de vendas, incluindo tendências sazonais.

Queiroz e Cavalheiro (2003, p. 2) relacionam a ocorrência de dois interesses principais no ajuste de séries temporais para variação sazonal: “o estudo da sazonalidade propriamente dita e a remoção da sazonalidade da série para depois estudá-la em seus demais aspectos. ”

Rodrigues, Argenton e Prudenciano (2008) traz que a forma mais simples de considerar a sazonalidade na previsão de demanda é valendo-se do emprego do último dado da demanda, no período sazonal em questão, assumindo-o como previsão. Entretanto, usualmente a inclusão da sazonalidade na previsão da demanda ocorre obtendo-se o índice de sazonalidade para diversos períodos, utilizando a média móvel centrada, e aplicando sobre o valor médio (ou tendência) previsto para em questão.

3 METODOLOGIA

Inicialmente foi realizada uma pesquisa bibliográfica para levantamento dos conceitos e modelos de previsão de demanda para construção do referencial teórico. Na sequência foi realizado um estudo de caso a fim de aplicar os conceitos e analisar os resultados.

A metodologia científica adotada para o desenvolvimento desta dissertação tem como base a pesquisa bibliográfica em artigos científicos e livros, associada ao estudo de caso. Trata-se da observação direta, ou seja, a utilização de análise de dados através de relatórios e indicadores fornecidos pela empresa.

Com a pesquisa bibliográfica adquirem-se dados ou registros teóricos já trabalhados por outros pesquisadores e documentados em livros, artigos, teses e outros meios impressos, que se tornam fontes dos temas a serem abordados na pesquisa (SEVERINO, 2007).

Quanto aos objetivos pode ser identificada como uma pesquisa descritiva, descreve características de determinado fenômeno ou população, envolvendo uso de técnicas padronizadas de coleta de dados.

A pesquisa realizada é caracterizada como de finalidade aplicada e de natureza quantitativa. A pesquisa aplicada é voltada à obtenção de conhecimentos com vistas à aplicação em uma determinada situação (GIL, 2010).

A abordagem quantitativa caracteriza-se pela formulação de hipóteses, definições operacionais das variáveis, quantificação nas modalidades de coleta de dados e informações utilizando tratamentos estatísticos (GRESSLER, 2004).

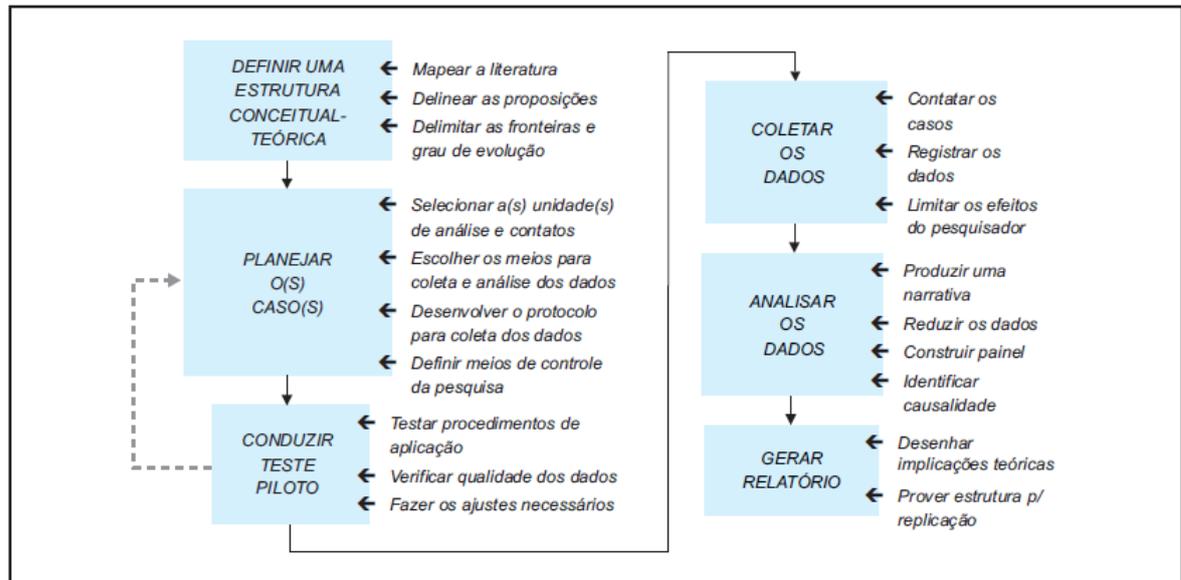
A metodologia do estudo de caso no entendimento de Yin (2005), adequa-se a questões “como” e “porque” em um ambiente no qual os pesquisados exercem pouca influência sob os fenômenos que ocorrem. Esse tipo de estudo possibilita o entendimento da dinâmica das ocorrências em um contexto, permitindo uma investigação das principais características de eventos reais, como processos organizacionais, que nessa dissertação trata previsão de demanda. Segundo Severino (2007), o estudo de caso é uma pesquisa em que se estuda um caso particular que tem elementos representativos de um conjunto de casos análogos.

A utilização desses diversos instrumentos e fontes de dados é importante para verificação da convergência ou divergência dos dados, executando uma triangulação das fontes de evidência (MIGUEL, 2007).

Conforme Miguel (2007), a adoção de uma abordagem como o estudo de caso deve atender a questão de pesquisa no sentido de aumentar as chances de endereçar a questão

proposta. Para atender então aos objetivos da pesquisa, o trabalho deve ser conduzido com o rigor metodológico necessário. Uma proposta de conteúdo e sequência para a condução de um estudo de caso pode ser vista na Figura 3.

Figura 3 - Condução do estudo de caso



Fonte: Miguel (2007, p. 221).

Com base em Miguel (2007), deve ser desenvolvido um referencial mapeando a literatura sobre o tema, a partir da revisão da literatura é possível identificar lacunas nas quais a pesquisa pode ser justificada, definidas as proposições do trabalho e respectivos objetivos. No que se refere ao planejamento dos casos, é necessário realizar a escolha da(s) unidade(s) de análise, ou seja, do(s) caso(s). Outra etapa prevista é a condução de um teste piloto, após, parte-se para a coleta dos dados, que devem ser coletados e registrados utilizando os instrumentos definidos no planejamento. A partir do conjunto de dados coletados, considerando as múltiplas fontes de evidência, o pesquisador deve então produzir uma análise geral do(s) caso(s). Todas as atividades das etapas anteriores devem então ser sintetizadas em um relatório da pesquisa. Esse relatório é o gerador de uma monografia (tese ou dissertação) e/ou de artigos (para congressos ou periódicos).

O desenvolvimento deste trabalho de pesquisa foi realizado em quatro etapas:

a) Definir uma estrutura conceitual-teórica

Esta etapa consiste na definição dos assuntos a serem pesquisados no estudo, são coletados textos, livros, artigos e teses que abordam o assunto do trabalho. Em seguida

realizou-se a leitura do material com o objetivo de aumentar os conhecimentos e garantir que todo tema abordado seja de conhecimento.

b) Planejar o Caso

Nesta etapa definiu-se quais modelos de previsão seriam usados para atender o objetivo do trabalho. É fundamental que a escolha seja criteriosa, pois estes serão a base para se descobrir a aplicabilidade do modelo na empresa.

c) Conduzir teste piloto

Esta etapa do projeto também é fundamental, pois é aqui que toda a base para a escolha do modelo de previsão foi desenvolvida. Através do estudo do comportamento no teste piloto. Todos os métodos devem ser estudados, para evitar surpresas nas etapas seguintes, e garantir a aderência do modelo escolhido.

d) Coletar os dados

Com a definição das séries necessárias, foram realizadas coletas e análises dos dados para verificar possíveis incoerências. A empresa já possui os dados organizados da forma a serem utilizados no trabalho. Foram coletados dados históricos de demanda, apresentados 40 observações mensais, quantidades de 10 produtos da demanda de caixas de 25 Kg de gordura hidrogenada vegetal, no período de janeiro de 2014 a abril de 2017. E selecionado covariáveis, como: mês, ano, Variação Mensal da Taxa de Desemprego, Taxa de Crescimento Trimestral - PIB Brasileiro, Variação Anual da Taxa de Inflação – IPCA e Crescimento Mensal da Produção Brasileira.

e) Analisar os dados

Esta etapa é a base para o desenvolvimento do trabalho, etapa que realiza toda análise e define o modelo de previsão a ser utilizado e os ganhos possíveis com o uso.

Com a definição dos modelos de previsão que o trabalho adotou, sendo: modelos de médias móveis, modelos ARIMA (BOX et al., 1994) e modelos de regressão linear múltipla, foi definido um *software* para servir de base nas análises dos modelos, sendo ele: Minitab versão 16.

3.1 Materiais e métodos

A empresa objeto de estudo é uma indústria do ramo alimentício localizada no interior do Estado de São Paulo, tendo início de suas atividades no ramo alimentício no ano de 1964. A capacidade produtiva mensal da indústria gira em torno de 18.000 toneladas de óleos, gorduras e cremes vegetais. A caracterização e detalhamento da empresa serão apresentados no subtítulo da seção 4.1 – Caracterização da empresa.

Para o estudo deste trabalho utilizou-se dados históricos dos produtos, coletados por meio do sistema de informação utilizado pela empresa em forma de planilhas eletrônicas. Esses dados correspondem a venda mensal ao longo de 3 anos dos produtos selecionados, num período que compreende de Janeiro de 2014 á Abril de 2017.

Com base nos dados dessa coleta realizou-se uma análise estatística dos produtos utilizando-se o *software* Minitab versão 16. O Minitab é um *software* estatístico desenvolvido em 1972 com o propósito original de auxiliar professores a ensinar estatística básica, tornou-se rapidamente uma referência no meio acadêmico sendo utilizado, atualmente, em mais de 4000 faculdades e universidades em todo o mundo e citado em mais de 300 publicações.

O *software* estatístico tornou-se também largamente utilizado no meio empresarial, oferecendo precisão e ferramentas de fácil uso para controle de qualidade, controle estatístico de processo, planejamento de experimentos, confiabilidade, análise de sobrevivência e estatística geral.

É uma opção para organizações de qualquer porte, desde as que estão recém começando no mundo dos negócios, até as gigantes multinacionais, que o utilizam em 80 países do mundo. A precisão, a confiabilidade e o uso amigável fizeram o *software* preferido das empresas que buscam a Qualidade Seis Sigma.

4 ESTUDO DE CASO

4.1 Caracterização da empresa

Com 80 mil m² de área total, a empresa desse estudo que aqui será denominada como Empresa X Alimentos está localizada no interior do Estado de São Paulo. Possui uma localização privilegiada e estrutura inteligente de logística que a torna capaz de servir o mercado em qualquer ponto do território nacional.

Atualmente a empresa atende diversos segmentos e, entre eles estão as grandes indústrias do ramo alimentício, *food service* de grande, médio e pequeno porte, padarias e confeitarias e também o consumidor final. Os produtos são indicados para frituras leves e industriais; fabricação de massas, pães, chocolates, sorvetes e produtos de confeitaria. Também atua com produtos para as áreas de saúde animal, óleo-química, química, automotiva e biocombustível.

Atualmente são oferecidos quase 300 diferentes tipos de produtos com uma produção mensal de 18.000 toneladas de óleos, gorduras e cremes vegetais com alta qualidade, higiene e resistência. Além de pesquisar, desenvolver e comercializar os mais variados ingredientes, a empresa também conta com serviços de análises físico-químicas, assistência técnica e consultoria para seus clientes.

Atualmente a empresa conta com aproximadamente 400 funcionários diretos, que recebem treinamentos com frequência para se especializarem e crescerem junto à empresa. A classificação do porte da empresa adotado pelo SEBRAE resumida no quadro seguinte: por número de funcionários. O critério para a definição do porte da empresa conforme o número de funcionários utilizado atualmente no Brasil, está apresentado no Quadro 3.

Quadro 3 – Classificação dos estabelecimentos segundo porte

Porte	Comércio e Serviços	Indústria
Microempresa	Até 9 empregados	Até 19 empregados
Empresa de Pequeno Porte	De 10 a 49 empregados	De 20 a 99 empregados
Empresa de Médio Porte	De 50 a 99 empregados	De 100 a 499 empregados
Grandes Empresas	100 ou mais empregados	500 ou mais empregados

Fonte: SEBRAE (2014, p. 17).

A produção mensal é de cerca de 18 mil toneladas de óleos, gorduras e cremes vegetais, com uma frota própria de transporte com mais de 50 caminhões e mais de 3 mil clientes em todo Brasil, entre eles, empresas de expressão mundial.

São fabricados produtos em caixas, baldes, *bags*, tambores e granel, nesta seção são dosados os insumos alimentares necessários para cada produto. A empresa tem capacidade instalada de equipamentos para texturização/cristalização para fabricação de gorduras vegetais em baldes, caixas, *bags* e tambores com capacidade total de 8.000 toneladas por mês e estrutura com capacidade total de 10.000 toneladas por mês para fabricação de óleos vegetais em latas, garrafas PET, galões e granel.

Constituído por duas grandes áreas do setor produtivo, Planejamento de Produção e Controle de Produção, a primeira área é responsável pela relação direta com a administração de vendas e comercial, emissão de ordens de produção, execução das formulações dos produtos e distribuição da produção. Já o controle de produção atua no acompanhamento da produção, quantidade produzida, gerenciamento de estoque, assim como dados gerais de consumo, matérias-primas, insumos e embalagens.

4.2 Coleta dos dados

Nesta etapa objetivo principal foi levantar os dados previstos, segundo Carvalho (2002), no momento de analisar um fenômeno ou um problema é necessário ter como base o planejamento com exatidão referente à natureza e também a quantidade das informações e dados que se deseja obter.

A coleta de dados ocorreu no período entre Abril e Junho de 2017, sendo diretamente de históricos e informações obtidas por meio de planilhas da empresa em estudo e pela verificação da disponibilidade de dados para a elaboração das previsões. A empresa armazena dados históricos mensais completos de demanda desde Janeiro de 2014 em uma base de dados que é atualizada mensalmente.

Coletaram-se dados históricos de demanda, apresentados 40 observações mensais, de janeiro de 2014 a Abril de 2017, perfazendo três ciclos completos de 12 meses, além dos quatro primeiros meses de 2017. Os dados coletados foram as quantidades de 10 produtos da demanda de caixas de 25 Kg de gordura hidrogenada vegetal vendidos nos últimos anos, separados mensalmente, como pode-se verificar na tabela 1.

Tabela 1 – Dados históricos de demanda de dez produtos da empresa desse estudo no período de Janeiro de 2014 a Abril de 2017

Mês	Ano	Produto 01	Produto 02	Produto 03	Produto 04	Produto 05	Produto 06	Produto 07	Produto 08	Produto 09	Produto 10
1	2014	761.832	42.260	154.000	153.400	144.480	0	175.800	91.056	104.205	101.925
2	2014	734.256	80.160	132.000	269.900	172.560	112.650	110.420	120.456	113.535	92.650
3	2014	781.560	80.140	154.000	259.120	189.000	114.200	124.140	170.280	91.830	198.325
4	2014	592.536	96.180	176.050	280.860	155.700	160.925	70.780	219.984	69.390	242.575
5	2014	489.576	61.840	71.975	295.000	191.060	110.825	67.120	189.384	86.700	167.725
6	2014	371.736	79.620	196.475	210.920	144.200	118.000	57.380	161.304	76.620	106.875
7	2014	601.608	68.780	198.100	266.200	192.380	107.775	47.860	254.232	66.360	159.750
8	2014	658.368	108.480	175.050	215.860	230.600	151.175	54.520	218.400	74.430	132.850
9	2014	657.552	93.060	172.200	296.000	159.220	121.825	54.120	218.016	83.775	127.625
10	2014	661.944	104.100	131.650	268.420	126.760	130.600	19.780	249.312	67.860	152.450
11	2014	1.017.192	94.540	167.500	208.940	193.820	68.425	72.000	240.240	99.480	211.700
12	2014	686.664	59.640	66.000	200.500	193.100	54.950	43.180	192.024	101.685	75.525
1	2015	964.464	70.460	154.025	190.200	283.720	82.400	76.280	227.808	98.565	139.900
2	2015	748.536	102.860	150.150	233.200	162.400	70.075	17.740	138.840	82.560	101.600
3	2015	648.240	85.880	150.750	216.640	346.920	52.375	82.920	225.768	98.085	109.350
4	2015	817.608	31.180	114.450	132.620	317.600	86.350	68.320	122.280	90.225	120.250
5	2015	650.520	43.180	146.250	223.820	84.480	102.575	38.740	191.040	106.140	100.650
6	2015	737.976	19.200	99.500	181.740	16.700	92.150	88.600	255.336	57.780	116.050
7	2015	759.576	7.340	123.775	120.380	5.100	130.900	1.100	222.240	66.975	134.950
8	2015	860.760	65.040	110.000	242.900	97.100	102.750	6.720	227.184	34.065	25.900
9	2015	902.400	62.000	104.425	182.260	112.860	93.350	9.360	186.528	104.655	116.000
10	2015	1.284.552	19.020	198.000	191.000	73.300	116.025	59.040	227.616	65.025	143.500
11	2015	883.464	51.100	154.450	215.000	37.180	82.950	7.940	193.680	49.110	96.125
12	2015	942.624	15.580	91.925	162.000	14.060	27.250	5.040	294.816	49.980	105.325
1	2016	1.320.288	51.500	88.000	155.720	275.780	76.225	32.760	338.400	56.130	86.075
2	2016	1.287.864	50.100	141.025	155.880	174.600	76.675	11.040	184.488	57.540	85.875
3	2016	411.336	1.000	44.000	97.180	141.320	1.475	60	191.112	7.080	35.675
4	2016	142.728	0	39.650	2.040	31.900	9.650	940	112.704	15.825	18.525
5	2016	76.608	0	32.750	0	26.100	18.850	0	77.712	9.585	0
6	2016	80.736	620	0	34.240	101.140	21.000	4.000	93.072	8.220	0
7	2016	35.712	15.880	0	0	1.200	16.075	2.740	71.592	5.055	0
8	2016	127.152	3.840	0	0	0	25.050	3.300	71.544	5.880	0
9	2016	206.424	2.720	0	54.680	17.380	47.675	4.120	90.624	22.170	4.500
10	2016	183.096	2.340	0	40.240	32.320	15.550	3.400	34.848	12.240	3.650
11	2016	272.976	2.960	0	52.700	300	35.400	11.240	93.936	9.840	475
12	2016	351.816	9.000	0	57.500	480	36.175	9.480	64.848	13.185	4.350
1	2017	304.560	8.540	0	29.000	24.440	8.900	3.680	47.280	17.655	375
2	2017	329.280	1.720	0	14.300	28.900	35.300	8.260	100.344	14.310	6.925
3	2017	185.976	2.040	0	43.600	61.500	38.500	3.200	57.768	8.670	55.025
4	2017	39.528	0	0	2.480	17.700	11.200	2.800	5.688	8.430	600

Fonte: O próprio autor.

Assim, as variáveis dependentes consideradas foi a demanda mensal da empresa. Já como covariáveis foram considerados mês, ano, variação mensal da taxa de desemprego, taxa de crescimento trimestral - PIB brasileiro, variação anual da taxa de inflação – IPCA e crescimento mensal da produção brasileira.

Foram coletados seis covariáveis, a fim de encontrar as que apresentassem maior relevância para os modelos. Sendo, mês, ano, Variação Mensal da Taxa de Desemprego, Taxa de Crescimento Trimestral - PIB Brasileiro, Variação Anual da Taxa de Inflação – IPCA, Crescimento Mensal da Produção Brasileira, como apresentado na Tabela 2.

Tabela 2 – Covariáveis

Mês	Ano	Covariável 01	Covariável 02	Covariável 03	Covariável 04
1	2014	6,40%	3,50%	5,59%	1,90%
2	2014	6,80%	3,50%	5,68%	0,20%
3	2014	7,20%	3,50%	6,15%	-0,80%
4	2014	7,10%	-0,40%	6,28%	-0,60%
5	2014	7,00%	-0,40%	6,37%	-0,80%
6	2014	6,80%	-0,40%	6,52%	-1,40%
7	2014	6,90%	-0,60%	6,50%	0,60%
8	2014	6,90%	-0,60%	6,51%	0,60%
9	2014	6,80%	-0,60%	6,75%	-0,50%
10	2014	6,60%	-0,30%	6,59%	0,20%
11	2014	6,50%	-0,30%	6,56%	-1,20%
12	2014	6,50%	-0,30%	6,41%	-1,60%
1	2015	6,80%	-1,80%	7,14%	0,30%
2	2015	7,40%	-1,80%	7,70%	-1,30%
3	2015	7,90%	-1,80%	8,13%	-0,70%
4	2015	8,00%	-3,00%	8,17%	-1,20%
5	2015	8,10%	-3,00%	8,47%	0,60%
6	2015	8,30%	-3,00%	8,89%	-0,30%
7	2015	8,60%	-4,50%	9,56%	-1,50%
8	2015	8,70%	-4,50%	9,53%	-1,20%
9	2015	8,90%	-4,50%	9,49%	-1,30%
10	2015	8,90%	-5,80%	9,93%	-0,70%
11	2015	9,00%	-5,80%	10,48%	-2,40%
12	2015	9,00%	-5,80%	10,67%	-0,70%
1	2016	9,50%	-5,40%	10,71%	0,40%
2	2016	10,20%	-5,40%	10,36%	-2,90%
3	2016	10,90%	-5,40%	9,39%	2,50%
4	2016	11,20%	-3,60%	9,28%	0,00%
5	2016	11,20%	-3,60%	9,32%	0,00%
6	2016	11,30%	-3,60%	8,84%	1,90%
7	2016	11,60%	-2,90%	8,74%	-0,10%
8	2016	11,80%	-2,90%	8,97%	-3,00%
9	2016	11,80%	-2,90%	8,48%	0,80%
10	2016	11,80%	-2,50%	7,87%	-1,30%
11	2016	11,90%	-2,50%	6,99%	0,60%
12	2016	12,00%	-2,50%	6,29%	2,00%
1	2017	12,60%	-0,40%	5,35%	-0,10%
2	2017	13,20%	-0,40%	4,76%	0,00%
3	2017	13,70%	-0,40%	4,57%	-1,30%
4	2017	13,60%	-0,40%	4,08%	0,60%

Fonte: ADVFN Brasil, (2017)

4.3 Análise dos dados e discussões dos resultados

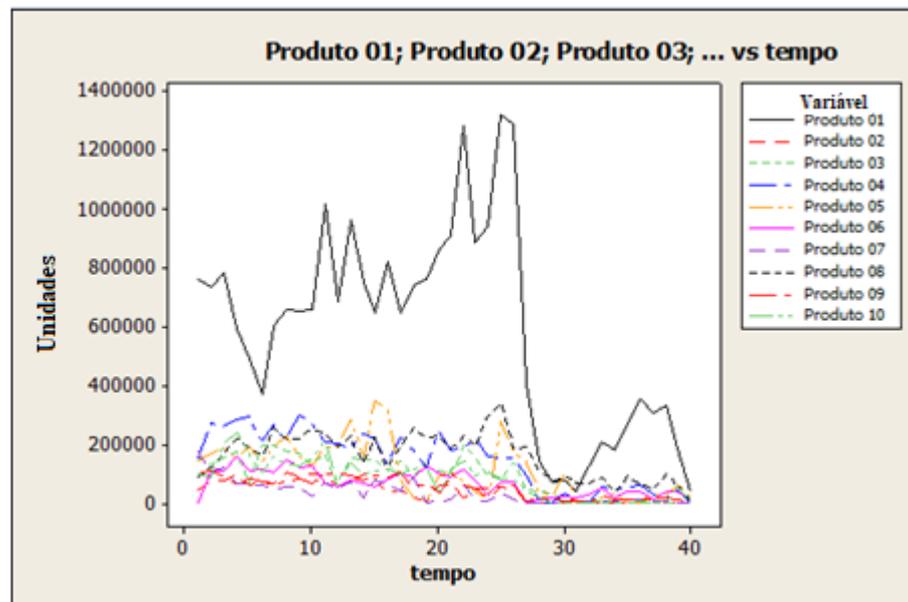
Estudos elaborados por Gil (2010), afirmam que o processo de análise dos dados envolve diversos procedimentos: codificação das respostas, tabulação dos dados e cálculos estatísticos.

Neste estudo foi utilizada uma ferramenta informatizada para a obtenção de resultados de análises estatísticas de dados por intermédio do *software* Minitab versão 16, que é usado para obtenção de análises gráficas e descritivas e modelagem estatística dos dados. Além disso, também foram utilizados vários textos básicos sobre modelagem estatística para complementação de conceitos usados neste trabalho.

Nessa direção, três técnicas estatísticas foram assumidas na modelagem dos dados temporais e para a previsão de demanda: modelos de médias móveis, modelos ARIMA (BOX et al., 1994) e modelos de regressão linear múltipla.

Para iniciar a construção dos modelos, uma análise gráfica preliminar foi realizada com o objetivo de identificar o padrão da demanda considerando 10 produtos da empresa considerada no estudo, apresentado na figura 4.

Figura 4 - Série histórica de demanda mensal



Fonte: O próprio autor.

Para análise das séries temporais visualizadas na figura 4, vamos assumir os modelos estatísticos mencionados anteriormente (modelos de médias móveis, modelos ARIMA (BOX et al., 1994) e modelos de regressão linear múltipla).

(1) Uso de Modelos de médias móveis

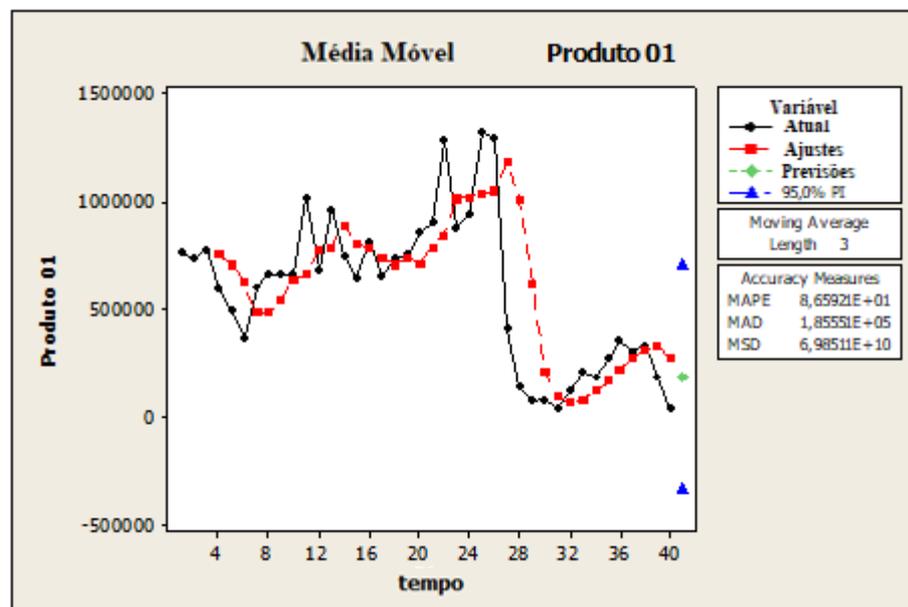
- **Resultados obtidos usando modelos de médias móveis para as 10 séries temporais consideradas no estudo**

Usando modelos de médias móveis ajustados para as séries temporais obtidos a partir do software Minitab, versão 16, foram gerados gráficos de previsão de demanda dos 10 produtos considerados neste estudo, utilizando dados coletados no período de janeiro de 2014 a abril de 2017, previsões de demanda e os erros das previsões.

- **Produto 1**

Para o Produto 1, a previsão de demanda para o próximo período será de 184.928 unidades (série observada e série ajustada dadas na Figura 5).

Figura 5 – Modelo de média móvel produto 1

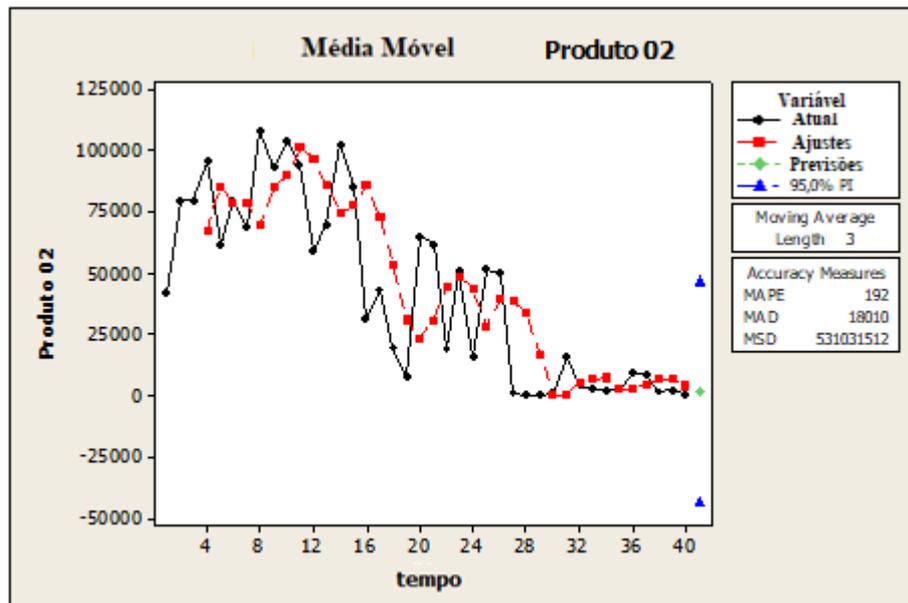


Fonte: O próprio autor.

- **Produto 2**

Para o Produto 2 a previsão de demanda será de 1.253 unidades (série observada e série ajustada dadas na Figura 6).

Figura 6 – Modelo de média móvel produto 2

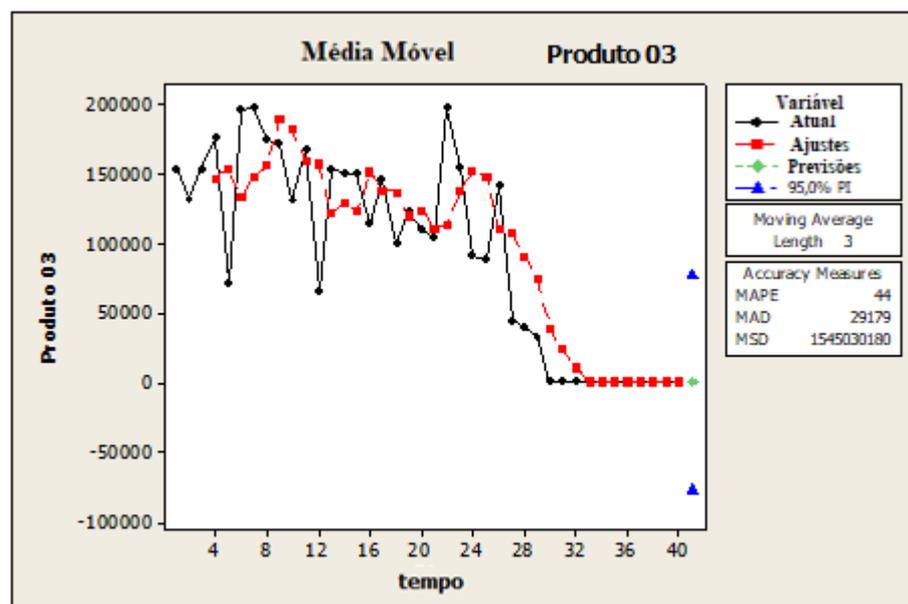


Fonte: O próprio autor.

- **Produto 3**

Para o Produto 3 a previsão de demanda será de 0 unidades (série observada e série ajustada dadas na Figura 7).

Figura 7 – Modelo de média móvel produto 3

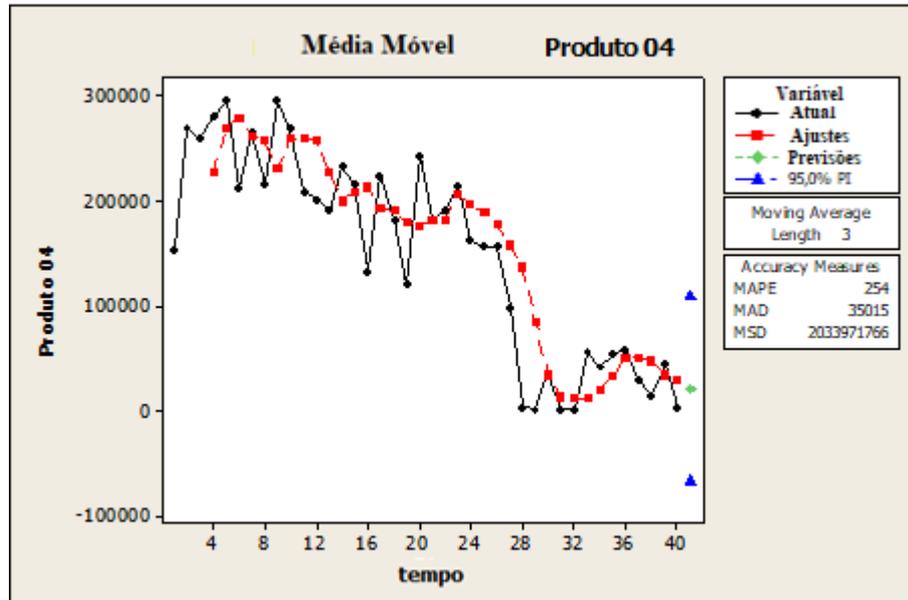


Fonte: O próprio autor.

- **Produto 4**

Para o Produto 4 a previsão de demanda será de 20.126 unidades (série observada e série ajustada dadas na Figura 8).

Figura 8 – Modelo de média móvel produto 4

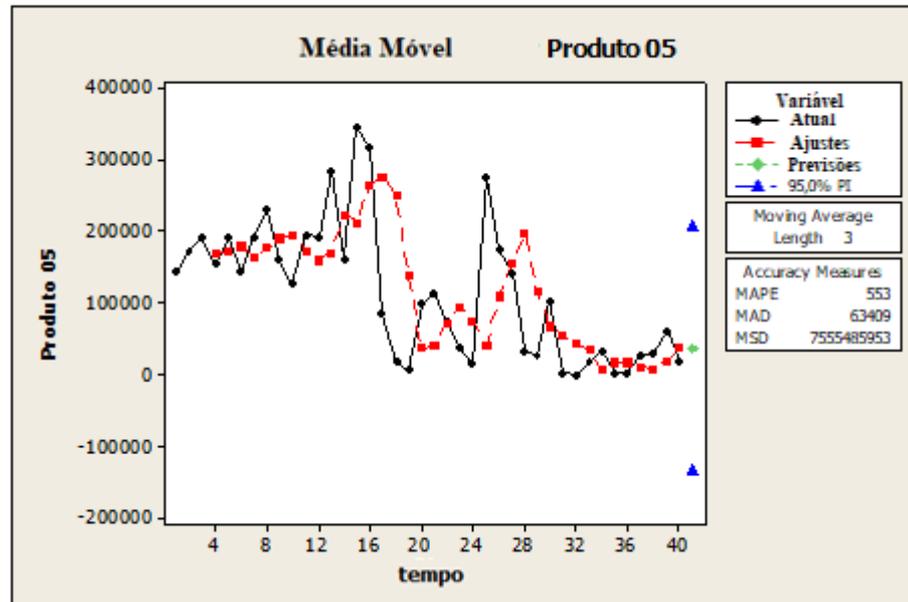


Fonte: O próprio autor.

- **Produto 5**

Para o Produto 5 a previsão de demanda será de 36.033 unidades (série observada e série ajustada dadas na Figura 9).

Figura 9 – Modelo de média móvel produto 5

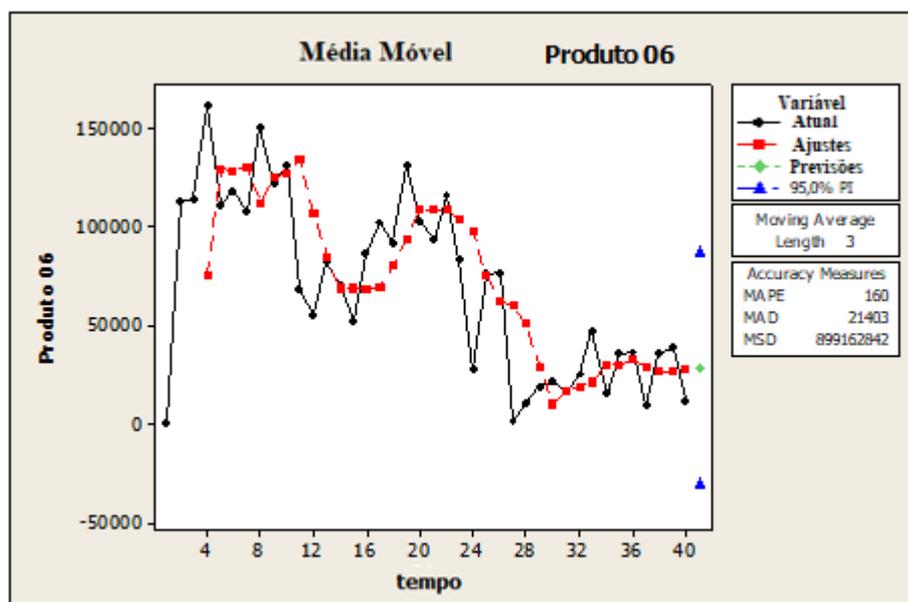


Fonte: O próprio autor.

- **Produto 6**

Para o Produto 6 a previsão de demanda será de 28.333 unidades (série observada e série ajustada dadas na Figura 10).

Figura 10 – Modelo de média móvel produto 6

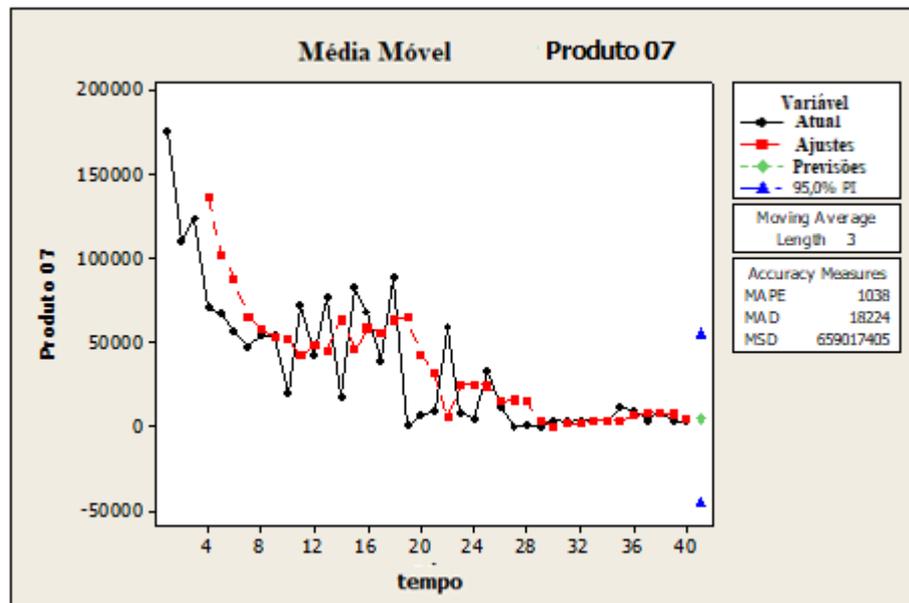


Fonte: O próprio autor.

- **Produto 7**

Para o Produto 7 a previsão de demanda será de 4.753 unidades (série observada e série ajustada dadas na Figura 11).

Figura 11 – Modelo de média móvel produto 7

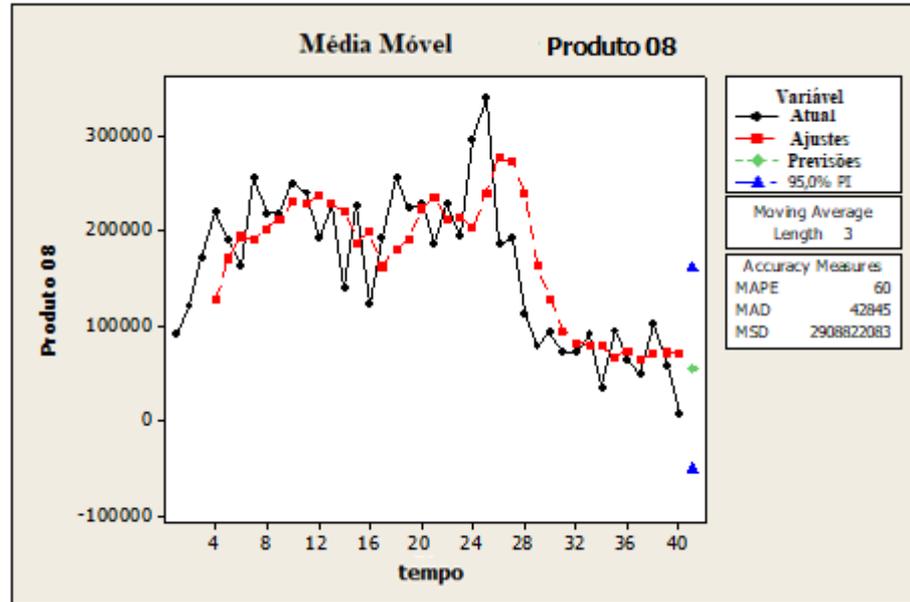


Fonte: O próprio autor.

- **Produto 8**

Para o Produto 8 a previsão de demanda será de 54.600 unidades (série observada e série ajustada dadas na Figura 12).

Figura 12 – Modelo de média móvel produto 8

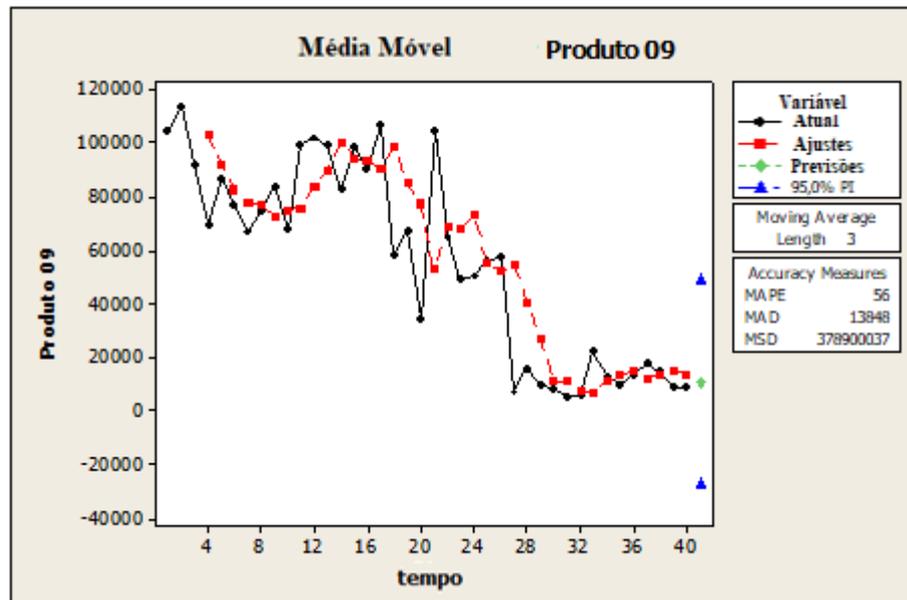


Fonte: O próprio autor.

- **Produto 9**

Para o Produto 9 a previsão de demanda será de 10.470 unidades (série observada e série ajustada dadas na Figura 13).

Figura 13 – Modelo de média móvel produto 9

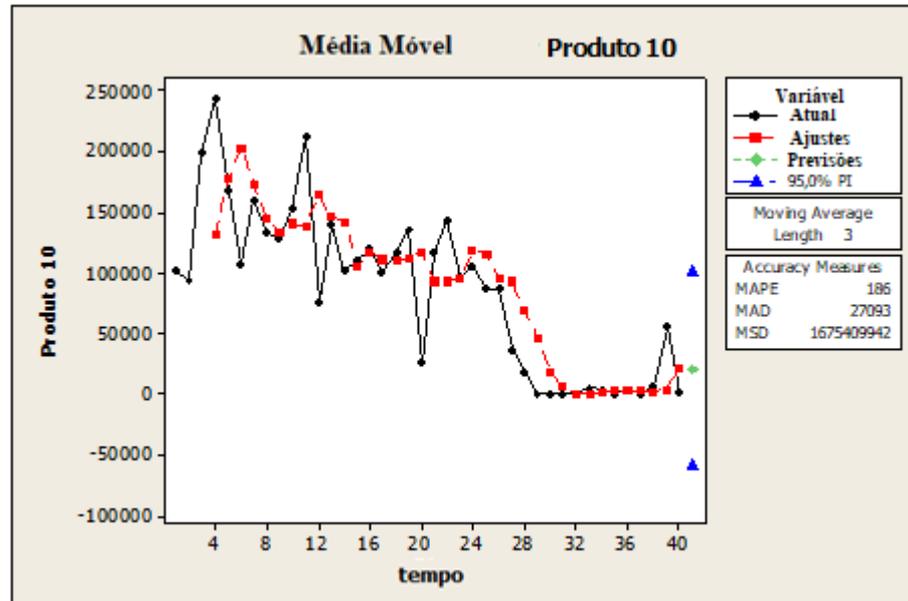


Fonte: O próprio autor.

- **Produto 10**

Para o Produto 10 a previsão de demanda será de 20.850 unidades (série observada e série ajustada dadas na Figura 14).

Figura 14 – Modelo de média móvel produto 10



Fonte: O próprio autor.

(2) Uso de modelos ARIMA para as séries temporais

- **Resultados obtidos usando modelos ARIMA para as 10 séries temporais consideradas no estudo**
- **Produto 1**

Assumindo o modelo ARIMA (12) com $p = 2$, $d = 1$ e $q = 1$ para os dados dos 10 produtos. Foram obtidos os seguintes estimadores para os parâmetros do modelo ARIMA considerando o produto 1 dados na Tabela 3 (uso do software Minitab).

Tabela 3 - Parâmetros e coeficientes do modelo estimados para o produto 1

Esimativas Finais de Parâmetros					
Type		Coef	SE Coef	T	P
AR	1	0,0130	1,2433	0,01	0,992
AR	2	-0,1255	0,1986	-0,63	0,531
MA	1	0,0996	1,2527	0,08	0,937

Fonte: O próprio autor.

De forma visual (ver Figura 19), observa-se a aderência do modelo aos dados observados. Com isso, realizou-se a previsão para os próximos 5 períodos e a matriz com seus valores previstos e intervalos de confiança 95% são apresentados na Tabela 4.

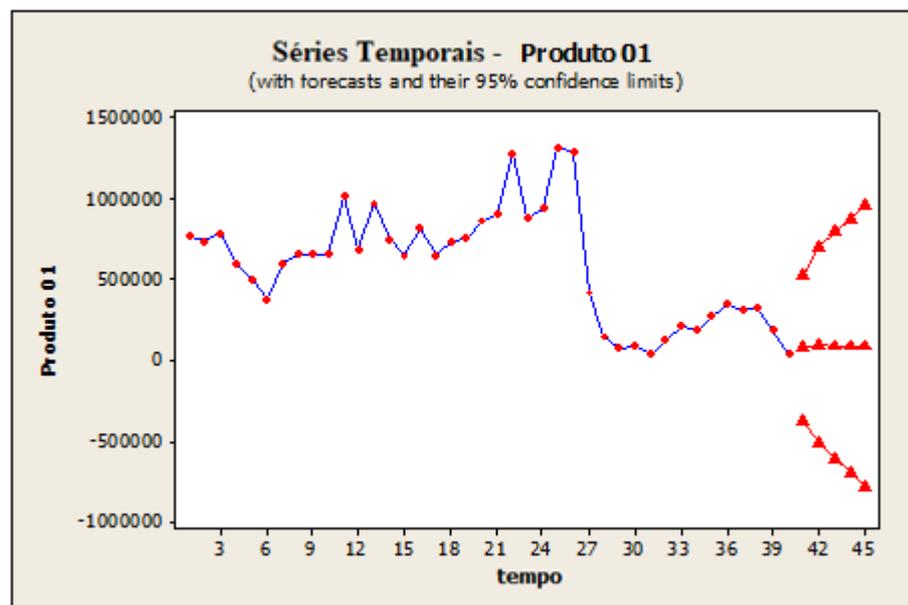
Tabela 4 – Previsões produto 1

Previsões após o período 40			
Períodos	Previsões	95% Limits	
		Inferior	Superior
41	71148	-378827	521122
42	89932	-519494	699358
43	86210	-618592	791013
44	83805	-706794	874404
45	84241	-786711	955192

Fonte: O próprio autor.

O modelo se mostrou aderente em função dos dados e seus valores estão dentro dos intervalos de confiança. Para melhor visualização, a figura 15 mostra os valores reais e os valores previstos.

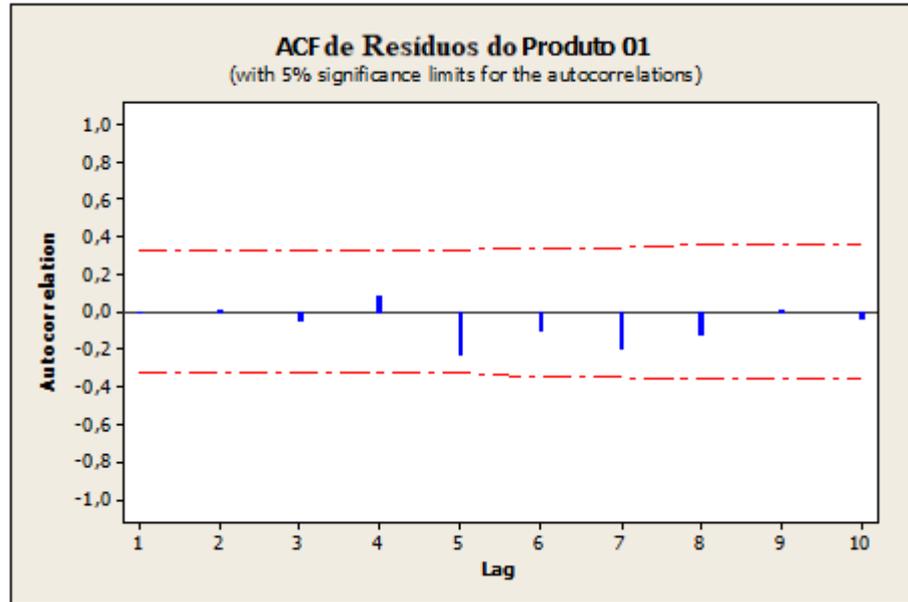
Figura 15 – Previsões produto 1



Fonte: O próprio autor.

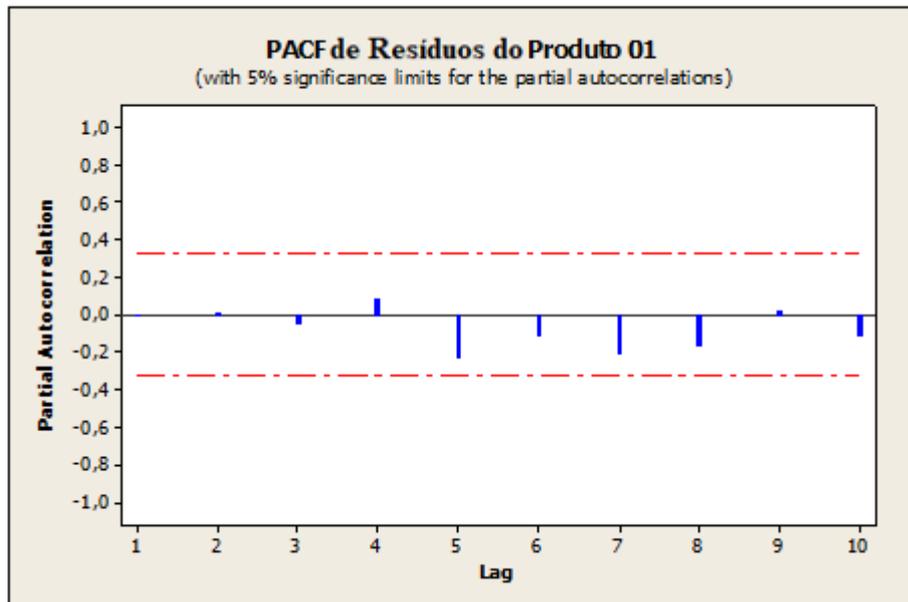
De acordo com os gráficos ACF e PACF (ver Figuras 16 e 17) não rejeitamos o modelo (as autocorrelações estão dentro da faixa de aceitação). Da mesma forma aceitar o modelo usando o teste de Ljung-Box (Chi-Square statistics, valor-p > 0,05).

Figura 16 – ACF produto 1



Fonte: O próprio autor.

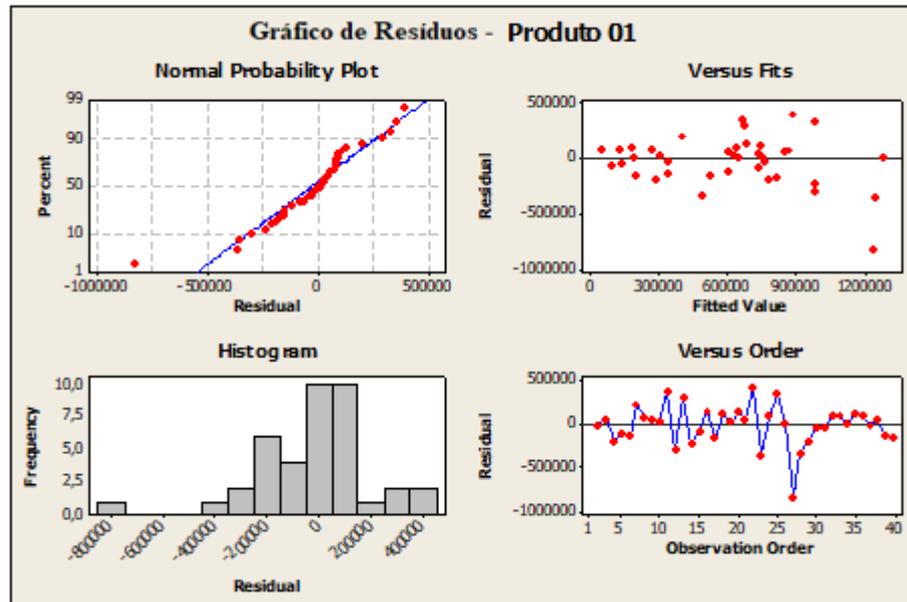
Figura 17 – PACF produto 1



Fonte: O próprio autor.

A figura 18, apresenta os resíduos do modelo. Observa-se excelente ajuste do modelo e que as suposições necessárias (normalidade dos resíduos, variância constante) são verificadas.

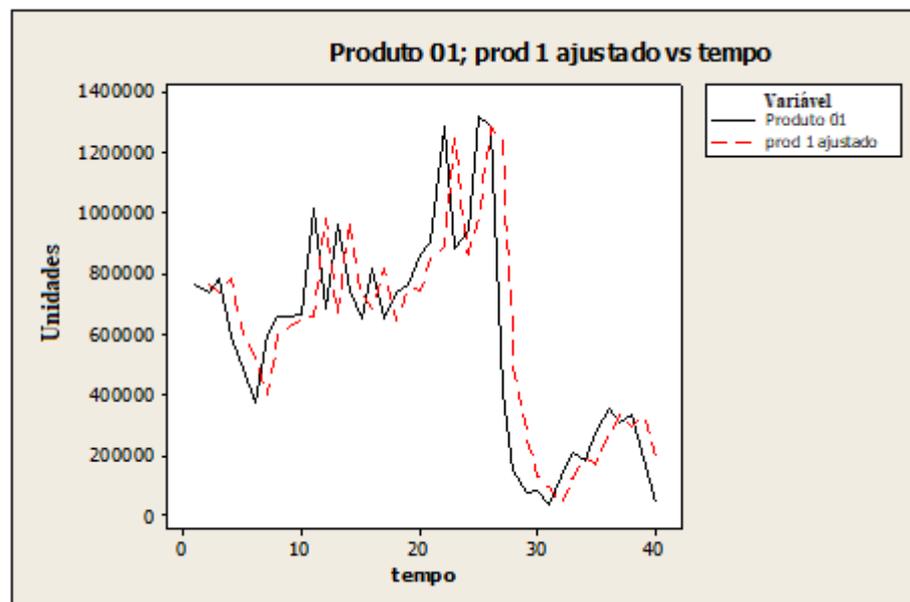
Figura 18 – Resíduos do modelo (produto 1)



Fonte: O próprio autor.

Assim, observa-se a partir da figura 18, que os resíduos estão próximos da reta no gráfico de probabilidade normal, uma indicação de bom ajuste da distribuição normal aos resíduos. Da mesma forma observa-se que o gráfico de resíduos versus valores ajustados mostra uma variabilidade dentro de uma faixa, uma indicação de variância constante.

Figura 19 – Modelo ajustado e dados observados (produto 1)



Fonte: O próprio autor.

- **Produto 2**

Para o produto 2, os estimadores para o modelo ARIMA considerado obtidos são dados na Tabela 5.

Tabela 5 – Estimadores dos Parâmetros e intervalos de confiança 95% (prod. 2)

Estimativas Finais de Parâmetros					
Type		Coef	SE Coef	T	P
AR	1	0,0768	0,3656	0,21	0,835
AR	2	-0,1188	0,2345	-0,51	0,615
MA	1	0,5634	0,3431	1,64	0,109

Fonte: O próprio autor.

De forma visual, observa-se a aderência do modelo em função dos dados. Com isso, realizou-se a previsão para os próximos 5 períodos e a matriz com seus valores previstos são apresentados na Tabela 6.

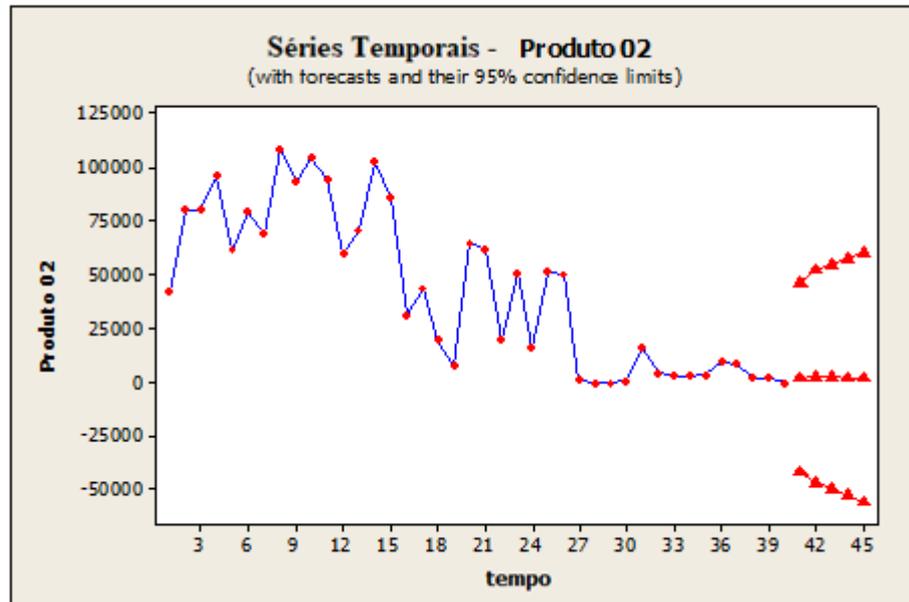
Tabela 6 – Previsões produto 2

Periodos	Previsões	95% Limits	
		Inferior	Superior
41	2048,7	-42329,8	46427,3
42	2448,5	-47437,8	52334,7
43	2235,7	-50109,1	54580,6
44	2171,9	-53144,8	57488,6
45	2192,3	-56253,5	60638,0

Fonte: O próprio autor.

O modelo se mostrou aderente em função dos dados e seus valores estão dentro dos intervalos de confiança. Para melhor visualização, a figura 20 mostra os valores reais e os valores previstos.

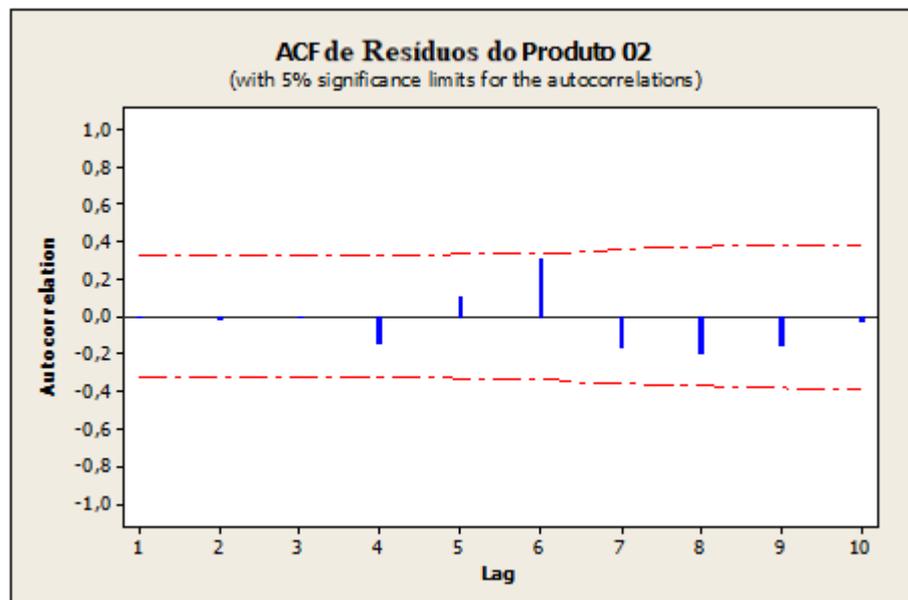
Figura 20 – Previsões produto 2



Fonte: O próprio autor.

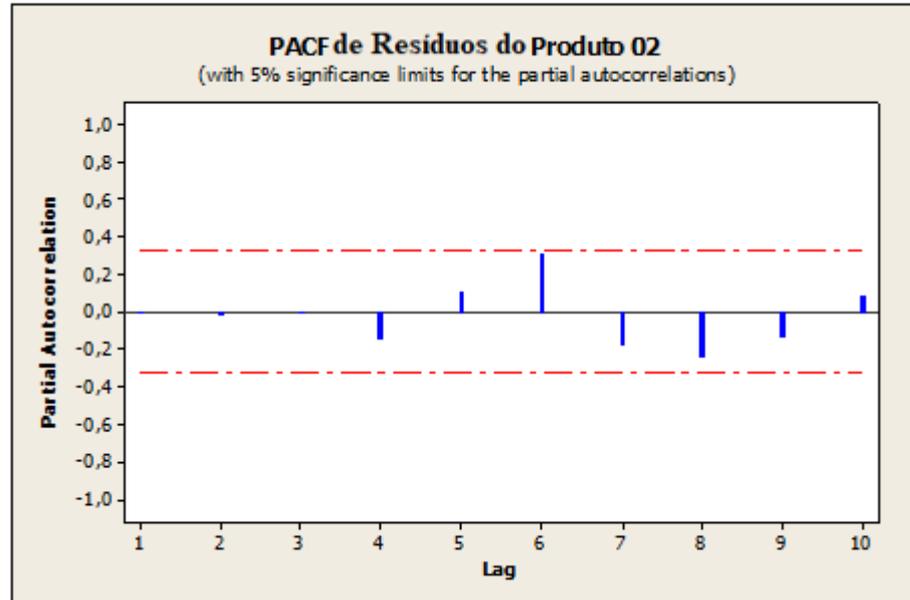
De acordo com os gráficos ACF e PACF não rejeitamos o modelo (as autocorrelações estão dentro da faixa de aceitação). Da mesma forma aceitar o modelo usando o teste de Ljung-Box (Chi-Square statistics, valor-p > 0,05), apresentados nas figuras 21 e 22.

Figura 21 – ACF produto 2



Fonte: O próprio autor.

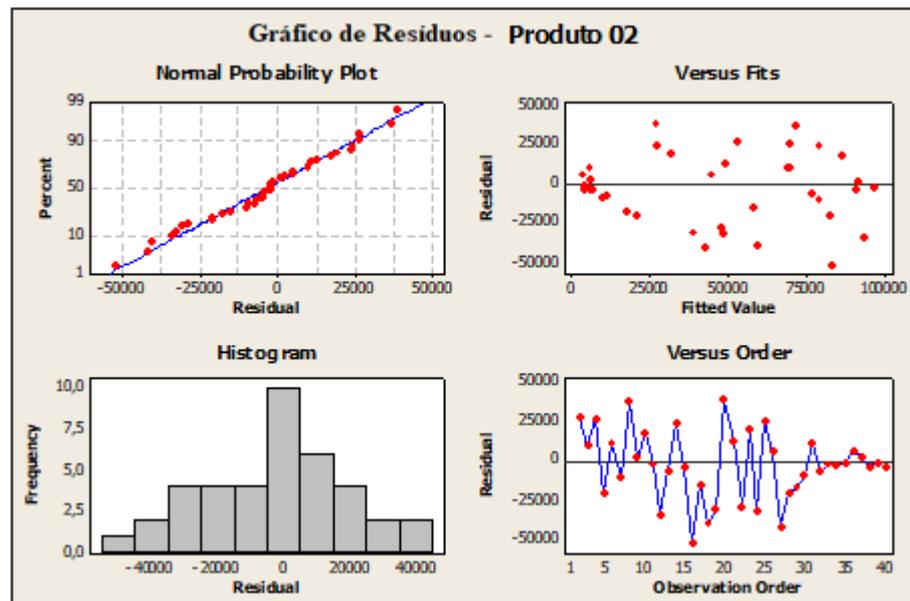
Figura 22 – PACF produto 2



Fonte: O próprio autor.

A figura 23, apresenta os resíduos do modelo. Observa-se excelente ajuste do modelo e que as suposições necessárias (normalidade dos resíduos, variância constante) são verificadas.

Figura 23 – Resíduos produto 2

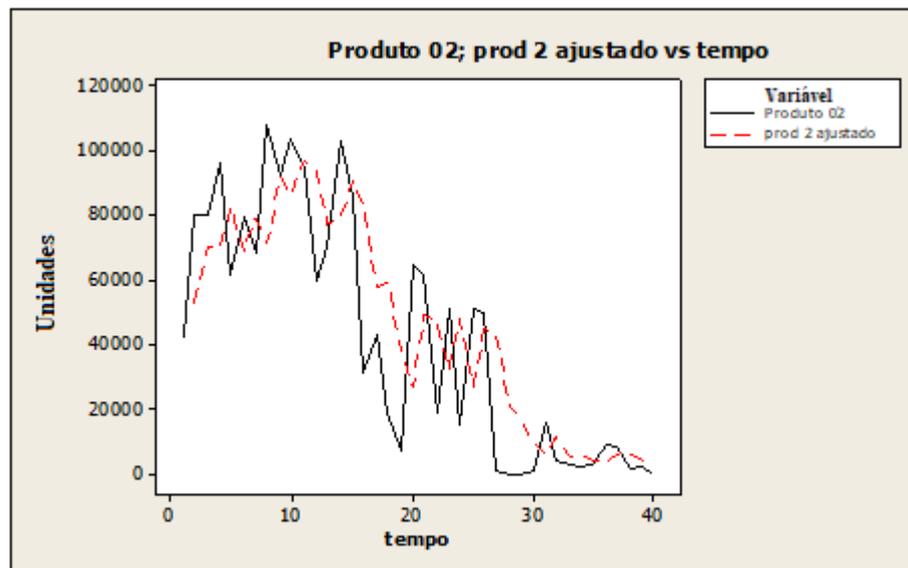


Fonte: O próprio autor.

Assim, observa-se a partir da figura 23, que os resíduos estão próximos da reta no gráfico de probabilidade normal, uma indicação de bom ajuste da distribuição normal aos resíduos. Da mesma forma observa-se que o gráfico de resíduos versus valores ajustados mostra uma variabilidade dentro de uma faixa, uma indicação de variância constante.

Como o modelo ARIMA está com uma boa aderência de acordo com a literatura, foi gerado um gráfico de ajuste com o tempo, como apresentado na figura 24 para o produto 2.

Figura 24 – Ajuste com tempo produto 2



Fonte: O próprio autor.

- **Produto 3**

Para o produto 3, os estimadores para o modelo ARIMA considerado obtidos são dados na Tabela 7.

Tabela 7 – Estimadores dos Parâmetros e intervalos de confiança 95% (prod. 3)

Estimativas Finais de Parâmetros					
Type		Coef	SE Coef	T	P
AR	1	-0,4987	0,5078	-0,98	0,333
AR	2	-0,2464	0,2962	-0,83	0,411
MA	1	0,1457	0,5221	0,28	0,782

Fonte: O próprio autor.

De forma visual, observa-se a aderência do modelo em função dos dados. Com isso, realizou-se a previsão para os próximos 5 períodos e a matriz com seus valores previstos são apresentados na Tabela 8.

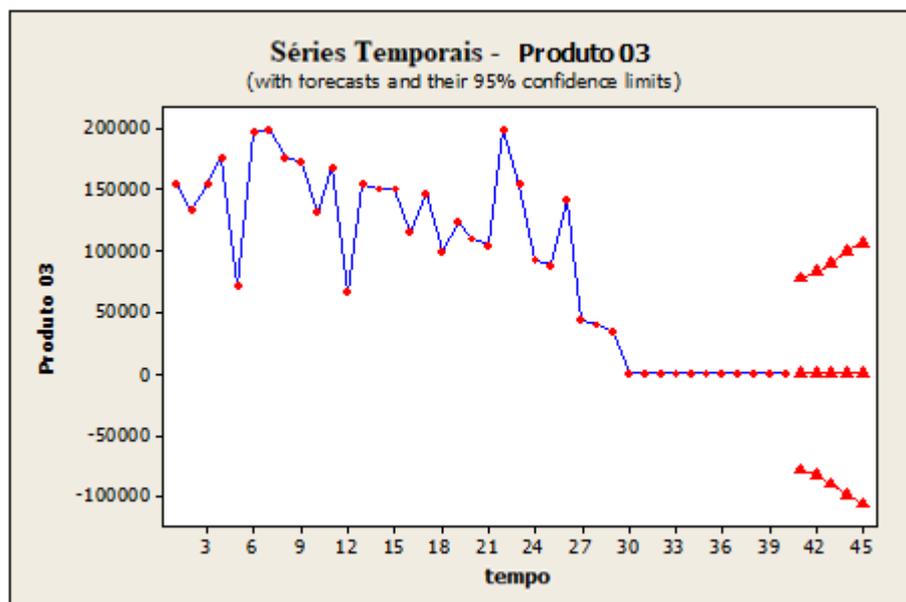
Tabela 8 – Previsões produto 3

Previsões após o período 40			
Períodos	Previsões	95% Limits	
		Inferior	Superior
41	0	-78177	78177
42	0	-82973	82973
43	0	-89542	89542
44	0	-99397	99397
45	0	-106051	106051

Fonte: O próprio autor.

O modelo se mostrou aderente em função dos dados e seus valores estão dentro dos intervalos de confiança. Para melhor visualização, a figura 25 mostra os valores reais e os valores previstos.

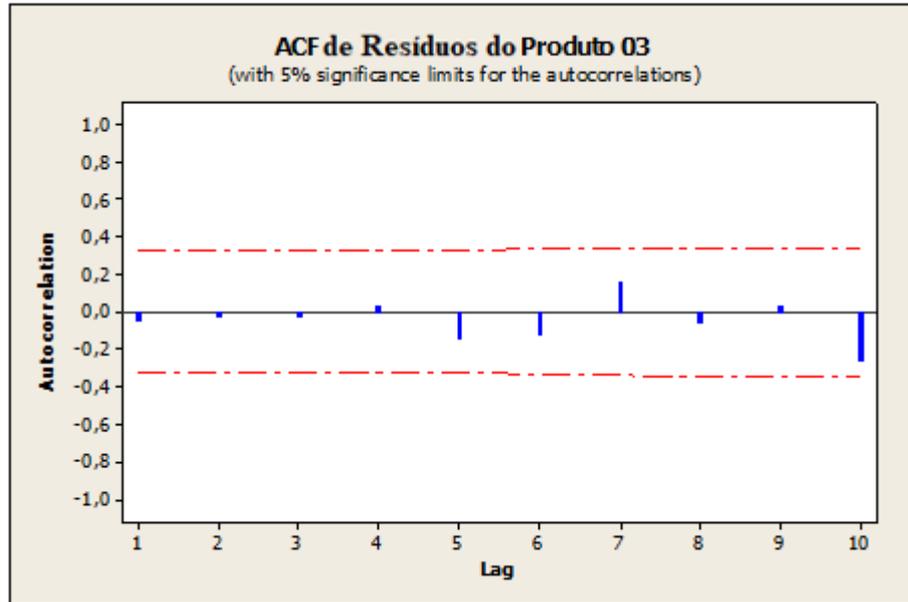
Figura 25 – Previsões produto 3



Fonte: O próprio autor.

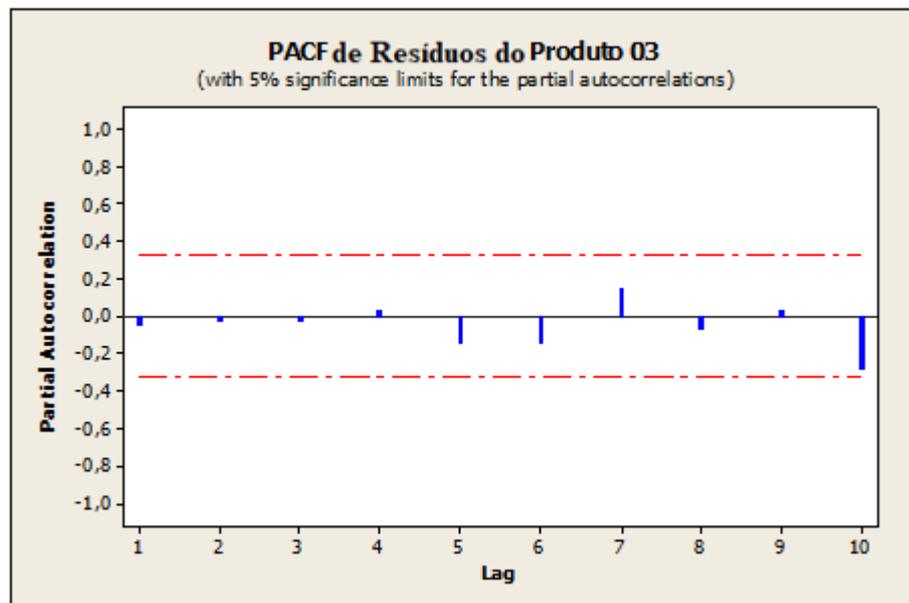
De acordo com os gráficos ACF e PACF não rejeitamos o modelo (as autocorrelações estão dentro da faixa de aceitação). Da mesma forma aceitar o modelo usando o teste de Ljung-Box (Chi-Square statistics, valor-p > 0,05), apresentados nas figuras 26 e 27.

Figura 26 – ACF produto 3



Fonte: O próprio autor.

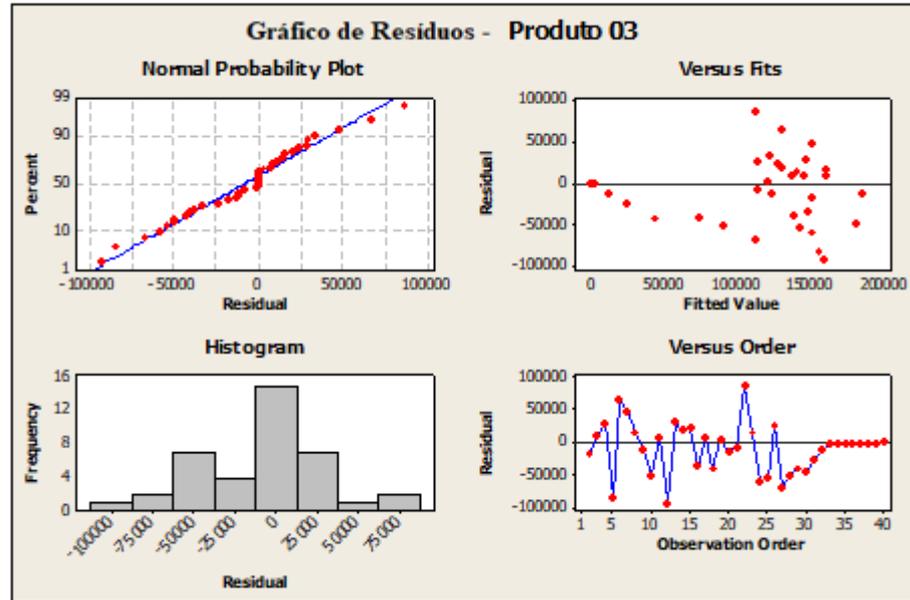
Figura 27 – PACF produto 3



Fonte: O próprio autor.

A figura 28, apresenta os resíduos do modelo. Observa-se excelente ajuste do modelo e que as suposições necessárias (normalidade dos resíduos, variância constante) são verificadas.

Figura 28 – Resíduos produto 3

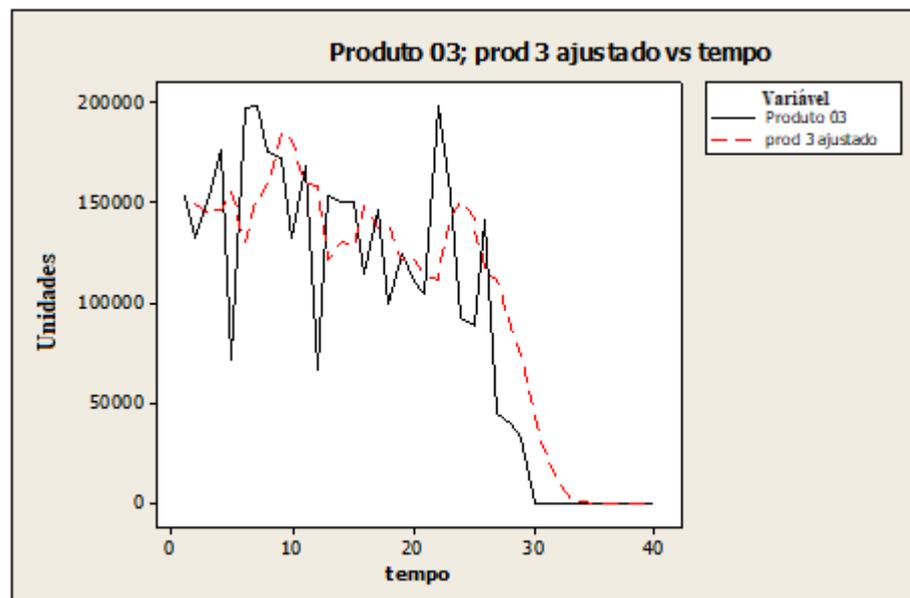


Fonte: O próprio autor.

Assim, observa-se a partir da figura 28, que os resíduos estão próximos da reta no gráfico de probabilidade normal, uma indicação de bom ajuste da distribuição normal aos resíduos. Da mesma forma observa-se que o gráfico de resíduos versus valores ajustados mostra uma variabilidade dentro de uma faixa, uma indicação de variância constante.

Como o modelo ARIMA está com uma boa aderência de acordo com a literatura, foi gerado um gráfico de ajuste com o tempo, como apresentado na figura 29 para o produto 3.

Figura 29 – Ajuste com tempo produto 3



Fonte: O próprio autor.

- **Produto 4**

Para o produto 4, os estimadores para o modelo ARIMA considerado obtidos são dados na Tabela 9.

Tabela 9 – Estimadores dos Parâmetros e intervalos de confiança 95% (prod. 4)

Estimativas Finais de Parâmetros					
Type		Coef	SE Coef	T	P
AR	1	0,5351	0,4377	1,22	0,229
AR	2	0,3557	0,2553	1,39	0,172
MA	1	0,9428	0,4198	2,25	0,031

Fonte: O próprio autor.

De forma visual, observa-se a aderência do modelo em função dos dados. Com isso, realizou-se a previsão para os próximos 5 períodos e a matriz com seus valores previstos são apresentados na Tabela 10.

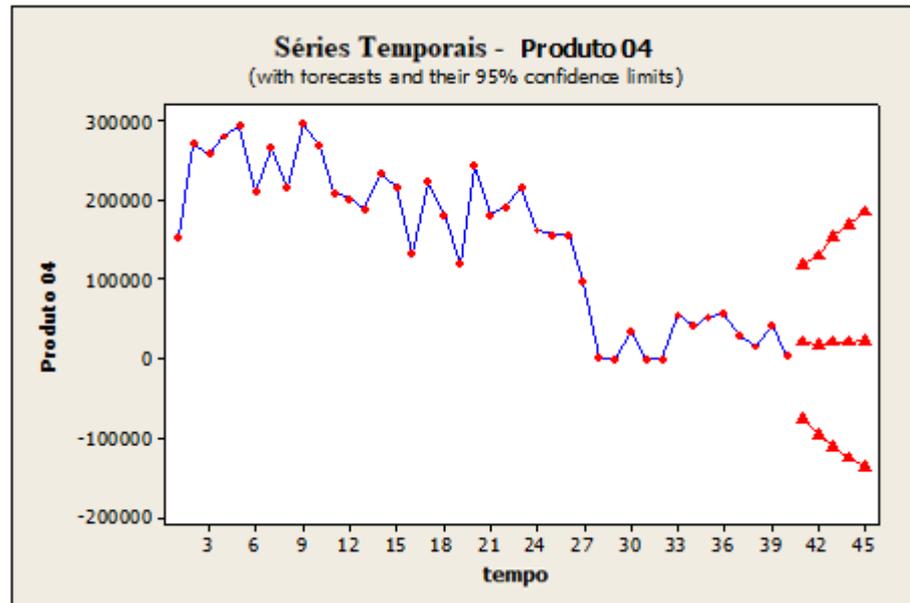
Tabela 10 – Previsões produto 4

Periodos	Previsões	95% Limits	
		Inferior	Superior
41	21225	-75909	118359
42	16628	-96264	129520
43	20836	-112468	154140
44	21452	-126398	169303
45	23279	-138225	184783

Fonte: O próprio autor.

O modelo se mostrou aderente em função dos dados e seus valores estão dentro dos intervalos de confiança. Para melhor visualização, a figura 30 mostra os valores reais e os valores previstos.

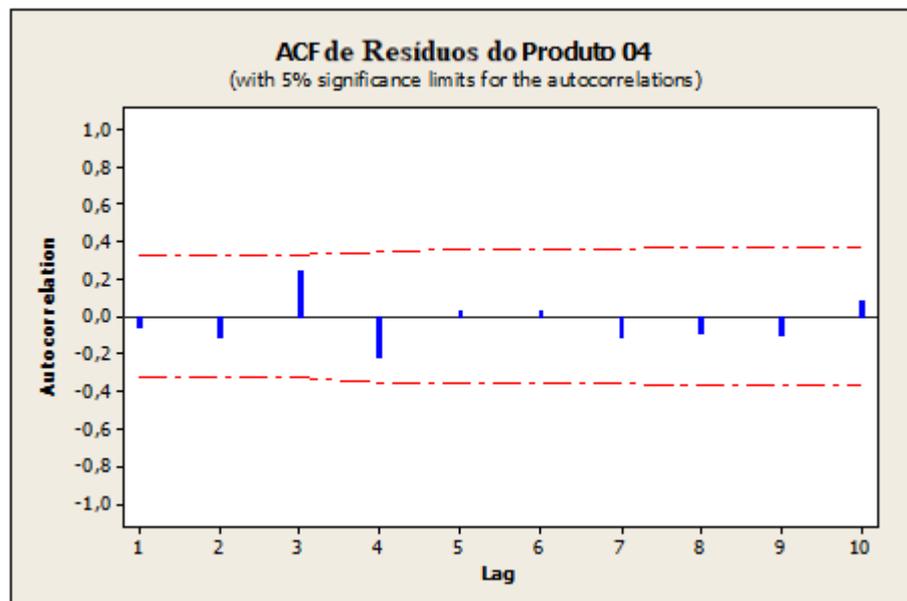
Figura 30 – Previsões produto 4



Fonte: O próprio autor.

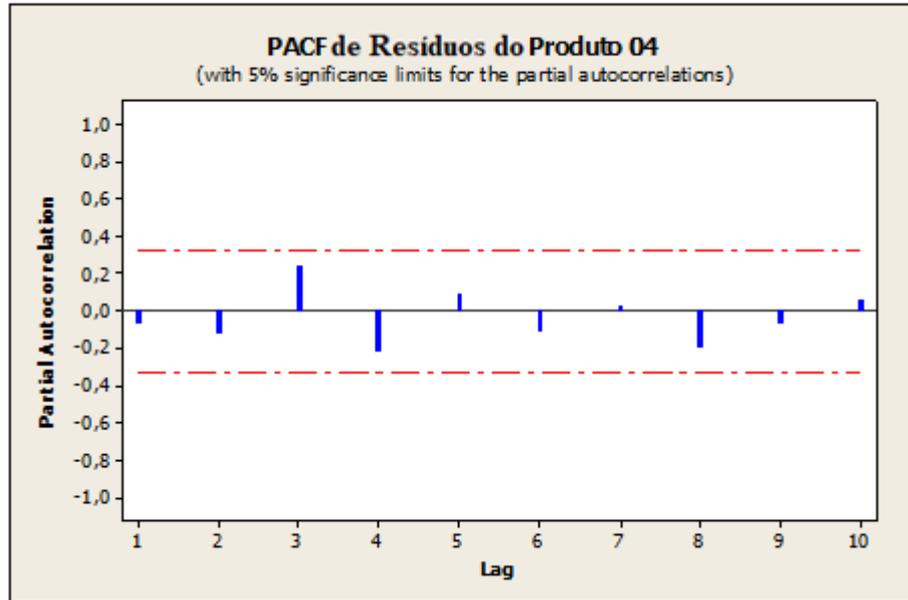
De acordo com os gráficos ACF e PACF não rejeitamos o modelo (as autocorrelações estão dentro da faixa de aceitação). Da mesma forma aceitar o modelo usando o teste de Ljung-Box (Chi-Square statistics, valor- $p > 0,05$), apresentados nas figuras 31 e 32.

Figura 31 – ACF produto 4



Fonte: O próprio autor.

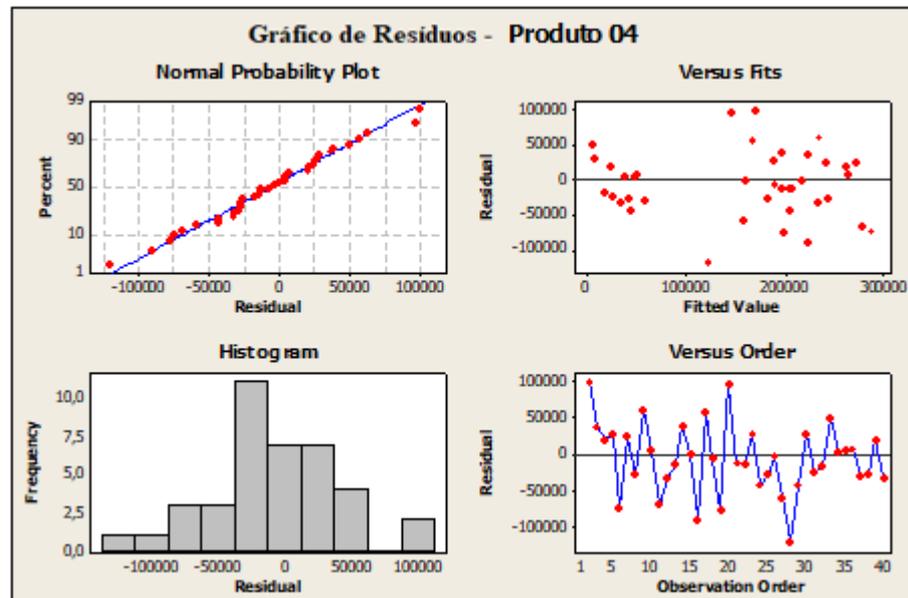
Figura 32 – PACF produto 4



Fonte: O próprio autor.

A figura 33, apresenta os resíduos do modelo. Observa-se excelente ajuste do modelo e que as suposições necessárias (normalidade dos resíduos, variância constante) são verificadas.

Figura 33 – Resíduos produto 4



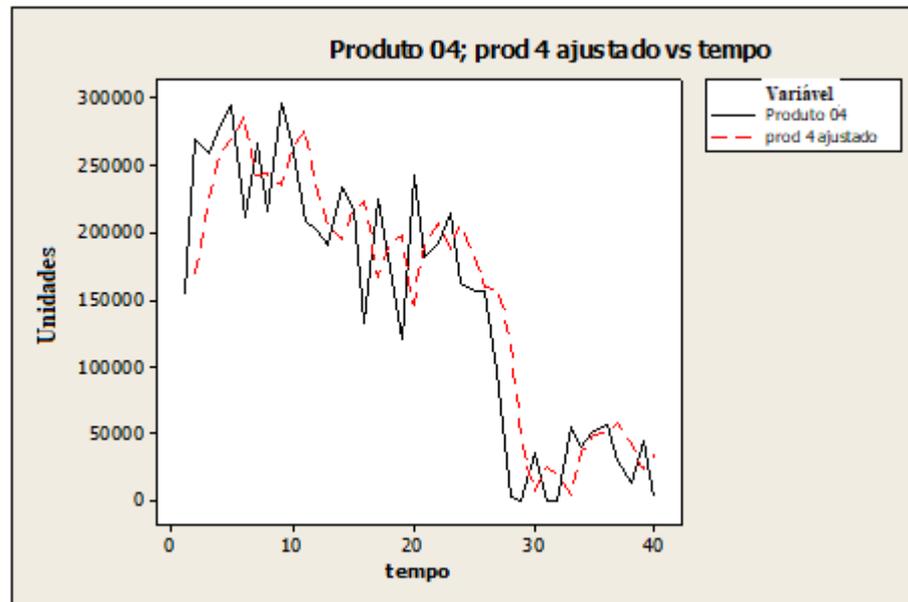
Fonte: O próprio autor.

Assim, observa-se a partir da figura 33, que os resíduos estão próximos da reta no gráfico de probabilidade normal, uma indicação de bom ajuste da distribuição normal aos

resíduos. Da mesma forma observa-se que o gráfico de resíduos versus valores ajustados mostra uma variabilidade dentro de uma faixa, uma indicação de variância constante.

Como o modelo ARIMA está com uma boa aderência de acordo com a literatura, foi gerado um gráfico de ajuste com o tempo, como apresentado na figura 34 para o produto 4.

Figura 34 – Ajuste com tempo produto 4



Fonte: O próprio autor.

- **Produto 5**

Para o produto 5, os estimadores para o modelo ARIMA considerado obtidos são dados na Tabela 11.

Tabela 11 – Estimadores dos Parâmetros e intervalos de confiança 95% (prod. 5)

Esimativas Finais de Parâmetros					
Type		Coef	SE Coef	T	P
AR	1	0,4266	0,2213	1,93	0,062
AR	2	-0,1243	0,1919	-0,65	0,521
MA	1	0,8186	0,1607	5,09	0,000

Fonte: O próprio autor.

De forma visual, observa-se a aderência do modelo em função dos dados. Com isso, realizou-se a previsão para os próximos 5 períodos e a matriz com seus valores previstos são apresentados na Tabela 12.

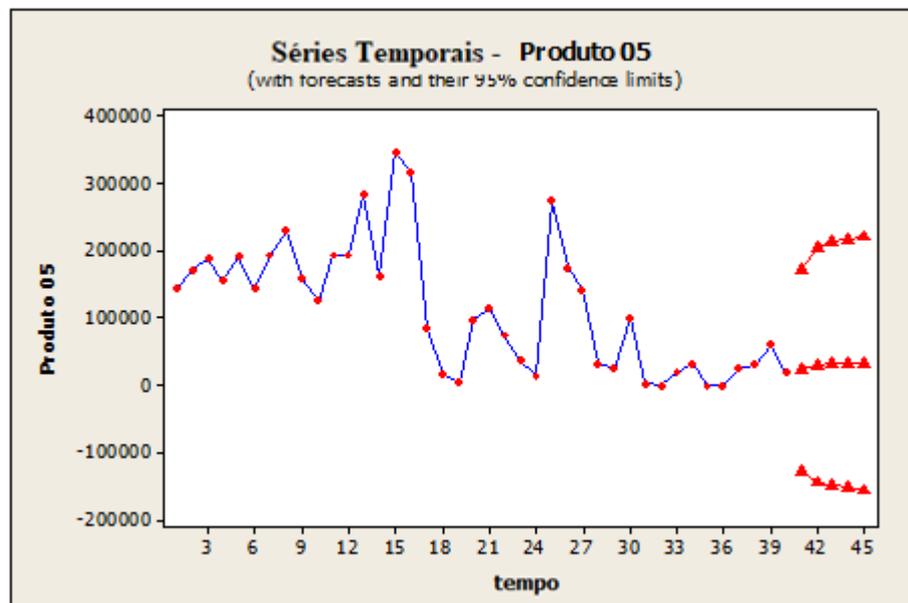
Tabela 12 – Previsões produto 5

Previsões após o período 40			
Períodos	Previsões	95% Limits	
		Inferior	Superior
41	22123	-127645	171891
42	29454	-145822	204730
43	32032	-149540	213603
44	32220	-152899	217339
45	31980	-156735	220694

Fonte: O próprio autor.

O modelo se mostrou aderente em função dos dados e seus valores estão dentro dos intervalos de confiança. Para melhor visualização, a figura 35 mostra os valores reais e os valores previstos.

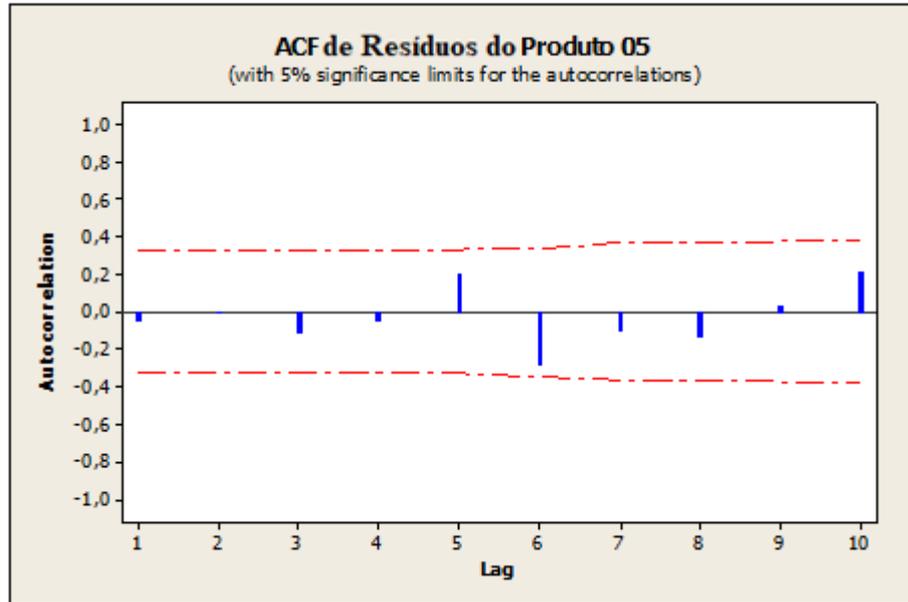
Figura 35 – Previsões produto 5



Fonte: O próprio autor.

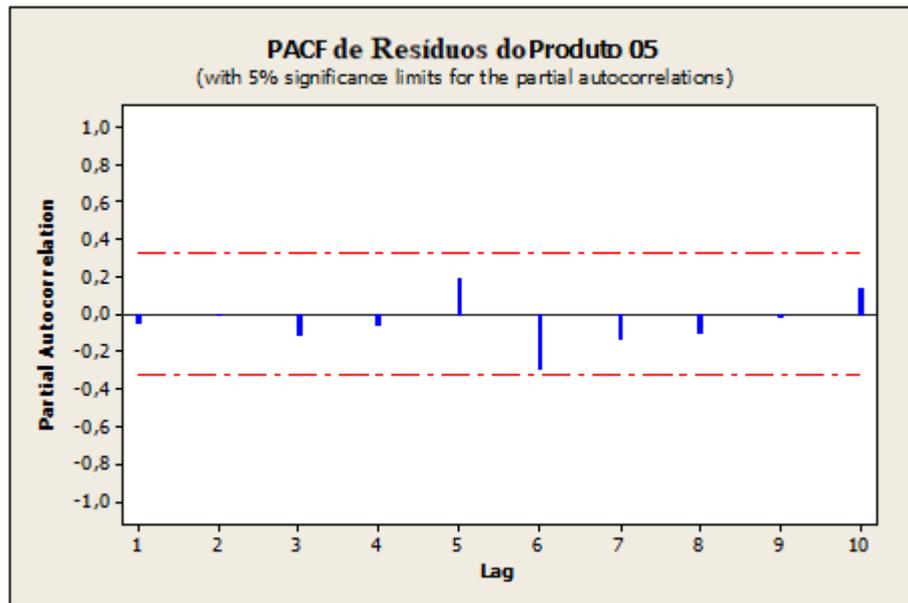
De acordo com os gráficos ACF e PACF não rejeitamos o modelo (as autocorrelações estão dentro da faixa de aceitação). Da mesma forma aceitar o modelo usando o teste de Ljung-Box (Chi-Square statistics, valor-p > 0,05), apresentados nas figuras 36 e 37.

Figura 36 – ACF produto 5



Fonte: O próprio autor.

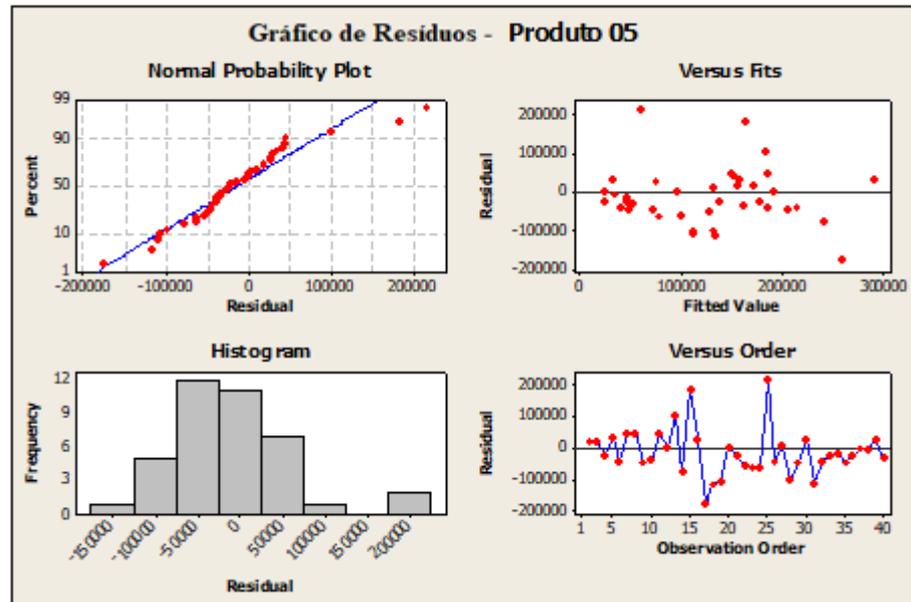
Figura 37 – PACF produto 5



Fonte: O próprio autor.

A figura 38, apresenta os resíduos do modelo. Observa-se excelente ajuste do modelo e que as suposições necessárias (normalidade dos resíduos, variância constante) são verificadas.

Figura 38 – Resíduos produto 5

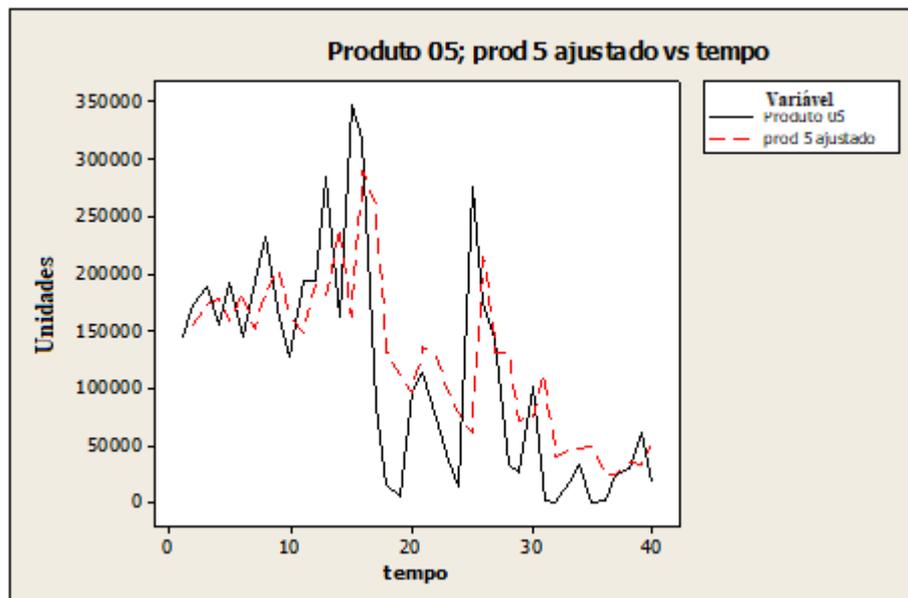


Fonte: O próprio autor.

Assim, observa-se a partir da figura 38, que os resíduos estão próximos da reta no gráfico de probabilidade normal, uma indicação de bom ajuste da distribuição normal aos resíduos. Da mesma forma observa-se que o gráfico de resíduos versus valores ajustados mostra uma variabilidade dentro de uma faixa, uma indicação de variância constante.

Como o modelo ARIMA está com uma boa aderência de acordo com a literatura, foi gerado um gráfico de ajuste com o tempo, como apresentado na figura 39 para o produto 5.

Figura 39 – Ajuste com tempo produto 5



Fonte: O próprio autor.

- **Produto 6**

Para o produto 6, os estimadores para o modelo ARIMA considerado obtidos são dados na Tabela 13.

Tabela 13 – Estimadores dos Parâmetros e intervalos de confiança 95% (prod. 6)

Estimativas Finais de Parâmetros					
Type		Coef	SE Coef	T	P
AR	1	0,6656	0,1644	4,05	0,000
AR	2	0,2206	0,1632	1,35	0,185
MA	1	1,0387	0,0024	436,30	0,000

Fonte: O próprio autor.

De forma visual, observa-se a aderência do modelo em função dos dados. Com isso, realizou-se a previsão para os próximos 5 períodos e a matriz com seus valores previstos são apresentados na Tabela 14.

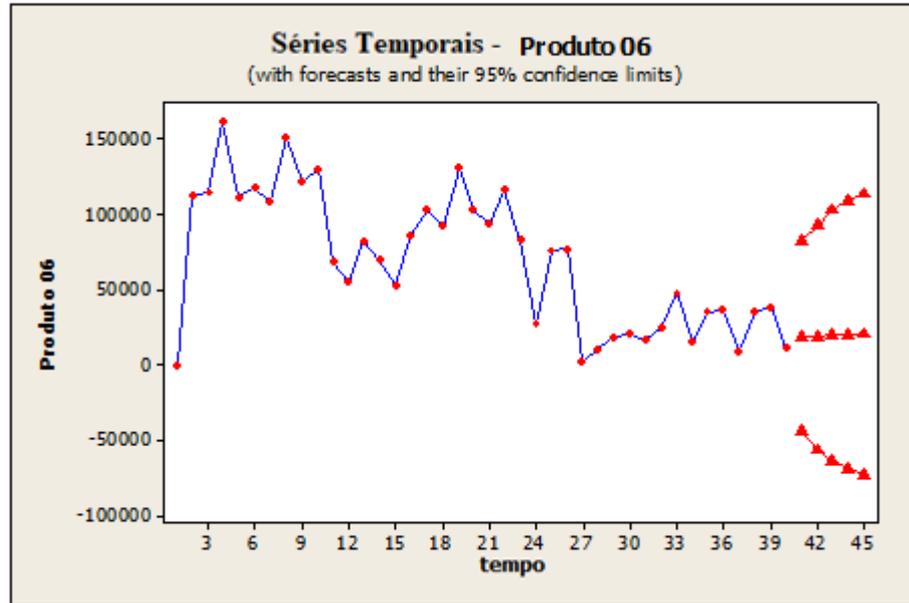
Tabela 14 – Previsões produto 6

Períodos	Previsões	95% Limits	
		Inferior	Superior
41	18957	-44283	82197
42	18096	-56544	92737
43	19235	-64476	102947
44	19803	-69649	109256
45	20433	-72978	113843

Fonte: O próprio autor.

O modelo se mostrou aderente em função dos dados e seus valores estão dentro dos intervalos de confiança. Para melhor visualização, a figura 40 mostra os valores reais e os valores previstos.

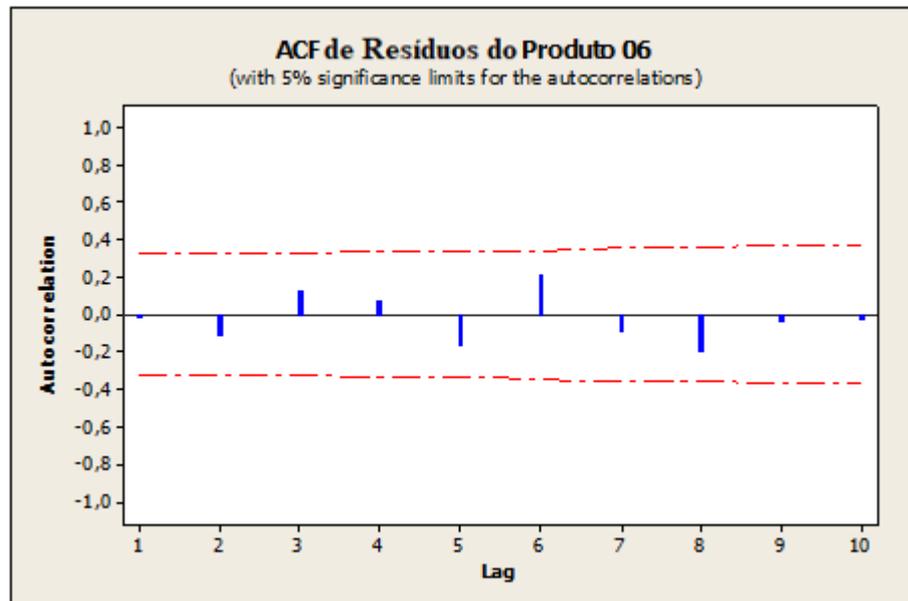
Figura 40 – Previsões produto 6



Fonte: O próprio autor.

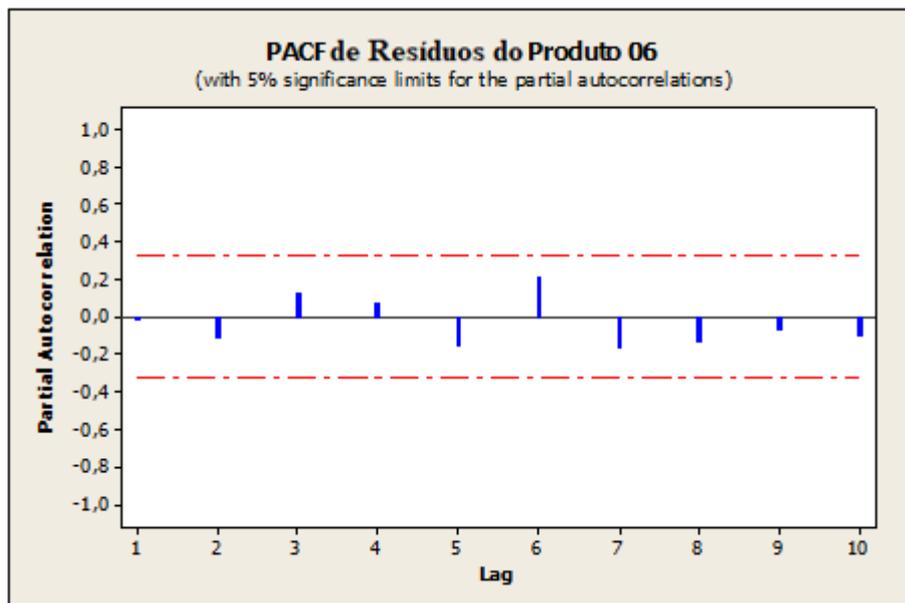
De acordo com os gráficos ACF e PACF não rejeitamos o modelo (as autocorrelações estão dentro da faixa de aceitação). Da mesma forma aceitar o modelo usando o teste de Ljung-Box (Chi-Square statistics, valor-p > 0,05), apresentados nas figuras 41 e 42.

Figura 41 – ACF produto 6



Fonte: O próprio autor.

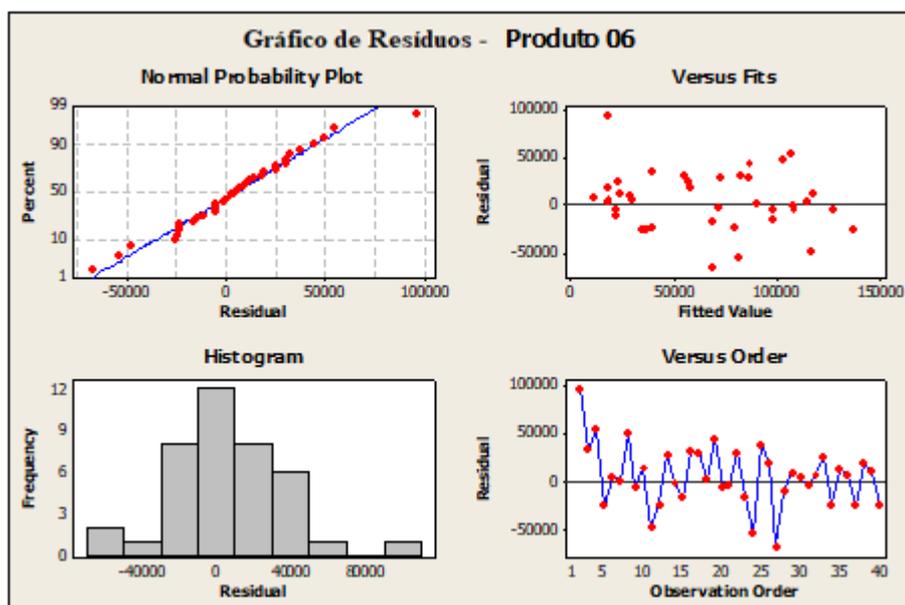
Figura 42 – PACF produto 6



Fonte: O próprio autor.

A figura 43, apresenta os resíduos do modelo. Observa-se excelente ajuste do modelo e que as suposições necessárias (normalidade dos resíduos, variância constante) são verificadas.

Figura 43 – Resíduos produto 6

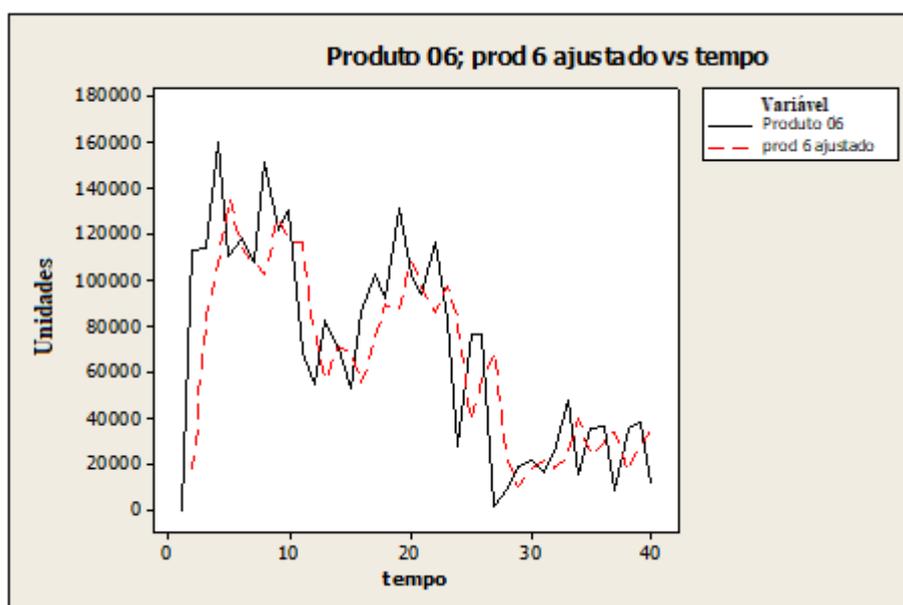


Fonte: O próprio autor.

Assim, observa-se a partir da figura 43, que os resíduos estão próximos da reta no gráfico de probabilidade normal, uma indicação de bom ajuste da distribuição normal aos resíduos. Da mesma forma observa-se que o gráfico de resíduos versus valores ajustados mostra uma variabilidade dentro de uma faixa, uma indicação de variância constante.

Como o modelo ARIMA está com uma boa aderência de acordo com a literatura, foi gerado um gráfico de ajuste com o tempo, como apresentado na figura 44 para o produto 6.

Figura 44 – Ajuste com tempo produto 6



Fonte: O próprio autor.

- **Produto 7**

Para o produto 7, os estimadores para o modelo ARIMA considerado obtidos são dados na Tabela 15.

Tabela 15 – Estimadores dos Parâmetros e intervalos de confiança 95% (prod. 7)

Estimativas Finais de Parâmetros					
Type		Coef	SE Coef	T	P
AR	1	0,6047	0,1372	4,41	0,000
AR	2	0,3951	0,1373	2,88	0,007
MA	1	1,0344	0,0018	572,63	0,000

Fonte: O próprio autor.

De forma visual, observa-se a aderência do modelo em função dos dados. Com isso, realizou-se a previsão para os próximos 5 períodos e a matriz com seus valores previstos são apresentados na Tabela 16.

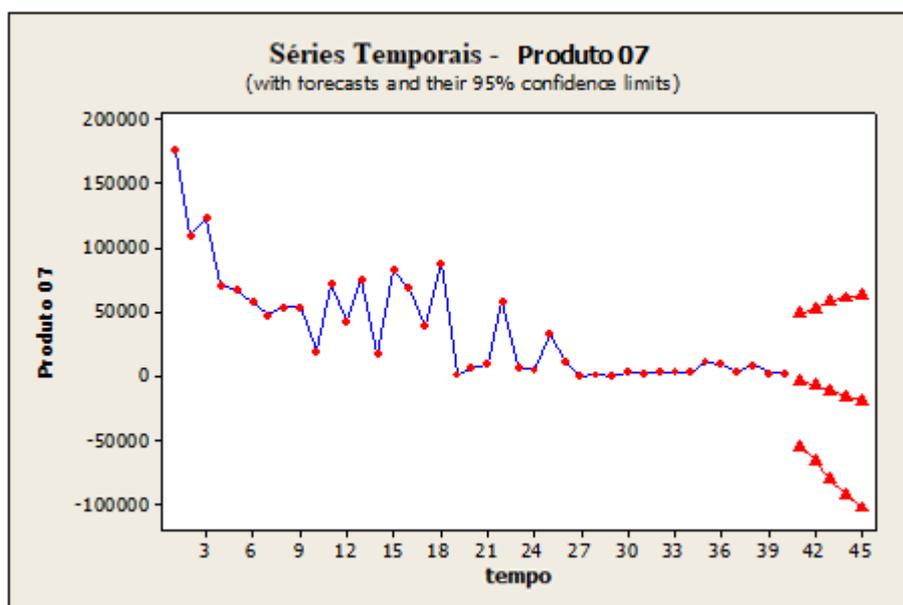
Tabela 16 – Previsões produto 7

Previsões após o período 40			
Períodos	Previsões	95% Limits	
		Inferior	Superior
41	-3014	-54772	48743
42	-6689	-66271	52893
43	-11208	-81091	58674
44	-15393	-92238	61452
45	-19709	-102942	63523

Fonte: O próprio autor.

O modelo se mostrou aderente em função dos dados e seus valores estão dentro dos intervalos de confiança. Para melhor visualização, a figura 45 mostra os valores reais e os valores previstos.

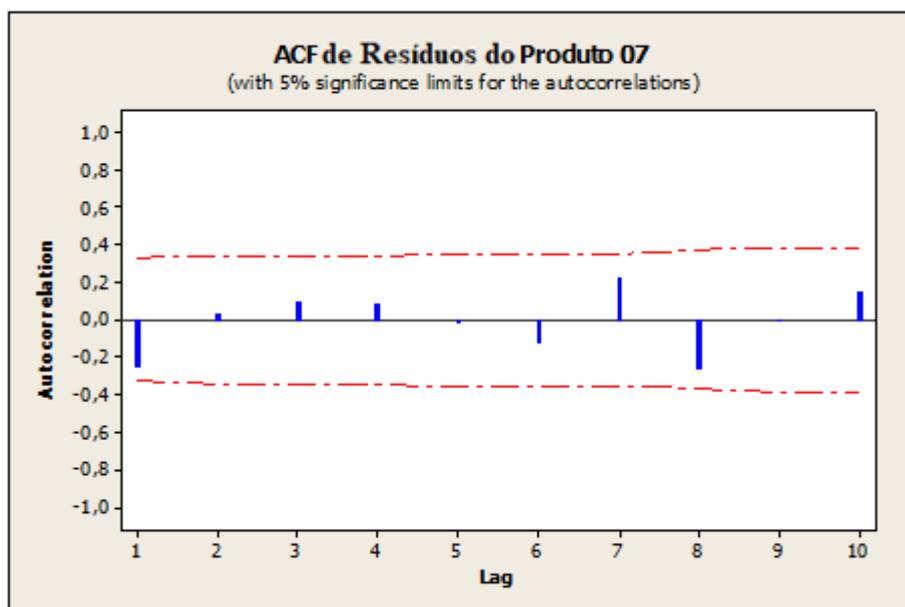
Figura 45 – Previsões produto 7



Fonte: O próprio autor.

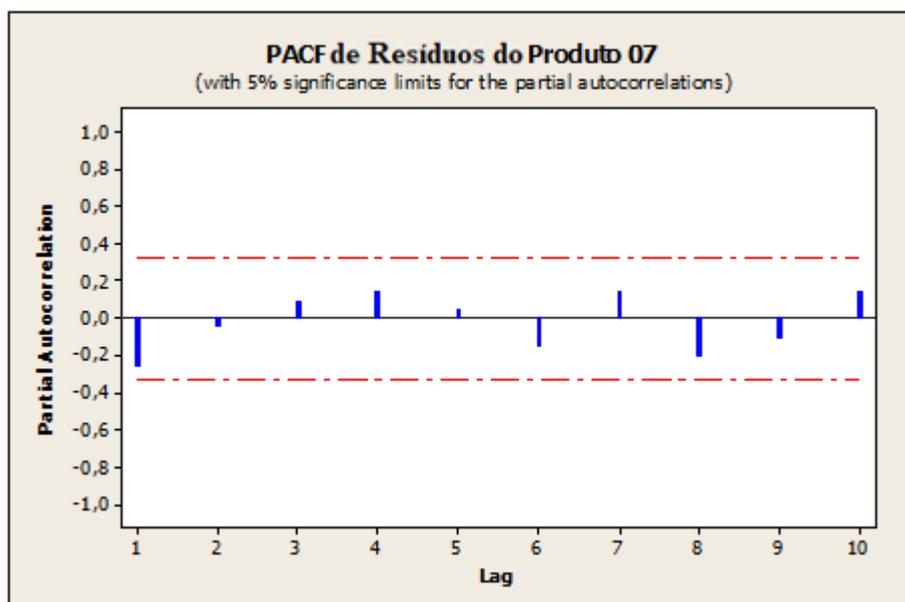
De acordo com os gráficos ACF e PACF não rejeitamos o modelo (as autocorrelações estão dentro da faixa de aceitação). Da mesma forma aceitar o modelo usando o teste de Ljung-Box (Chi-Square statistics, valor-p > 0,05), apresentados nas figuras 46 e 47.

Figura 46 – ACF produto 7



Fonte: O próprio autor.

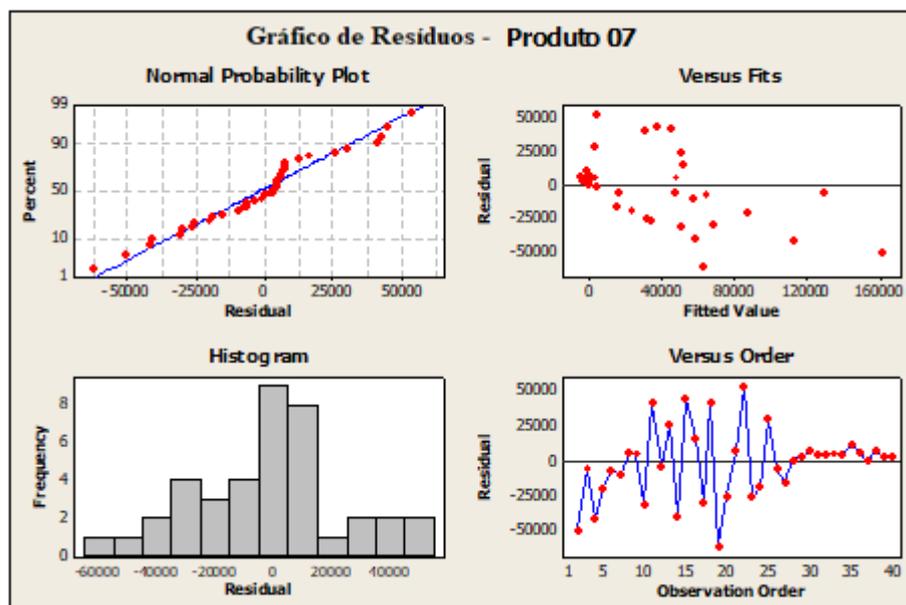
Figura 47 – PACF produto 7



Fonte: O próprio autor.

A figura 48, apresenta os resíduos do modelo. Observa-se excelente ajuste do modelo e que as suposições necessárias (normalidade dos resíduos, variância constante) são verificadas.

Figura 48 – Resíduos produto 7

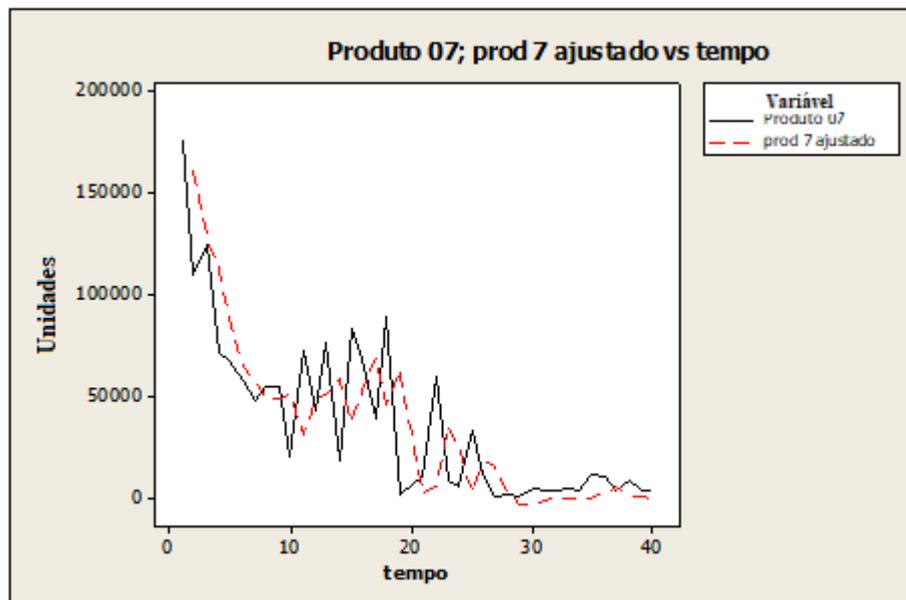


Fonte: O próprio autor.

Assim, observa-se a partir da figura 48, que os resíduos estão próximos da reta no gráfico de probabilidade normal, uma indicação de bom ajuste da distribuição normal aos resíduos. Da mesma forma observa-se que o gráfico de resíduos versus valores ajustados mostra uma variabilidade dentro de uma faixa, uma indicação de variância constante.

Como o modelo ARIMA está com uma boa aderência de acordo com a literatura, foi gerado um gráfico de ajuste com o tempo, como apresentado na figura 49 para o produto 7.

Figura 49 – Ajuste com tempo produto 7



Fonte: O próprio autor.

- **Produto 8**

Para o produto 8, os estimadores para o modelo ARIMA considerado obtidos são dados na Tabela 17.

Tabela 17 – Estimadores dos Parâmetros e intervalos de confiança 95% (prod. 8)

Estimativas Finais de Parâmetros					
Type		Coef	SE Coef	T	P
AR	1	0,3613	0,7628	0,47	0,639
AR	2	0,2229	0,3838	0,58	0,565
MA	1	0,7663	0,7250	1,06	0,298

Fonte: O próprio autor.

De forma visual, observa-se a aderência do modelo em função dos dados. Com isso, realizou-se a previsão para os próximos 5 períodos e a matriz com seus valores previstos são apresentados na Tabela 18.

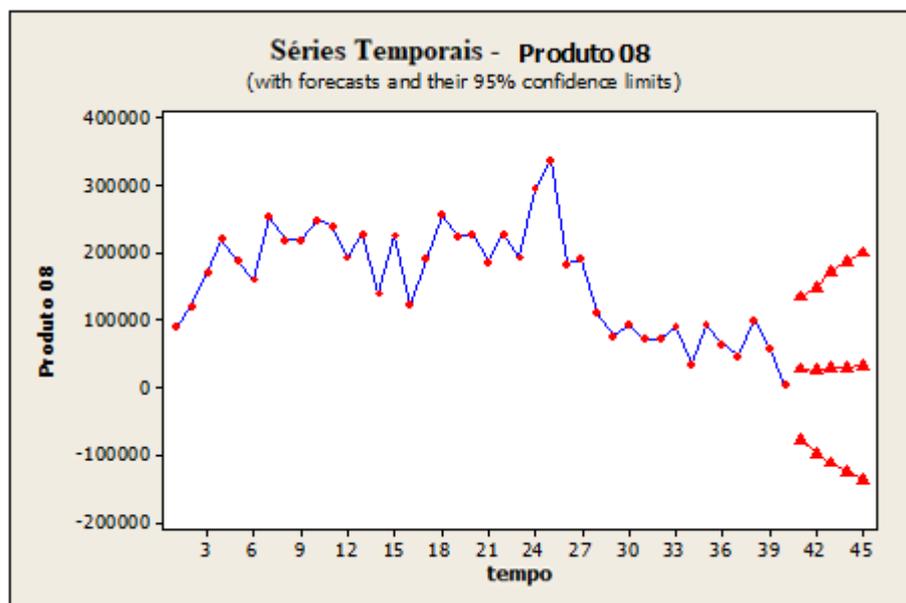
Tabela 18 – Previsões produto 8

Previsões após o período 40			
Períodos	Previsões	95% Limits	
		Inferior	Superior
41	29014	-76570	134599
42	25830	-97028	148688
43	29880	-111972	171732
44	30633	-125109	186376
45	31808	-136461	200078

Fonte: O próprio autor.

O modelo se mostrou aderente em função dos dados e seus valores estão dentro dos intervalos de confiança. Para melhor visualização, a figura 50 mostra os valores reais e os valores previstos.

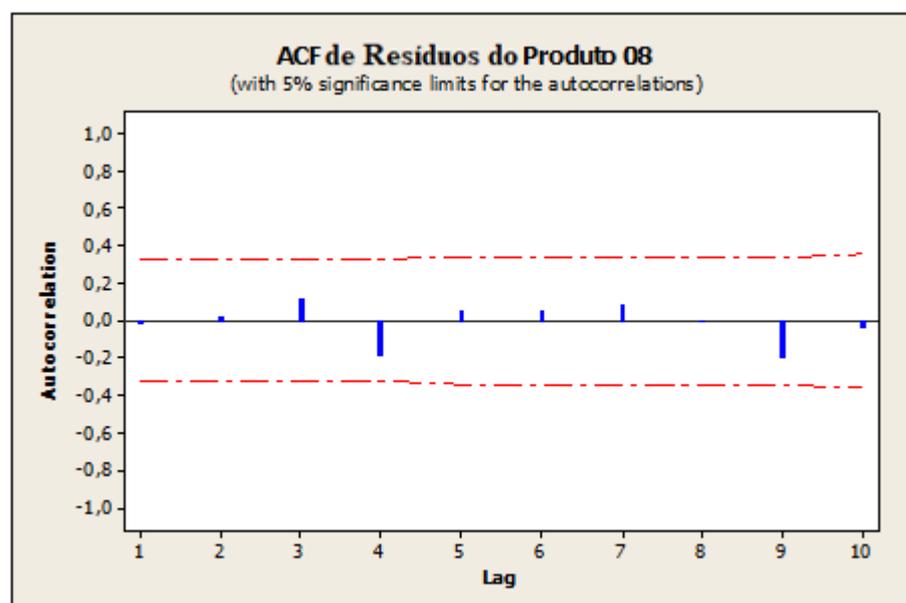
Figura 50 - Previsões produto 8



Fonte: O próprio autor.

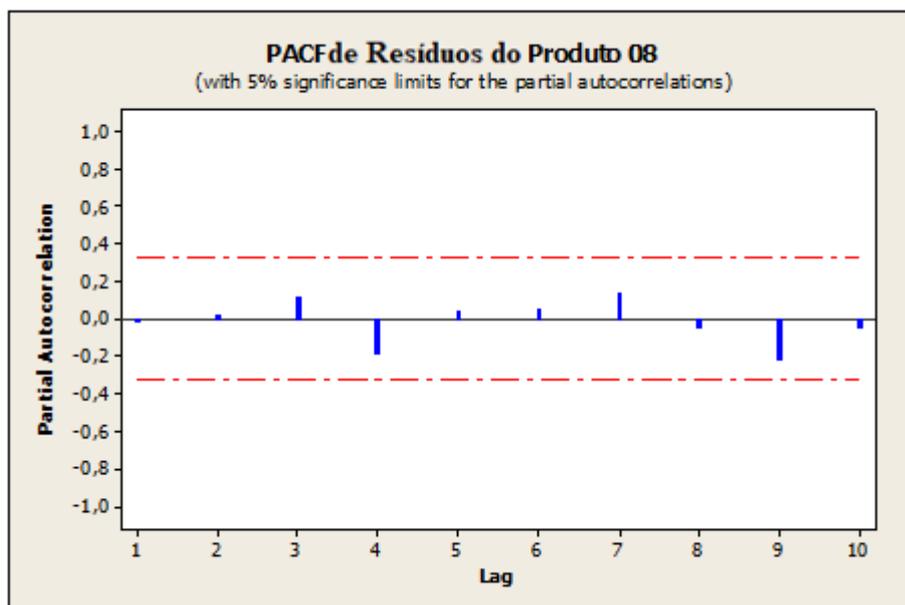
De acordo com os gráficos ACF e PACF não rejeitamos o modelo (as autocorrelações estão dentro da faixa de aceitação). Da mesma forma aceitar o modelo usando o teste de Ljung-Box (Chi-Square statistics, valor-p > 0,05), apresentados nas figuras 51 e 52.

Figura 51 – ACF produto 8



Fonte: O próprio autor.

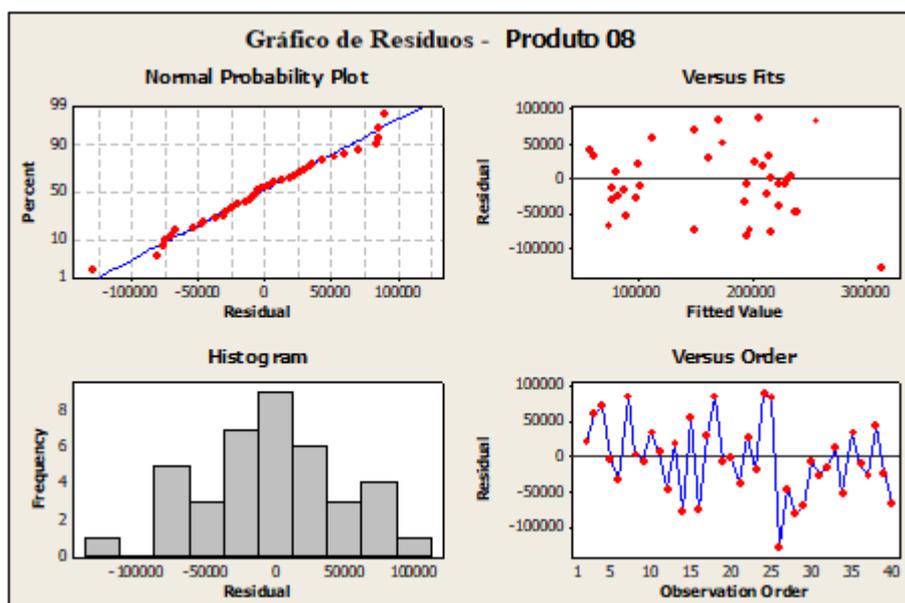
Figura 52 – PACF produto 8



Fonte: O próprio autor.

A figura 53, apresenta os resíduos do modelo. Observa-se excelente ajuste do modelo e que as suposições necessárias (normalidade dos resíduos, variância constante) são verificadas.

Figura 53 – Resíduos produto 8



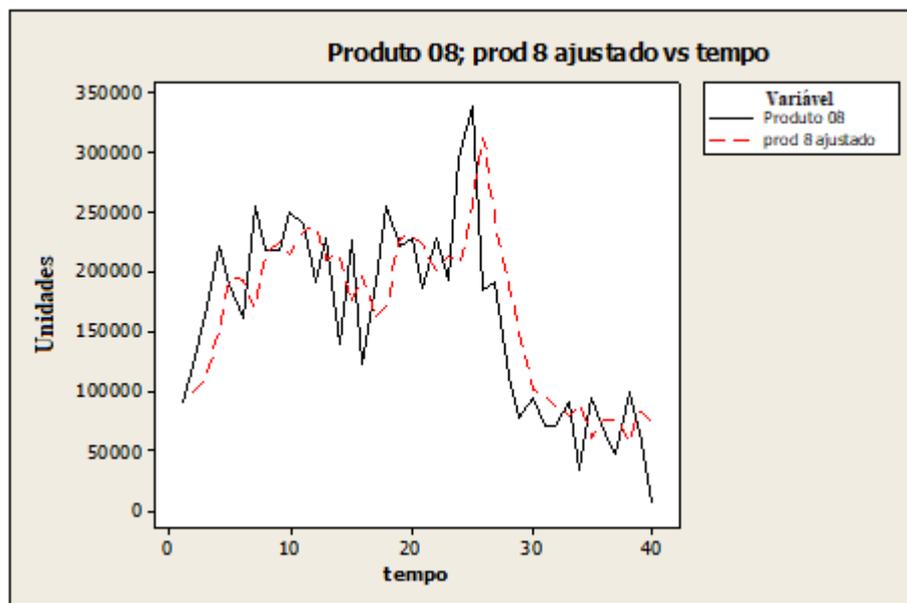
Fonte: O próprio autor.

Assim, observa-se a partir da figura 53, que os resíduos estão próximos da reta no gráfico de probabilidade normal, uma indicação de bom ajuste da distribuição normal aos

resíduos. Da mesma forma observa-se que o gráfico de resíduos versus valores ajustados mostra uma variabilidade dentro de uma faixa, uma indicação de variância constante.

Como o modelo ARIMA está com uma boa aderência de acordo com a literatura, foi gerado um gráfico de ajuste com o tempo, como apresentado na figura 54 para o produto 8.

Figura 54 – Ajuste com tempo produto 8



Fonte: O próprio autor.

- **Produto 9**

Para o produto 9, os estimadores para o modelo ARIMA considerado obtidos são dados na Tabela 19.

Tabela 19 – Estimadores dos Parâmetros e intervalos de confiança 95% (prod. 9)

Estimativas Finais de Parâmetros					
Type		Coef	SE Coef	T	P
AR	1	-1,1497	1,3924	-0,83	0,414
AR	2	-0,2808	0,7174	-0,39	0,698
MA	1	-0,7149	1,3502	-0,53	0,600

Fonte: O próprio autor.

De forma visual, observa-se a aderência do modelo em função dos dados. Com isso, realizou-se a previsão para os próximos 5 períodos e a matriz com seus valores previstos são apresentados na Tabela 20.

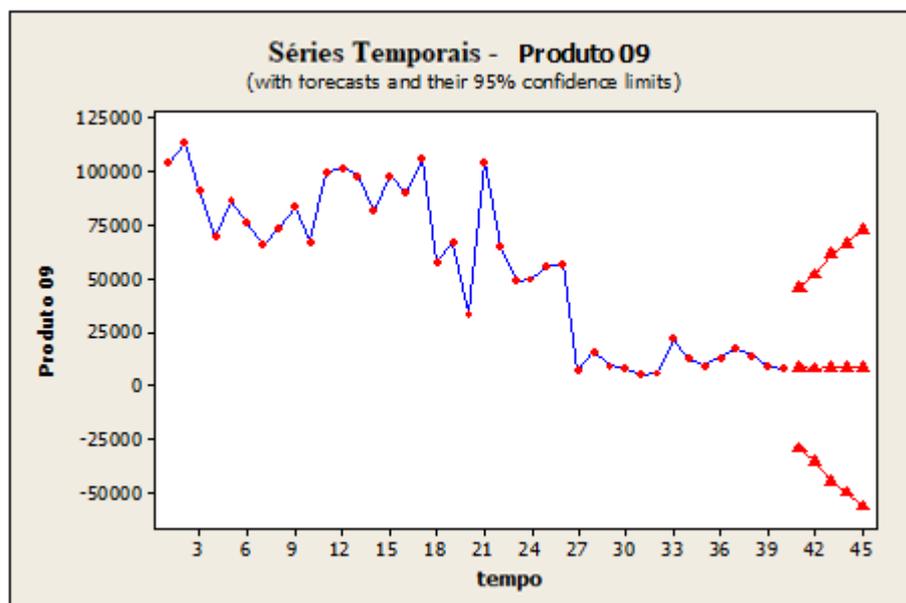
Tabela 20 – Previsões produto 9

Previsões após o período 40			
Períodos	Previsões	95% Limits	
		Inferior	Superior
41	8535,7	-29536,7	46608,1
42	8481,6	-35249,6	52212,7
43	8514,1	-44439,1	61467,3
44	8491,9	-50030,0	67013,8
45	8508,3	-56478,4	73495,1

Fonte: O próprio autor.

O modelo se mostrou aderente em função dos dados e seus valores estão dentro dos intervalos de confiança. Para melhor visualização, a figura 55 mostra os valores reais e os valores previstos.

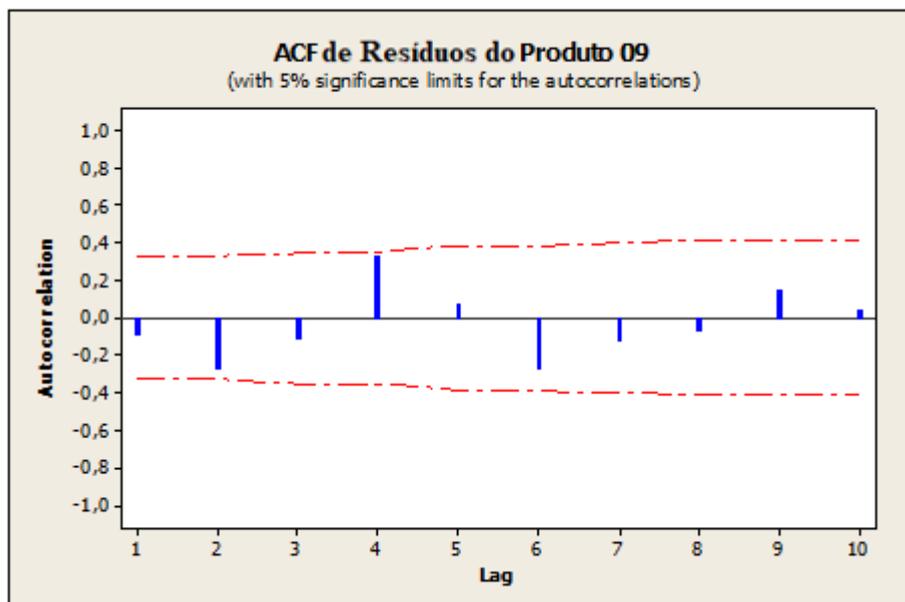
Figura 55 - Previsões produto 9



Fonte: O próprio autor.

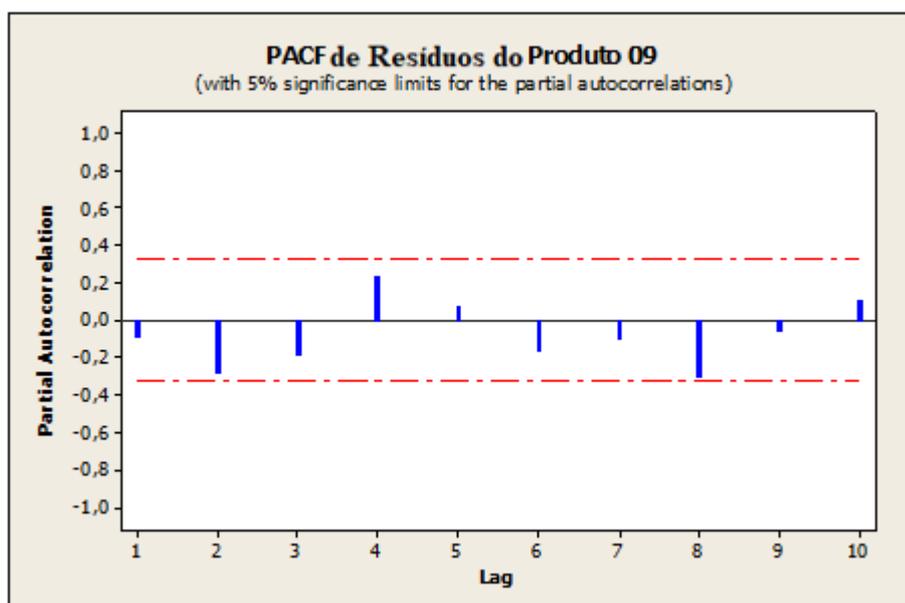
De acordo com os gráficos ACF e PACF não rejeitamos o modelo (as autocorrelações estão dentro da faixa de aceitação). Da mesma forma aceitar o modelo usando o teste de Ljung-Box (Chi-Square statistics, valor-p > 0,05), apresentados nas figuras 56 e 57.

Figura 56 – ACF produto 9



Fonte: O próprio autor.

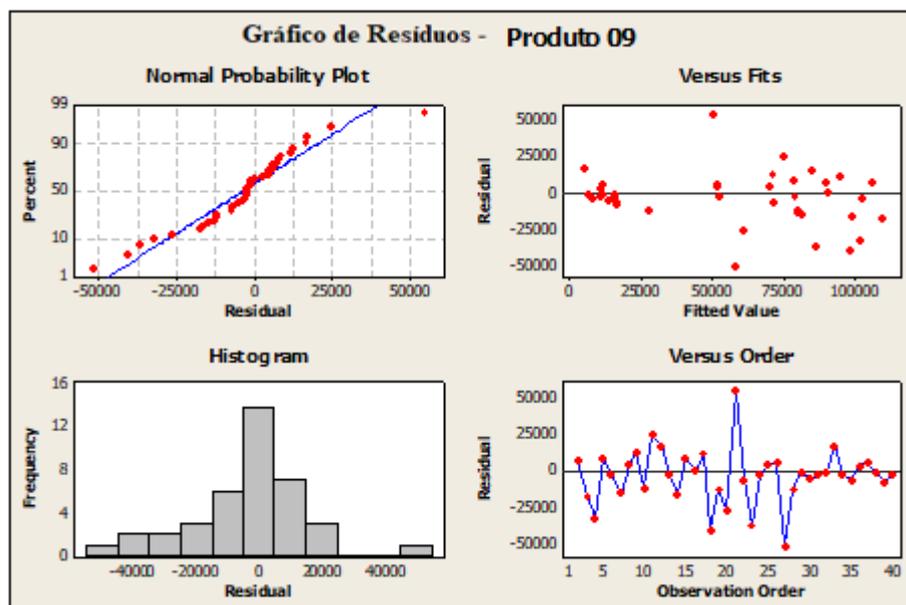
Figura 57 – PACF produto 9



Fonte: O próprio autor.

A figura 58, apresenta os resíduos do modelo. Observa-se excelente ajuste do modelo e que as suposições necessárias (normalidade dos resíduos, variância constante) são verificadas.

Figura 58 – Resíduos produto 9

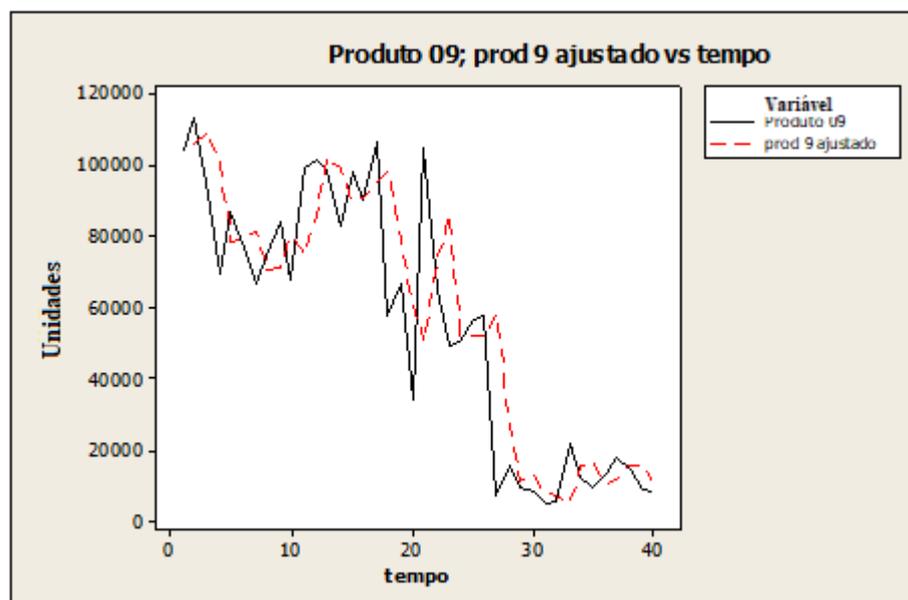


Fonte: O próprio autor.

Assim, observa-se a partir da figura 58, que os resíduos estão próximos da reta no gráfico de probabilidade normal, uma indicação de bom ajuste da distribuição normal aos resíduos. Da mesma forma observa-se que o gráfico de resíduos versus valores ajustados mostra uma variabilidade dentro de uma faixa, uma indicação de variância constante.

Como o modelo ARIMA está com uma boa aderência de acordo com a literatura, foi gerado um gráfico de ajuste com o tempo, como apresentado na figura 59 para o produto 9.

Figura 59 – Ajuste com tempo produto 9



Fonte: O próprio autor.

- **Produto 10**

Para o produto 10, os estimadores para o modelo ARIMA considerado obtidos são dados na Tabela 21.

Tabela 21 – Estimadores dos Parâmetros e intervalos de confiança 95% (prod. 10)

Estimativas Finais de Parâmetros					
Type		Coef	SE Coef	T	P
AR	1	-0,0903	0,3224	-0,28	0,781
AR	2	-0,2595	0,2187	-1,19	0,243
MA	1	0,4603	0,3163	1,46	0,154

Fonte: O próprio autor.

De forma visual, observa-se a aderência do modelo em função dos dados. Com isso, realizou-se a previsão para os próximos 5 períodos e a matriz com seus valores previstos são apresentados na Tabela 22.

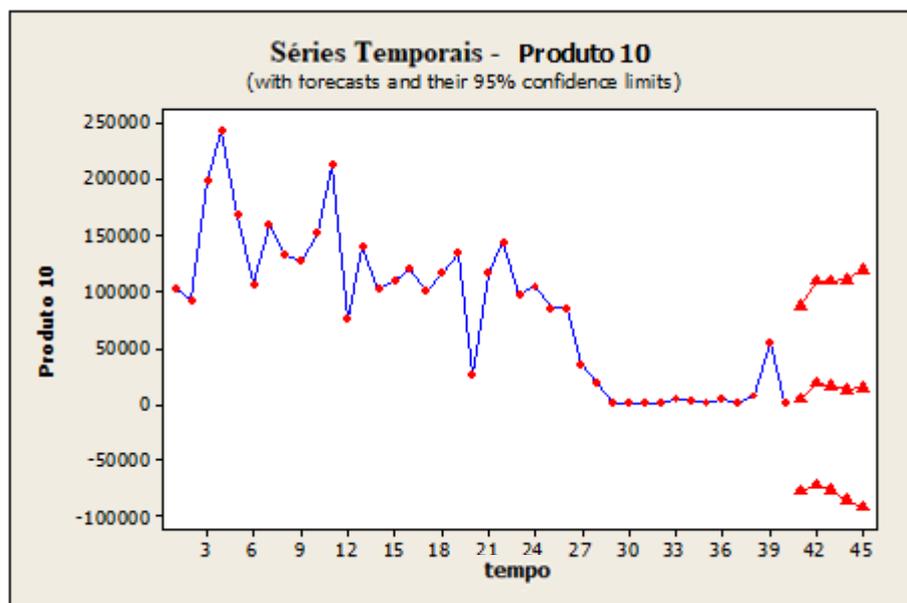
Tabela 22 – Previsões produto 10

Períodos	Previsões	95% Limits	
		Inferior	Superior
41	4653	-77846	87151
42	18412	-72031	108856
43	16118	-76459	108695
44	12754	-85568	111075
45	13653	-91190	118496

Fonte: O próprio autor.

O modelo se mostrou aderente em função dos dados e seus valores estão dentro dos intervalos de confiança. Para melhor visualização, a figura 60 mostra os valores reais e os valores previstos.

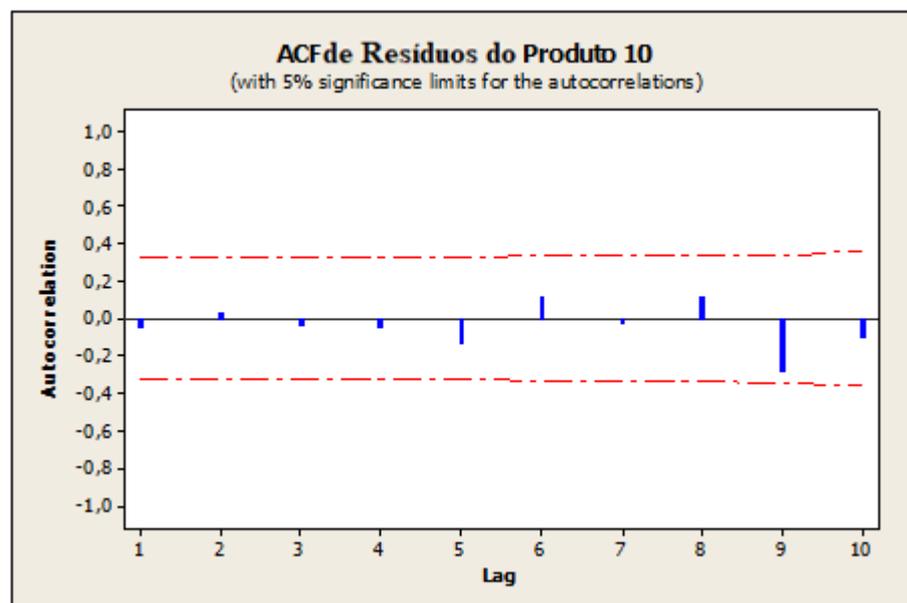
Figura 60 – Previsões produto 10



Fonte: O próprio autor.

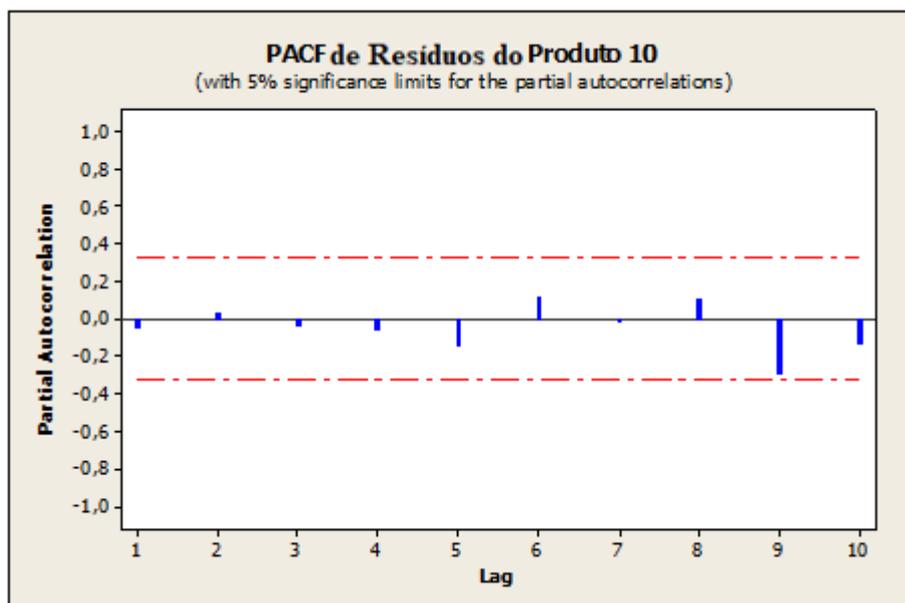
De acordo com os gráficos ACF e PACF não rejeitamos o modelo (as autocorrelações estão dentro da faixa de aceitação). Da mesma forma aceitar o modelo usando o teste de Ljung-Box (Chi-Square statistics, valor-p > 0,05), apresentados nas Figuras 61 e 62.

Figura 61 – ACF produto 10



Fonte: O próprio autor.

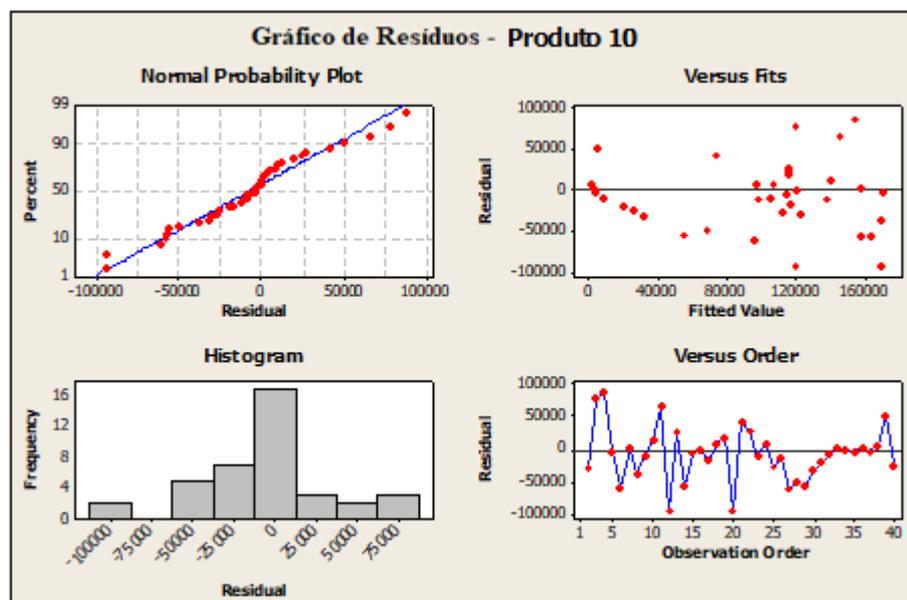
Figura 62 – PACF produto 10



Fonte: O próprio autor.

A figura 63, apresenta os resíduos do modelo. Observa-se excelente ajuste do modelo e que as suposições necessárias (normalidade dos resíduos, variância constante) são verificadas.

Figura 63 – Resíduos produto 10

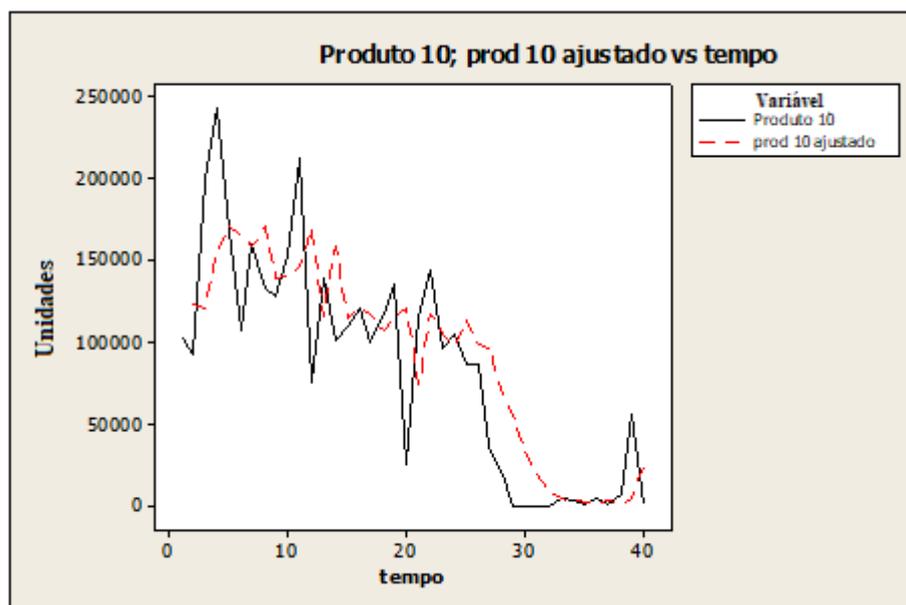


Fonte: O próprio autor.

Assim, observa-se a partir da figura 63, que os resíduos estão próximos da reta no gráfico de probabilidade normal, uma indicação de bom ajuste da distribuição normal aos resíduos. Da mesma forma observa-se que o gráfico de resíduos versus valores ajustados mostra uma variabilidade dentro de uma faixa, uma indicação de variância constante.

Como o modelo ARIMA está com uma boa aderência de acordo com a literatura, foi gerado um gráfico de ajuste com o tempo, como apresentado na figura 64 para o produto 10.

Figura 64 – Ajuste com tempo produto 10



Fonte: O próprio autor.

(3) Uso do Modelo de regressão múltipla

Apresentado o problema, define-se como objetivo central deste trabalho verificar o efeito conjunto dessas covariáveis na resposta Y através de técnicas de regressão múltipla (DRAPER E SMITH, 1981; SEBER E LEE, 2003; OU MONTGOMERY E RUNGER, 2011).

Para analisar os dados de produtividade no setor alimentício, utilizou-se um modelo de regressão linear múltiplo, de acordo com a equação (40). Considerando as covariáveis mês, ano, taxa desemprego, PIB, IPCA e taxa de crescimento e considerando a resposta Y produto mensal, supõe-se um modelo de regressão linear múltiplo dado por,

$$y_i = \beta_0 + \beta_1 x_{1i} + \beta_2 x_{2i} + \beta_3 x_{3i} + \beta_4 x_{4i} + \beta_5 x_{5i} + \beta_6 x_{6i} + \varepsilon_i \quad (40)$$

onde $i=1,2,\dots,40$; ε_i são erros aleatórios supostos como independentes, com uma distribuição normal com média zero, e variância constante σ^2 ; x_{1i} denota mês; x_{2i} denota ano; x_{3i} denota taxa desemprego; x_{4i} denota PIB; x_{5i} denota IPCA e x_{6i} taxa crescimento. Estimadores de mínimos quadrados dos coeficientes de regressão do modelo são obtidos usando o software MINITAB versão 16.

- **Produto 1**

Buscando realizar uma previsão por regressão múltipla, pode-se confirmar as covariáveis significativas no produto 1 são: ano e taxa de desemprego mensal (valor-p < 0,05), como representado na Tabela 23.

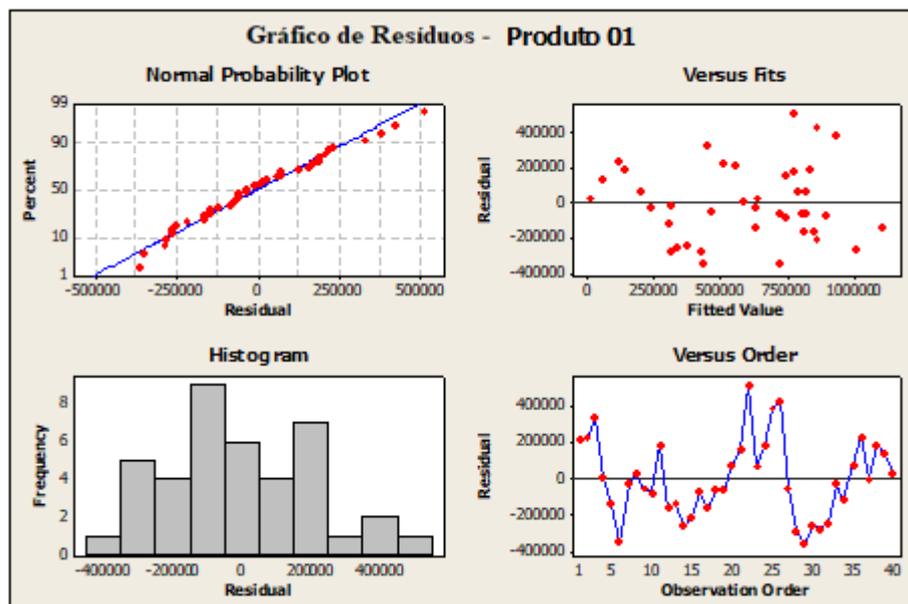
Tabela 23 – Regressão produto 1

	Coef	SE Coef	T	P
Constante	-882403948	450270571	-1,96	0,059
Mês	7619	18411	0,41	0,682
Ano	439335	223728	1,96	0,058
Taxa desemprego	-27941578	8442250	-3,31	0,002
PIB	-2737673	4777757	-0,57	0,571
IPCA	1431251	5238517	0,27	0,786
Crescimento da produção	-3642106	3156537	-1,15	0,257
S = 233369 R-Sq = 63,1% R-Sq(adj) = 56,4%				

Fonte: O próprio autor.

Conforme indica a figura 65 pode-se aceitar o modelo de regressão como válido, visto que uma das premissas é que os resíduos devem possuir uma distribuição normal com média zero e variância constante.

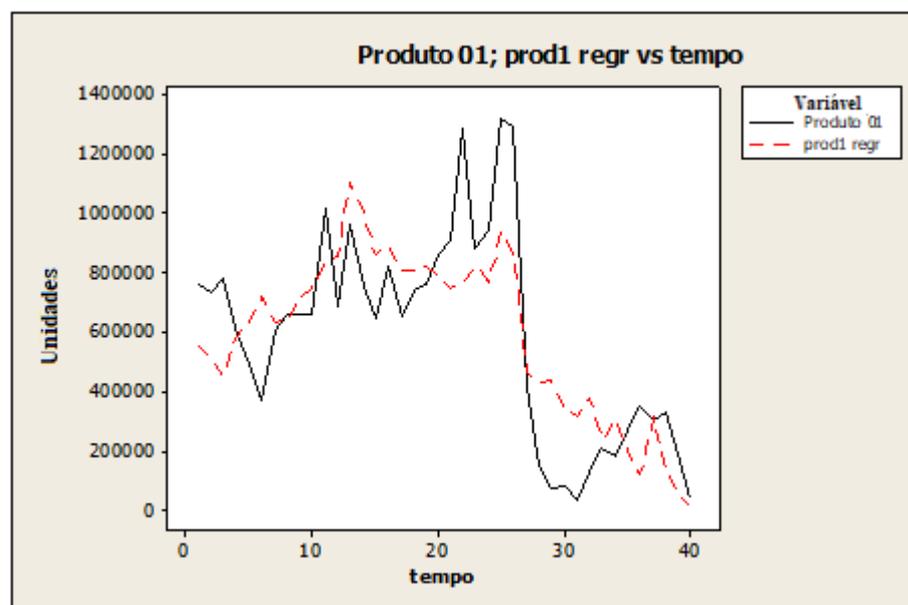
Figura 65 – Resíduos produto 1



Fonte: O próprio autor.

Foi gerado um gráfico de regressão com o tempo, como apresentado na figura 66 para o produto 1.

Figura 66 – Regressão com tempo produto 1



Fonte: O próprio autor.

- **Produto 2**

No produto 2, pode-se confirmar a covariável significativa é taxa de desemprego mensal (valor-p < 0,05), como representado na Tabela 24.

Tabela 24 – Regressão produto 2

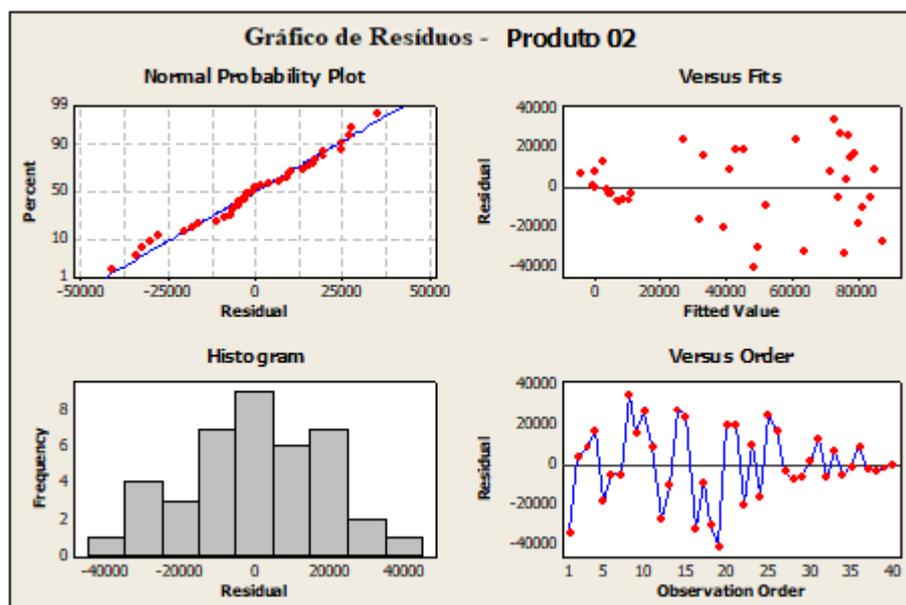
	Coef	SE Coef	T	P
Constante	-6398390	38515993	-0,17	0,869
Mês	-496	1575	-0,31	0,755
Ano	3290	19138	0,17	0,865
Taxa desemprego	-1510998	722147	-2,09	0,044
PIB	-209165	408688	-0,51	0,612
IPCA	-670708	448101	-1,50	0,144
Crescimento da produção	-453246	270009	-1,68	0,103

S = 19962,3 R-Sq = 75,6% R-Sq(adj) = 71,2%

Fonte: O próprio autor.

Conforme indica a figura 67 pode-se aceitar o modelo de regressão como válido, visto que uma das premissas é que os resíduos devem possuir uma distribuição normal com média zero e variância constante.

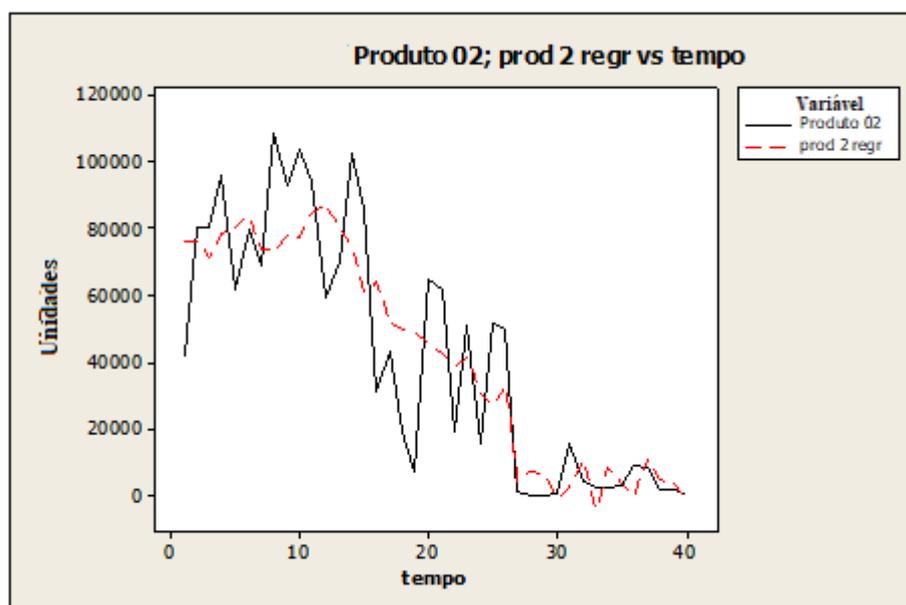
Figura 67 – Resíduos produto 2



Fonte: O próprio autor.

Foi gerado um gráfico de regressão com o tempo, como apresentado na figura 68 para o produto 2.

Figura 68 – Regressão com tempo produto 2



Fonte: O próprio autor.

- **Produto 3**

No produto 3, pode-se confirmar covariáveis significativas são mês e PIB mensal (valor-p < 0,05). Além disso considerando-se um nível de significância igual à 10% a covariável IPCA também mostra significância estatística (valor-p < 0,10), como representado na Tabela 25.

Tabela 25 – Regressão produto 3

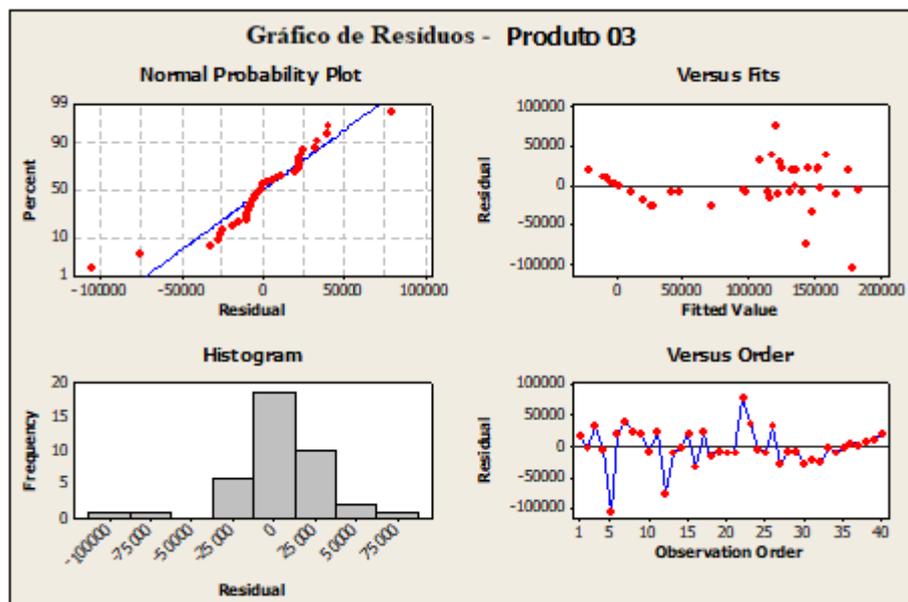
	Coef	SE Coef	T	P
Constante	94719177	64187096	1,48	0,150
Mês	-6264	2625	-2,39	0,023
Ano	-46847	31893	-1,47	0,151
Taxa desemprego	-1282074	1203462	-1,07	0,294
PIB	-1731220	681080	-2,54	0,016
IPCA	-1325370	746763	-1,77	0,085
Crescimento da produção	-641379	449972	-1,43	0,163

S = 33267,2 R-Sq = 81,3% R-Sq(adj) = 77,9%

Fonte: O próprio autor.

Conforme indica a figura 69 pode-se aceitar o modelo de regressão como válido, visto que uma das premissas é que os resíduos devem possuir uma distribuição normal com média zero e variância constante.

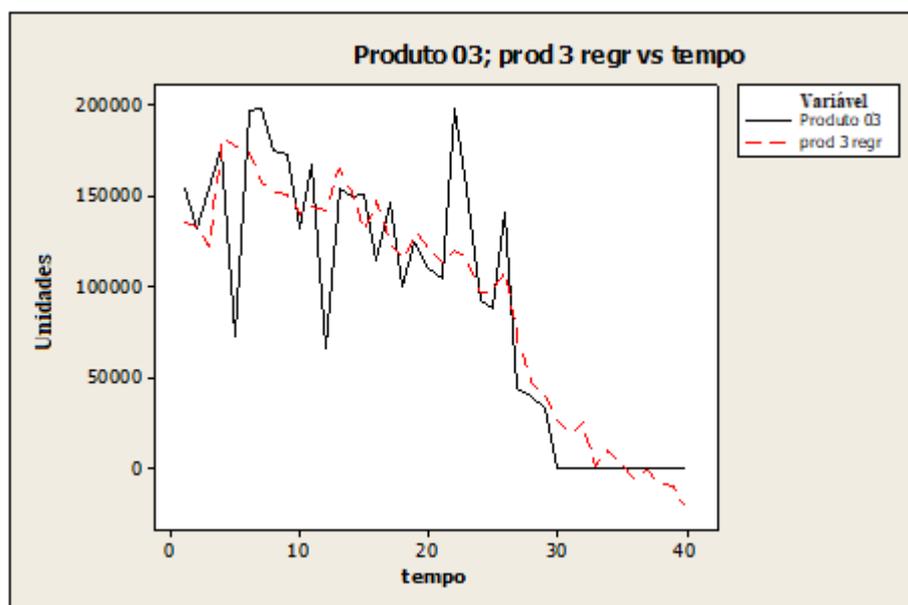
Figura 69 – Resíduos produto 3



Fonte: O próprio autor.

Foi gerado um gráfico de regressão com o tempo, como apresentado na figura 70 para o produto 3.

Figura 70 – Regressão com tempo produto 3



Fonte: O próprio autor.

- **Produto 4**

No produto 4, pode-se confirmar as covariáveis significativas são PIB e IPCA mensal (valor-p < 0,05). Além disso considerando-se um nível de significância igual à 10% a covariável ano também mostra significância estatística (valor-p < 0,10), como representado na Tabela 26.

Tabela 26 – Regressão produto 4

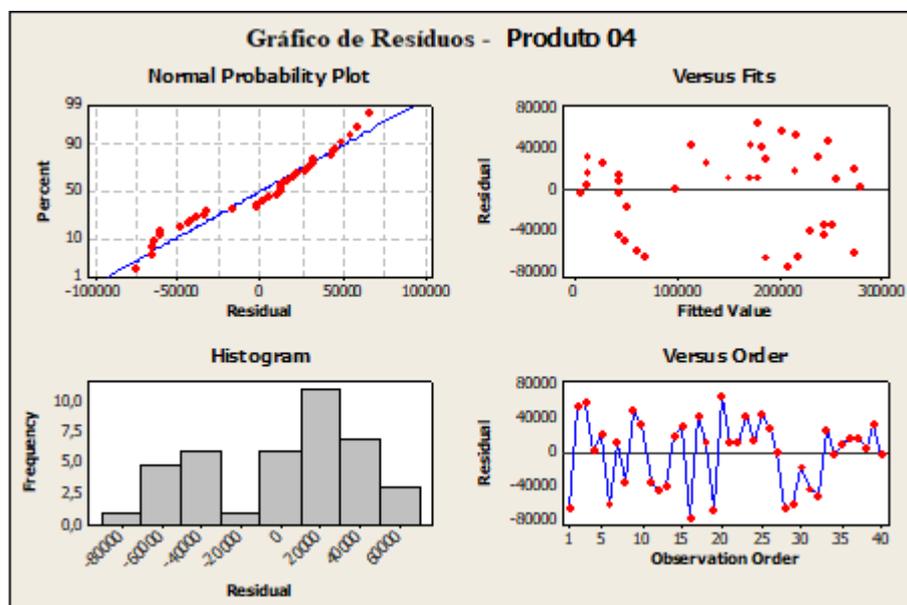
	Coef	SE Coef	T	P
Constante	150258153	83101779	1,81	0,080
Mês	-5597	3398	-1,65	0,109
Ano	-74341	41291	-1,80	0,081
Taxa desemprego	-1431652	1558099	-0,92	0,365
PIB	-2200421	881781	-2,50	0,018
IPCA	-2335108	966819	-2,42	0,021
Crescimento da produção	-716085	582569	-1,23	0,228

S = 43070,4 R-Sq = 83,7% R-Sq(adj) = 80,7%

Fonte: O próprio autor.

Conforme indica a figura 71 pode-se aceitar o modelo de regressão como válido, visto que uma das premissas é que os resíduos devem possuir uma distribuição normal com média zero e variância constante.

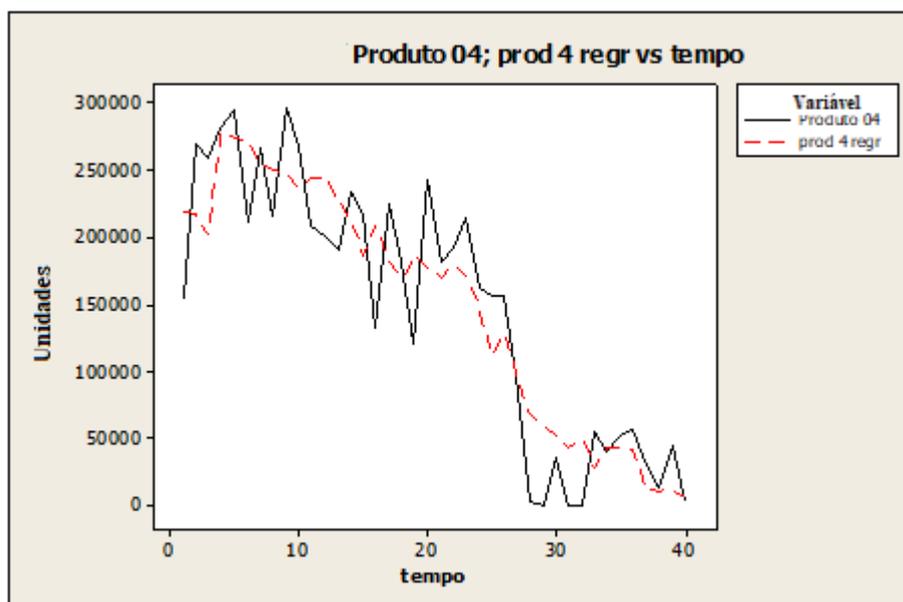
Figura 71 – Resíduos produto 4



Fonte: O próprio autor.

Foi gerado um gráfico de regressão com o tempo, como apresentado na figura 72 para o produto 4.

Figura 72 – Regressão com tempo produto 4



Fonte: O próprio autor.

- **Produto 5**

No produto 5, pode-se confirmar a covariável significativa é taxa de desemprego (valor-p < 0,05), como representado na Tabela 27.

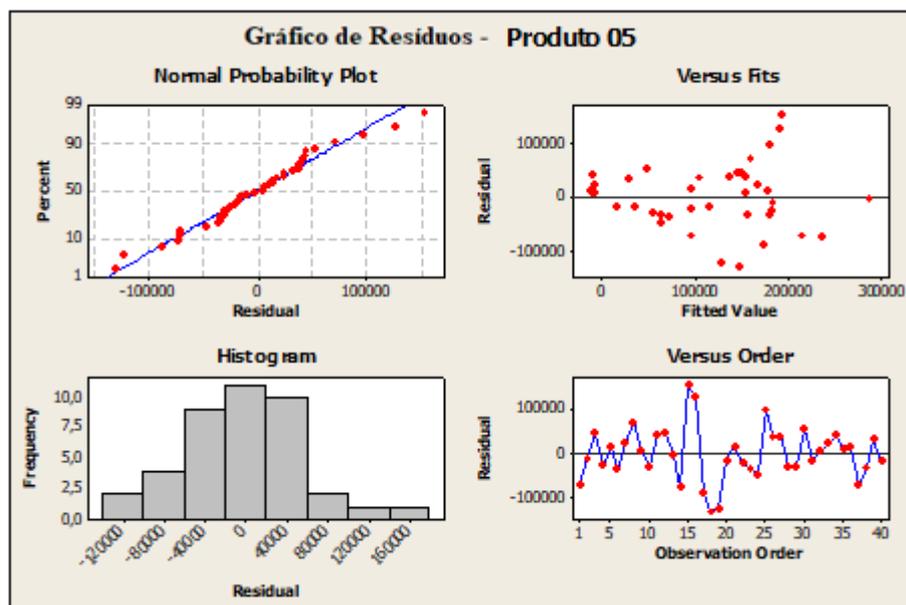
Tabela 27 – Regressão produto 5

	Coef	SE Coef	T	P
Constante	-125447653	123865239	-1,01	0,319
Mês	-7961	5065	-1,57	0,126
Ano	62638	61545	1,02	0,316
Taxa desemprego	-5664378	2322384	-2,44	0,020
PIB	-1033709	1314316	-0,79	0,437
IPCA	-1513944	1441067	-1,05	0,301
Crescimento da produção	14282	868334	0,02	0,987
S = 64197,6 R-Sq = 62,2% R-Sq(adj) = 55,4%				

Fonte: O próprio autor.

Conforme indica a figura 73 pode-se aceitar o modelo de regressão como válido, visto que uma das premissas é que os resíduos devem possuir uma distribuição normal com média zero e variância constante.

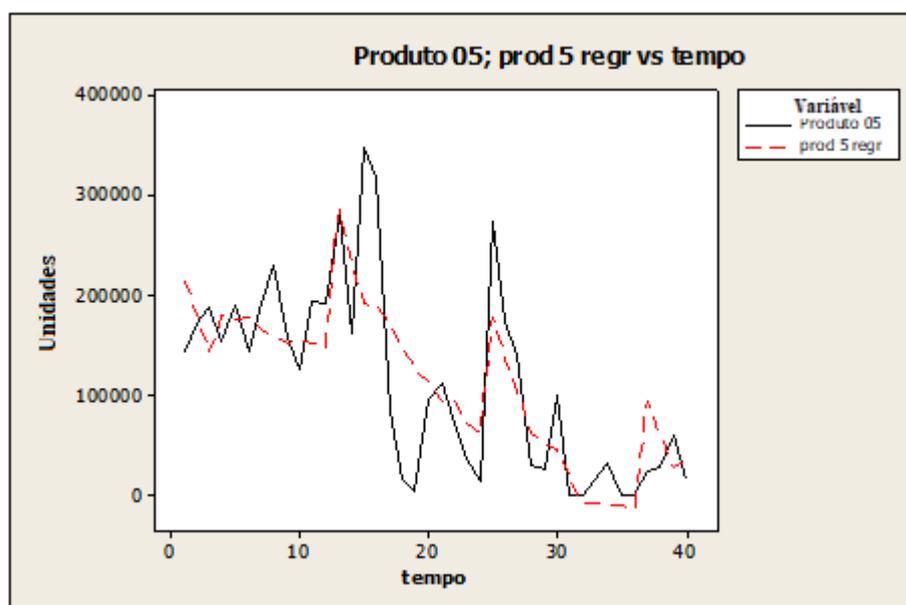
Figura 73 – Resíduos produto 5



Fonte: O próprio autor.

Foi gerado um gráfico de regressão com o tempo, como apresentado na figura 74 para o produto 5.

Figura 74 – Regressão com tempo produto 5



Fonte: O próprio autor.

- **Produto 6**

No produto 6, pode-se confirmar as covariáveis significativas são mês, ano, PIB mensal, IPCA e taxa de crescimento de produção (valor-p < 0,05), como representado na Tabela 28.

Tabela 28 – Regressão produto 6

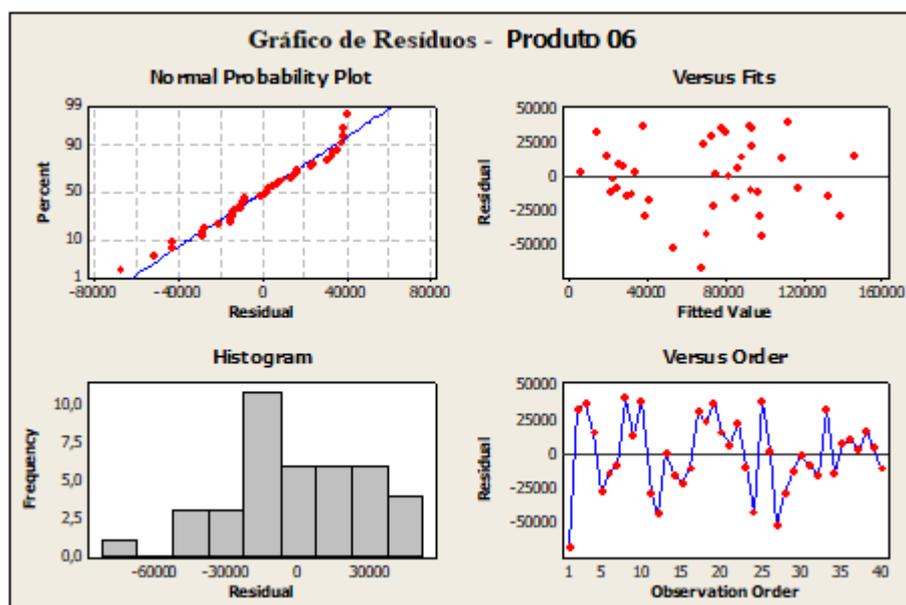
	Coef	SE Coef	T	P
Constante	161092096	56235621	2,86	0,007
Mês	-5355	2299	-2,33	0,026
Ano	-79895	27942	-2,86	0,007
Taxa desemprego	1280363	1054378	1,21	0,233
PIB	-1986186	596708	-3,33	0,002
IPCA	-1936402	654254	-2,96	0,006
Crescimento da produção	-805583	394229	-2,04	0,049

S = 29146,1 R-Sq = 65,3% R-Sq(adj) = 59,0%

Fonte: O próprio autor.

Conforme indica a figura 75 pode-se aceitar o modelo de regressão como válido, visto que uma das premissas é que os resíduos devem possuir uma distribuição normal com média zero e variância constante.

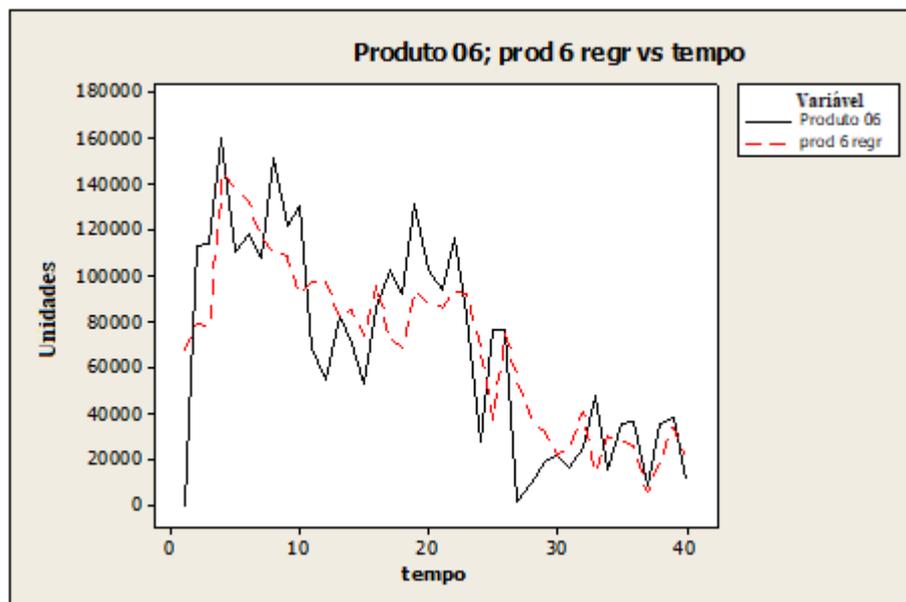
Figura 75 – Resíduos produto 6



Fonte: O próprio autor.

Foi gerado um gráfico de regressão com o tempo, como apresentado na figura 76 para o produto 6.

Figura 76 – Regressão com tempo produto 6



Fonte: O próprio autor.

- **Produto 7**

No produto 7, pode-se confirmar a covariável significativa é PIB mensal (valor-p < 0,05). Além disso considerando-se um nível de significância igual à 10% a covariável IPCA também mostra significância estatística (valor-p < 0,10), como representado na Tabela 29.

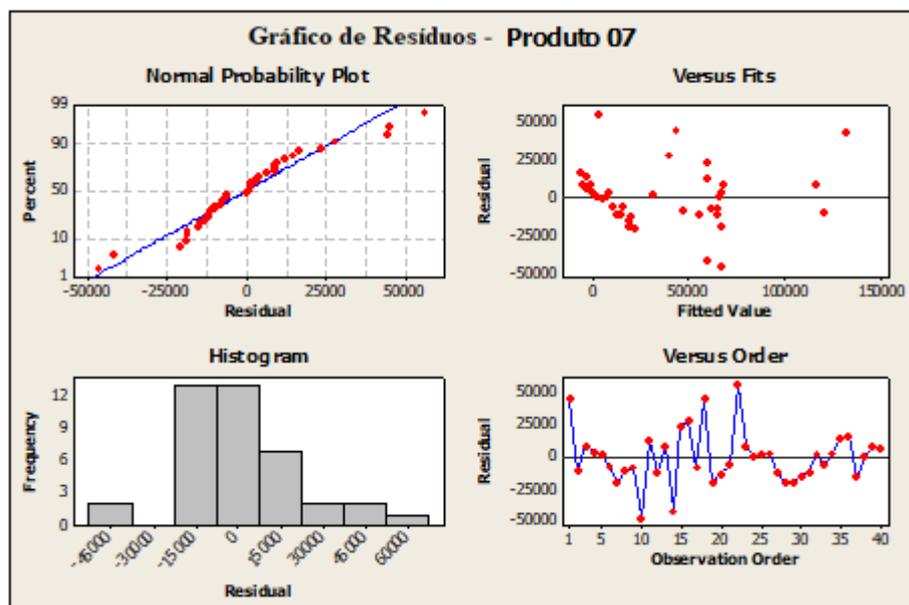
Tabela 29 – Regressão produto 7

	Coef	SE Coef	T	P
Constante	1618274	42985072	0,04	0,970
Mês	-1938	1758	-1,10	0,278
Ano	-762	21358	-0,04	0,972
Taxa desemprego	-817720	805939	-1,01	0,318
PIB	1269302	456108	2,78	0,009
IPCA	889375	500095	1,78	0,085
Crescimento da produção	384155	301339	1,27	0,211
S = 22278,5 R-Sq = 75,2% R-Sq(adj) = 70,7%				

Fonte: O próprio autor.

Conforme indica a figura 77 pode-se aceitar o modelo de regressão como válido, visto que uma das premissas é que os resíduos devem possuir uma distribuição normal com média zero e variância constante.

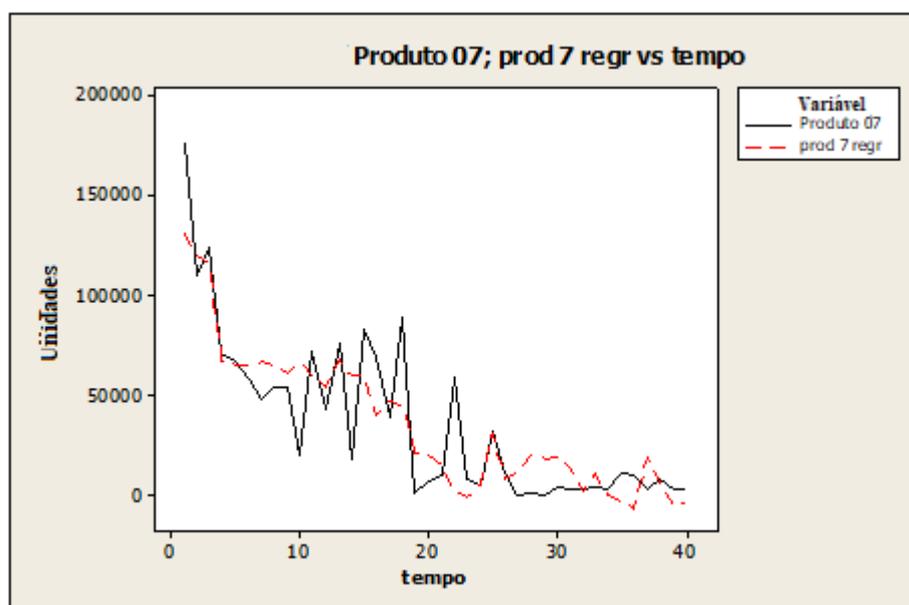
Figura 77 – Resíduos produto 7



Fonte: O próprio autor.

Foi gerado um gráfico de regressão com o tempo, como apresentado na figura 78 para o produto 7.

Figura 78 – Regressão com tempo produto 7



Fonte: O próprio autor.

- **Produto 8**

No produto 8, pode-se confirmar as covariáveis significativas são taxa de desemprego e PIB mensal (valor-p < 0,05), como representado na Tabela 30.

Tabela 30 – Regressão produto 8

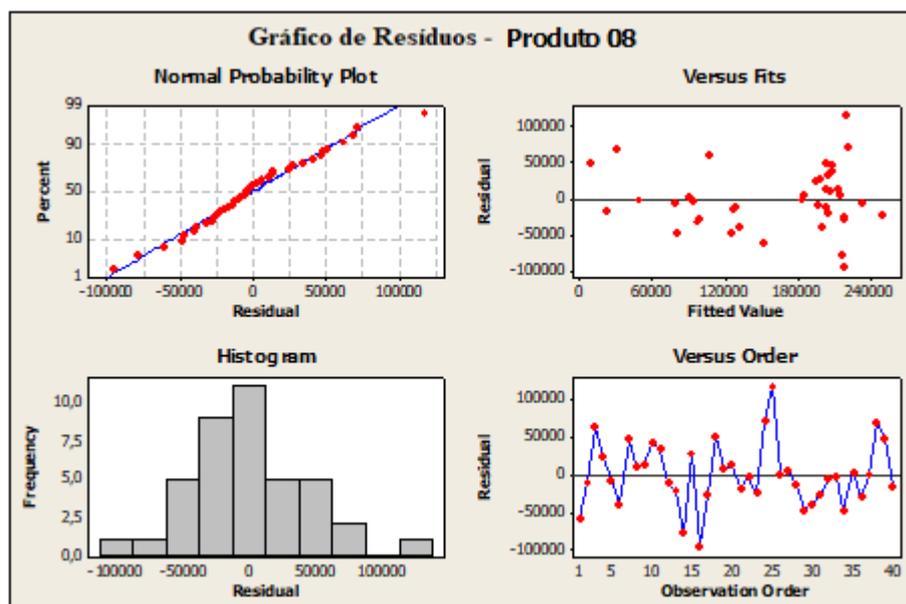
	Coef	SE Coef	T	P
Constante	-26524064	89589408	-0,30	0,769
Mês	-721	3663	-0,20	0,845
Ano	13414	44515	0,30	0,765
Taxa desemprego	-3587914	1679737	-2,14	0,040
PIB	-2188126	950620	-2,30	0,028
IPCA	-698089	1042297	-0,67	0,508
Crescimento da produção	374067	628050	0,60	0,556

S = 46432,9 R-Sq = 70,7% R-Sq(adj) = 65,3%

Fonte: O próprio autor.

Conforme indica a figura 79 pode-se aceitar o modelo de regressão como válido, visto que uma das premissas é que os resíduos devem possuir uma distribuição normal com média zero e variância constante.

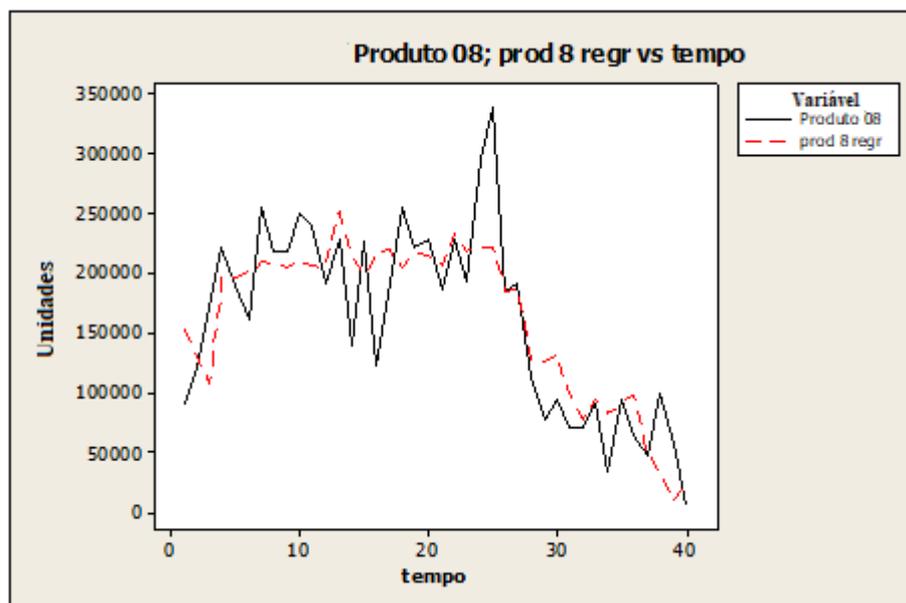
Figura 79 – Resíduos produto 8



Fonte: O próprio autor.

Foi gerado um gráfico de regressão com o tempo, como apresentado na figura 80 para o produto 8.

Figura 80 – Regressão com tempo produto 8



Fonte: O próprio autor.

- **Produto 9**

No produto 9, pode-se confirmar as covariáveis significativas são ano e taxa desemprego mensal (valor-p < 0,05), como representado na Tabela 31.

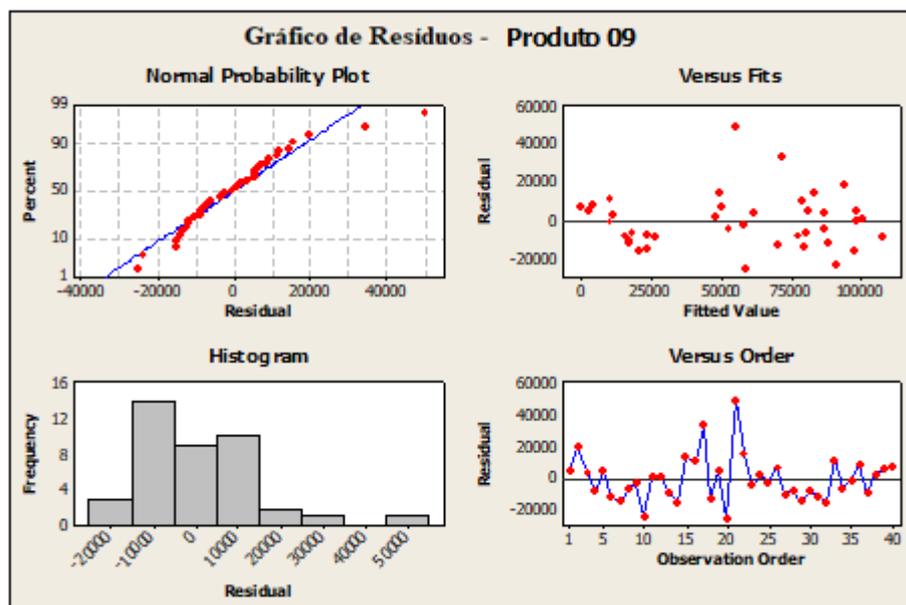
Tabela 31 – Regressão produto 9

	Coef	SE Coef	T	P
Constante	-62256019	30250847	-2,06	0,048
Mês	547	1237	0,44	0,661
Ano	31038	15031	2,06	0,047
Taxa desemprego	-2560901	567182	-4,52	0,000
PIB	317812	320987	0,99	0,329
IPCA	18856	351943	0,05	0,958
Crescimento da produção	-294499	212068	-1,39	0,174
S = 15678,6 R-Sq = 84,7% R-Sq(adj) = 82,0%				

Fonte: O próprio autor.

Conforme indica a figura 81 pode-se aceitar o modelo de regressão como válido, visto que uma das premissas é que os resíduos devem possuir uma distribuição normal com média zero e variância constante.

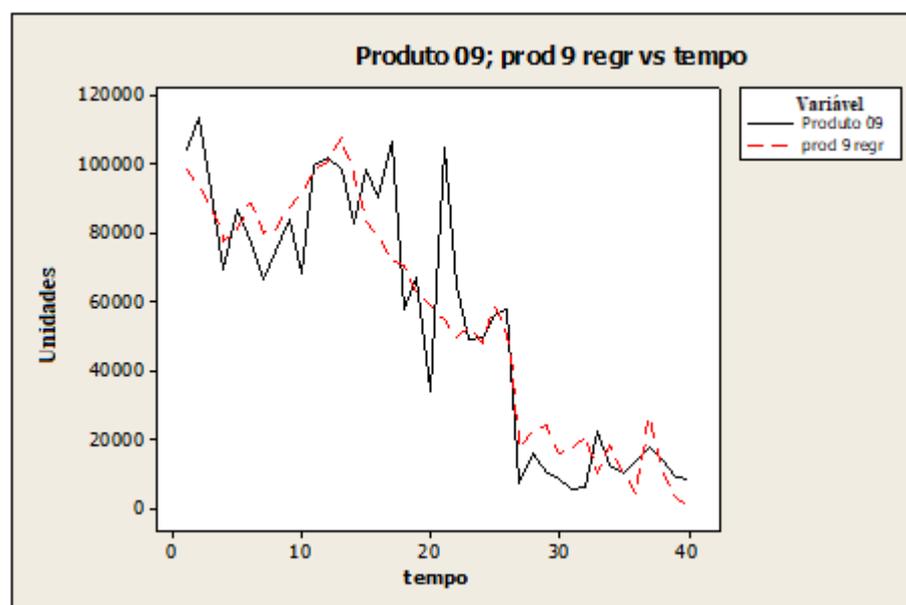
Figura 81 – Resíduos produto 9



Fonte: O próprio autor.

Foi gerado um gráfico de regressão com o tempo, como apresentado na figura 82 para o produto 9.

Figura 82 – Regressão com tempo produto 9



Fonte: O próprio autor.

- **Produto 10**

No produto 10, pode-se confirmar as covariáveis significativas são mês, ano, PIB mensal e IPCA (valor-p < 0,05). Além disso considerando-se um nível de significância igual à 10% a covariável crescimento mensal de produção também mostra significância estatística (valor-p < 0,10), como representado na Tabela 32.

Tabela 32 – Regressão produto 10

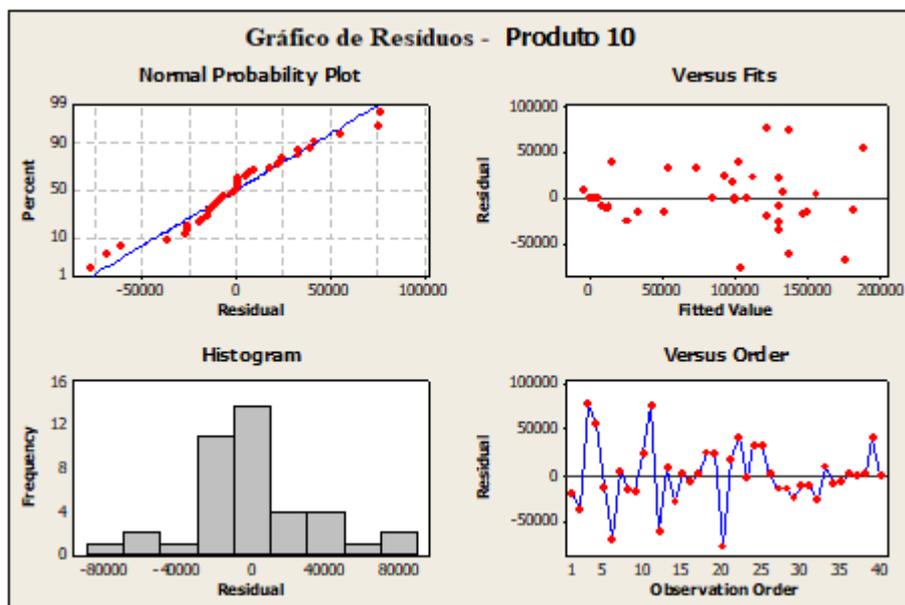
	Coef	SE Coef	T	P
Constante	153993036	68787197	2,24	0,032
Mês	-6844	2813	-2,43	0,021
Ano	-76298	34179	-2,23	0,032
Taxa desemprego	102722	1289711	0,08	0,937
PIB	-1997140	729891	-2,74	0,010
IPCA	-2158293	800281	-2,70	0,011
Crescimento da produção	-899330	482220	-1,86	0,071

S = 35651,4 R-Sq = 76,3% R-Sq(adj) = 72,0%

Fonte: O próprio autor.

Na figura 83 podemos aceitar o modelo de regressão como válido, visto que uma das premissas é que os resíduos devem possuir uma distribuição normal com média zero e variância constante.

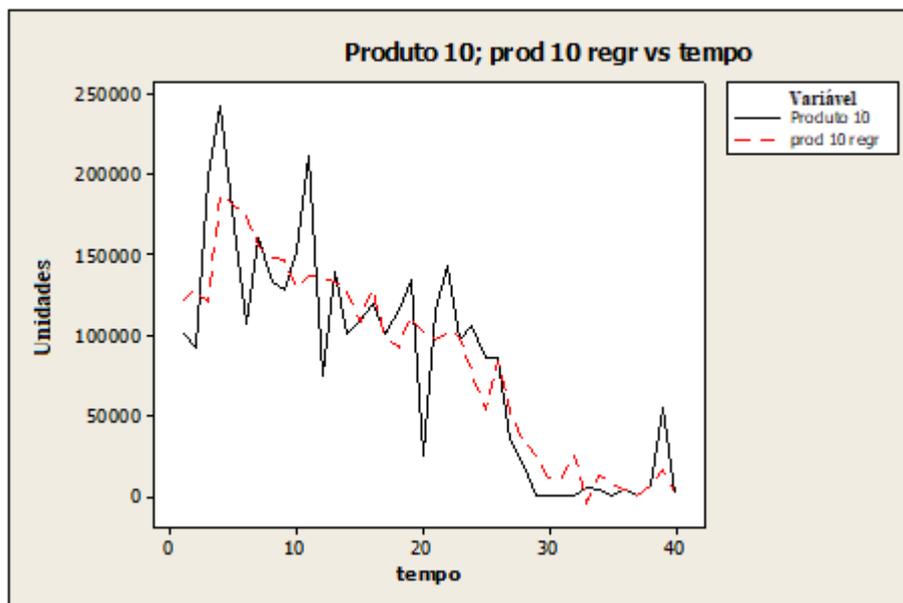
Figura 83 – Resíduos produto 10



Fonte: O próprio autor.

Foi gerado um gráfico de regressão com o tempo, como apresentado na figura 84 para o produto 10.

Figura 84 – Regressão com tempo produto 10



Fonte: O próprio autor.

A presente seção apresenta a discussão dos resultados obtidos com a modelagem dos respectivos modelos, realizando análises e comentários necessários quanto aos resultados.

Esse levantamento permitiu que fossem analisados e discutidos os métodos quantitativos, utilizando os modelos de médias móveis, modelos ARIMA (BOX et al., 1994) e modelos de regressão linear múltipla, no qual mostraram-se eficazes. O uso do *software* mostrou-se eficaz e indispensável, devido à diversidade de produtos e simulações necessárias.

Os resultados apresentados mostraram que a estratégia seguida nesse trabalho pode ser um bom caminho para se realizar uma previsão. A utilização dos métodos, conforme foi mostrado, pode proporcionar melhores decisões estratégicas e, certamente, maiores lucros para as empresas.

No mercado que a empresa atua, exige-se entrega imediata do produto, podendo-se ter como consequência a perda de negócios. Sendo assim, parece ser válida a utilização de técnicas de previsão de vendas, para aumentar a competitividade da empresa.

5 CONSIDERAÇÕES FINAIS

As empresas buscam cada vez mais se aperfeiçoar para atender as satisfações dos clientes ao mínimo custo. Isso indica que o aumento da eficiência é um dos principais pré-requisitos para se manterem num mercado tão competitivo quanto o global. Atender o consumidor com o produto correto, na hora certa e com a quantidade solicitada requer um planejamento apurado de todas as áreas da empresa. Este planejamento normalmente se inicia com a definição dos objetivos da empresa a curto, médio e longo prazo. Para isso, previsões são utilizadas para projetar o futuro e auxiliar a avaliação da empresa quanto aos seus objetivos.

A busca por uma metodologia mais adequada tem como objetivo minimizar os efeitos de uma errônea previsão. Com uma maior acuracidade nas previsões, menores serão os impactos para empresa, conseqüentemente, para o atendimento dos seus clientes. Tais erros podem gerar grandes conseqüências, podendo levar ao não atendimento ou atraso de um pedido para cliente, item primordial, quando inserida no mercado de alimentos.

A proposta desse trabalho foi de pesquisar, analisar e testar modelos quantitativos de previsão e, a partir disso selecionar modelos mais adequados para a série estudada. Quanto aos objetivos, geral e os específicos da pesquisa, estes foram alcançados e, após as análises dos modelos de médias móveis, ARIMA e regressão múltipla, os modelos trouxeram grandes resultados para o estudo de caso desta pesquisa.

Os modelos propostos obtiveram resultados satisfatórios. O ajustamento de modelo contribui para a tomada das decisões gerenciais que desempenham um papel crucial na busca pela competitividade e ganhos de resultados frente a um ambiente dinâmico. Os modelos servem como orientação tanto quanto a direcionamentos futuros quanto a variáveis que influenciam nos seus planejamentos. Uma orientação correta e precoce aumenta a probabilidade de chances de sucesso nos processos de tomada de decisão.

Porém, a instabilidade do mercado tem tornado interessante a integração de previsões, pois os padrões existentes na série são identificados pelos métodos quantitativos e alterados pelos julgamentos de acordo com as mudanças dinâmicas do ambiente. Desta forma, o processo enriquece ao se incorporar informações de diversas fontes, aumentando o âmbito da análise.

O sucesso na análise da demanda está na visão estratégica da empresa, capaz de detectar possíveis mudanças que venham a exercer influência na demanda. Além disso, cabe ressaltar que para ter previsões confiáveis é necessário adotar rotinas de monitoramento e

validação do modelo de forma a mantê-lo sempre atualizado. A manutenção e o acompanhamento podem ser feitos através de cálculos de erros de previsão apresentados neste trabalho.

É muito importante que a empresa utilize todas as ferramentas disponíveis para conseguir antecipar a demanda futura com precisão. Assim a mesma deve manter a base de dados históricos de demanda, assim como informações que expliquem suas variações e comportamento no passado. Estas informações são vitais para qualquer empresa que se preocupa com o planejamento de suas operações, principalmente para aquelas cujos produtos são perecíveis e que dependem da disponibilidade de matéria-prima de origem agropecuária, como é o caso da Indústria de Alimentos.

A previsão de demanda será de fundamental importância para a empresa estudada uma vez que permitirá um programa otimizado de todo o planejamento e produção. Além disso, entrará como ferramenta para o gerenciamento da capacidade da produção ao programar turnos e férias, permitirá a maximização da produção uma vez que evitará a ociosidade dos funcionários e planejamento orçamental e de capital, possibilitando melhor alocação de recursos físicos nos processos operacionais.

O processo proposto vai atender ao objetivo de reduzir a informalidade da informação, com a participação da alta direção, definindo uma meta de crescimento para os próximos períodos, elemento importante de um planejamento estratégico, aliada à participação da área comercial, em que as ações são planejadas em conjunto com o PCP, área financeira e diretoria, responsáveis pelo atendimento aos clientes e pelos resultados da empresa.

A empresa poderá desenvolver um plano de estimulação do consumo em períodos estratégicos onde o consumo está em declínio, investindo no *marketing* com a criação de promoções e atrativos visuais que influenciem o consumidor em períodos onde existe uma menor incidência de demanda.

Os modelos selecionados podem ser úteis para futuros estudos, a previsão de demanda é elemento importante para elaborar padrões de medição do que já vem sendo analisado. Um processo mais coerente pode ajudar a estabelecer certos padrões de comportamento de produtos, o que pode facilitar inclusive a política de compras e manutenção de estoques.

Os resultados apresentados mostraram que a estratégia seguida nesse trabalho pode ser um bom caminho para se realizar uma previsão. A utilização dos métodos, conforme foi mostrado, pode proporcionar melhores decisões estratégicas e, certamente, maiores lucros para as empresas.

No mercado que a empresa atua, exige-se entrega imediata do produto, podendo-se ter como consequência a perda de negócios. Sendo assim, parece ser válida a utilização de técnicas de previsão de vendas, para aumentar a competitividade da empresa.

Observa-se que a principal contribuição deste estudo foi a de gerar informações como meio para futuras tomadas de decisões da empresa com relação à demanda dos produtos. Do ponto de vista empresarial os resultados deste trabalho representam uma valiosa fonte de informações que deverá direcionar os planos de produção da empresa. E do ponto de vista acadêmico, buscou-se discutir e contribuir com o acervo, retratando a aplicação de alguns conceitos de maneira prática e próxima daquilo que é a realidade do mercado.

Ressalta-se, por fim, que este estudo pode ser útil para outras empresas, independente do porte e segmento, visto que pode servir como exemplo e como base para o planejamento de outros empreendimentos, possibilitando conhecimento sobre os métodos adotados, destacando a importância da utilização de previsões de demanda para o sucesso do negócio.

REFERÊNCIAS

- ADVFN Brasil. **Portal de investimentos em ações da bolsa de valores do Brasil, com cotações da Bovespa e BM&F**. Disponível em: < <https://br.advfn.com/indicadores>>. Acesso em: 10 jun. 2017.
- AFONSO, M. W.; MOREIRA FILHO, R. M.; NOVAES, M. L. O. Aplicação de modelos de previsão de demanda em uma farmácia hospitalar. **Relatórios de Pesquisa em Engenharia de Produção**, v. 11, n. 4, 2011. Disponível em: < http://www.producao.uff.br/conteudo/rpep/volume112011/RelPesq_V11_2011_04.pdf>. Acesso em: 13 jan. 2017.
- AKGUN, B. **Identification of Periodic Autoregressive Moving Average Models**. Middle East Technical University, 2003.
- ARMSTRONG, J. Combining forecasts. In: **Principles of forecasting: a Handbook for Researchers and Practitioners**. Boston: Kluwer Academic Publishers, 2001. p. 417-440.
- ARNOLD, J.R.T. **Administração de materiais: uma introdução**. São Paulo : Atlas, 2006.
- ARAÚJO, M. A. V.; ARAÚJO, F. J. A.; ADISSI, P. J. Elaboração de um modelo multivariado de Previsão de demanda para um call center. In: ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO, 24., Florianópolis, SC, 2004. **Anais...** Florianópolis: ENEGEP, 2004. p. 1-8.
- BACO, S.; PAIVA, A. P.; LIMA, R. S. Sistemas de previsão de demanda: aplicação em uma fábrica de anéis de pistão automotivos. In: SIMPÓSIO DE ENGENHARIA DE PRODUÇÃO, 13., Bauru, SP, 2006. **Anais....** 2006. p. 1-12.
- BALLOU, R. H. **Gerenciamento da cadeia de suprimentos: logística empresarial**. 5. ed. Porto Alegre: Bookman, 2006.
- BARBOSA, C. M.; E CHAVES, C. A. Demand chain management: a previsão estatística como principal técnica no processo de gerenciamento da demanda. **Exacta**, v. 11, n. 1, p. 101-114, 2014.
- BASSETO, A. L. C.; BORGES, R.; VINCENZI, S. L. Previsão de demanda em uma empresa de produção de peças para implementos agrícolas. In: CONGRESSO BRASILEIRO DE ENGENHARIA DE PRODUÇÃO. 5., Ponta Grossa, 2015. **Anais...** Ponta Grossa: Conbrep, 2015
- BASSOLI, H. M.; PIERRE, F. C.; OLIVEIRA, P. A. Aplicação de modelos de previsão de demanda para a gestão de estoque de um processo produtivo de uma indústria madeireira. **Tekne e Logos**, Botucatu, SP, v. 6, n.1, p. 1-11, jun. 2015.
- BEAN, C. R. The role of demand-management policies in reducing unemployment. In: **Reducing unemployment: current issues and policy options**. United Kingdom: Cambridge University Press, 1994. p. 99- 132.
- BELL, W. R. An Introduction to Forecasting with Time Series Models. **Insurance: Mathematics and Economics** 3, pp. 241-255, 1984.
- BOX, G. E. P.; JENKINS, G. M.; REINSEL, G. C. **Time Series Analysis: Forecasting and Control**. Third Edition. Prentice Hall, 1994.

- CALÔBA, G. M.; CALÔBA, L. P.; SALIBY, E. Cooperação entre redes neurais artificiais e técnicas ‘clássicas’ para previsão de demanda de uma série de vendas de cerveja na Austrália. **Pesquisa Operacional**, Rio de Janeiro, v. 22, n. 3, p. 345-358, jul./dez. 2002.
- CARVALHO, A. P. **Manual do Secretariado Executivo**. 5ª Ed. São Paulo: D`Livros Editora, 2002.
- CASACA, A. C. P. Previsões. In: **Comissão de Estudos de Trabalho de organização industrial**: notas de aula. [S.l.: s.n.], 2008. cap. 11.
- CASTANHEIRA, N. P. **Métodos quantitativos**. Curitiba: InterSaberes, 2013. (Série Matemática Aplicada).
- CECATTO, C.; BELFIORE, P. O uso de métodos de previsão de demanda nas indústrias alimentícias brasileiras. **Gestão e Produção**, São Carlos, v. 22, n.2, p. 404-418, 2015.
- CHOPRA, S.; MEINDL, P. **Gerenciamento da cadeia de suprimentos**: estratégia, planejamento e operação. São Paulo: Pearson Addison Wesley, 2011.
- CONSUL, F. B.; WERNER, L. Avaliação de técnicas de previsão de demanda utilizadas por um software de gerenciamento de estoques no setor farmacêutico. In: ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO. Maturidade e desafios da Engenharia de Produção: competitividade das empresas, condições de trabalho, meio ambiente. 30, São Carlos, SP, 2010. **Anais...** São Carlos, SP: Enegep, 2010. p. 1-14.
- CRUM, C.; PALMATIER, G. E. **Demand management best practices**: process, principles, and collaboration. Plantation, FL: J. Ross Publishing, 2003.
- DAVIS, M. M.; AQUILANO, N. J.; CHASE, R. B. **Fundamentos da administração da produção**. 3. ed. Porto Alegre: Bookman, 2001.
- DELURGIO, S. A. **Forecasting principles and applications**. Singapura: McGraw-Hill, 1998.
- DRAPER, N.R.; SMITH, H. **Applied regression analysis**. Wiley series in probability and mathematical statistics, 1981.
- EINSTEIN, A. **Frases**. Disponível em: < <https://pensador.uol.com.br/frase/ODE4OQ/>>. Acesso em: 13 jan. 2017.
- EKAMI, K. H. O.; MING, W. C. Ferramentas para a indústria de vestuário: previsão da demanda. In: COLÓQUIO DE MODA, 10., CONGRESSO BRASILEIRO DE INICIAÇÃO CIENTÍFICA EM DESIGN E MODA, 1., 2014. Caxias do Sul, RS. **Anais...** Caxias do Sul: Abepem, 2014. p. 1-10.
- FAHIMNIA, B.; TANG, C.; DAVARZANI, H.; SARKIS, J. Quantitative models for managing supply chain risks: A review. **European Journal of Operational Research**, v. 247, n. 1, p. 1–15, nov. 2015.
- FARIAS, O. O.; NOGUEIRA NETO, M. S.; NOGUEIRA, C. C. S. Estudo comparativo da aplicação de modelos clássicos de previsão de demanda no agronegócio. **Organizações em Contexto**, São Paulo, ano 2, n. 3, p. 220-233, jun, 2006.
- FERNANDES, F. C. F; GODINHO, M. F. **Planejamento e controle da produção**: dos fundamentos ao essencial. São Paulo: Atlas, 2010.

- FLEURY, P. F.; WANKE, P.; FIGUEIREDO, K. F. **Logística empresarial: a perspectiva brasileira**. Coleção Coppead de Administração. Centro de Estudos em Logística (CEL). 1 ed. São Paulo: Atlas, 2000.
- GAITHER, N.; FRAZIER, G. **Administração da produção e operações**. 8. ed. São Paulo: Thomson Learning, 2001.
- GARCIA, R. A. **Análise dos métodos de previsão da demanda**: estudo de caso em unidade distintas de uma escola de idiomas. 2011. 90 f. Monografia (Graduação em Engenharia de Produção), Universidade Federal do Espírito Santo, São Mateus, 2011.
- GIL, A. C. **Como elaborar projetos de pesquisa**. 5. ed. São Paulo: Atlas, 2010.
- GOMES, M. S. S.; SOUZA, T. A.; PIATO, E. L. Fatores Qualitativos que Influenciam a Previsão de Demanda em uma Indústria de Autopeças. In: CONGRESSO BRASILEIRO DE ENGENHARIA DE PRODUÇÃO. 5., 2015, Ponta Grossa, PR. **Anais ...** Ponta Grossa: Conbrepro, 2015. p. 1-10
- GONÇALVES, P. **Administração de materiais**. Rio de Janeiro: Campus, 2004.
- GONÇALVES, P. S. Previsão de demanda. In: **Logística e cadeia de suprimentos: o essencial**. Barueri- SP: Manole, 2013. p. 227-248.
- GRESSLER, L. A. **Introdução à pesquisa projetos e relatórios**. 2. ed. São Paulo: Loyola, 2004.
- GUPTA, A. Sales forecasting & market potential: best practices in India. **International Journal of Advanced Marketing and Research**, v. 1, n. 1, p. 1-7, 2013.
- GURGEL, J. L. M. Modelo de previsão de demanda: análise da produção em uma empresa do setor cerâmico do Rio Grande do Norte. In: ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO, 35, Fortaleza –CE, 2015. **Anais...** Fortaleza: Abepro, 2015. p. 1-17.
- HEIZER, J.; RENDER, B. **Production and operations management: strategic and tactical decisions**. 4th ed. New Jersey: Prentice Hall, 1996.
- HO, S. L.; XIE, M. The Use of ARIMA Models for Reliability Forecasting and Analysis. **Computers Industrial Engineering**, Vol. 35, n.1-2, 213-216, 1998.
- HO, J.; FANG, C. Production capacity planning for multiple products under uncertain demands conditions. **International Journal Production Economics**, v. 141, p. 593-604, 2013.
- HOLOWKA, H.; LEMES, I, K.; TRENTIN, L. S. Planejamento Agregado: na ótica do PCP e da Administração da Produção. In: ENCONTRO DE ENGENHARIA AGROINDUSTRIAL, 7., Campo Mourão, PR. 2013. **Anais...** Campo Mourão: Fecilcam, 2013. p. 1-11.
- HORNGREN, C. T.; SUNDEM, G. L.; STRATTON, Willian. **Contabilidade gerencial**. 12. ed. São Paulo: Prentice Hall, 2004.
- JACOB, W.; COSTA, M. Uma referência para construção de modelos ARIMA para previsão de demanda com base na metodologia de Box-Jenkins. In: ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO, 31., Belo horizonte – MG, 2011. **Anais...** Belo Horizonte: Ingep, 2011. p. 1-14.
- KRAJEWSKI, L. J.; RITZAMN, L.; MALHOTRA, M. **Administração de produção e operações**. São Paulo: Pearson Prentice Hall, 2009.

- LEVINE, D. M.; BERENSON, M. L.; STEPHAN, D. **Estatística: Teoria e Aplicações. Usando o Microsoft Excel em português.** Rio de Janeiro: LTC, 2000.
- LIBRANTZ, A. F. H.; ARAÚJO, S. A.; ALVES, W. A. L. Algoritmos de busca aplicados na estimação de parâmetros em um modelo probabilístico de gestão de estoque. **Exacta – EP**, v. 8, n. 2, p. 237-248, 2010.
- LINDBERG, E; ZACKRISSON, U. Deciding about the Uncertain: The Use of Forecasts as na Aid to Decision-making. **Scandinavian Journal of Management**. v. 7, n. 4, p. 271-283, 1991.
- LINGITZ, L.; MORATEWETZ, C.; GIGLOO, D. T.; MINNER, S.; SIHN, W. Modelling of flexibility costs in a decision support system for midterm capacity planning. **Procedia CIRP 7, 46th CIRP Conference on Manufacturing Systems**, p. 539 – 544, 2013.
- LJUNG, G.M.; BOX, G.E.P. On a Measure of a Lack of Fit in Time Series Models. **Biometrika**, n.2, n.2, Vol 65, n.2, 297–303, 1978.
- MAKRIDAKIS, S.; HOGART, R. M. Forecasting and Planning: An Evaluation. **Management Science**, Singapore, v. 27, n. 2, p. 115-138, fev. 1981.
- MAKRIDAKIS, S.; WHEELWRIGHT, S. C.; HYNDMAN, R. J. Elements of Forecasting by Francis X. Diebold Review by: William M. Briggs. Forecasting: Methods and Applications **Journal of the American Statistical Association**, United Kingdom, v. 94, n. 445, p. 345-346, mar. 1998. Disponível em: < <http://robjhyndman.com/forecasting/>> Acesso em: 17 jan. 2017.
- MANCUSO, A. C. B.; WERNER, L. Estudo dos métodos de previsão de demanda aplicado em uma empresa de auditorias médicas. **Revista Ingenieria Industrial**, Concepcion, Chile. v. 13, n. 1, p. 99-111, 2014.
- MARTINS, P. G.; LAUGENI, F. P. **Administração da produção**. 2. ed. São Paulo: Saraiva, 2005.
- MEIJDEN, V.D.L.H.; NUNEN, J.A.E.E.V.; RAMONDT, A. Forecasting: bridging the gap between sales and manufacturing. **International Journal Production Economics**, Amsterdam, v. 37, n. 1, p. 101-114, 1994.
- MESQUITA, M. A. Previsão de demanda. In: LUSTOSA, L; MESQUITA, M., QUELHAS, O, OLIVEIRA, R. J. P. **Planejamento e controle da Produção**. Rio de Janeiro: Elsevier, 2008. p. 49-75.
- MESQUITA, J. M. C. Impactos da sazonalidade da produção sobre os estoques e lucratividade: análise do segmento industrial brasileiro. **Revista Contabilidade Vista e Revista**, Belo Horizonte, v. 27, n. 3, p. 61-80, set/dez. 2016.
- MIGUEL, P. A. C. Estudo de caso na engenharia de produção: Estruturação e recomendações para sua condução. **Produção**, v. 17, n. 1, p. 216-229, jan./abr. 2007.
- MIRANDA, R. G.; ANDRADE, G. J. P. O.; GERBER, J. Z.; BORNIA, A. C. Método estruturado para o processo de planejamento da demanda nas organizações. **Revista Administração e Gestão Estratégica**, Ponta Grossa, v. 4, n. 1, p.45-53, 2011.
- MIYATA, H. H.; BARRETO, A.; YOSHIDA, M. V.; ARAÚJO, A. O. Previsão de demanda por simulação de Monte Carlo em uma empresa especializada em produtos odontológicos. In:

ENCONTRO DE ENGENHARIA DE PRODUÇÃO AGROINDUSTRIAL. 4., Campo Mourão – PR, 2010. **Anais...** Campo Mourão: FECILCAM, 2010. p. 1-10.

MONTGOMERY, D. C.; JENNINGS, C. L.; KULAHCI, M. **Introduction to Time Series Analysis and Forecasting**. John Wiley & Sons, Inc, 2008.

MONTGOMERY, D. C.; RUNGER, G. C. **Applied statistics and probability for engineers**. New York: Wiley, 2011.

MORAIS, R. R.; SOUSA, N. A.; MORAIS, A. R. Comparativo entre modelos de série temoral para previsão de demanda de um item com comportamento intermitente de demanda. In: SIMPÓSIO DE ADMINISTRAÇÃO DA PRODUÇÃO, 18., São Paulo, 2015. **Anais...** São paulo: FGV, 2015. p. 1-15

MOREIRA, D. A. **Administração da produção e operações**. São Paulo: Pioneira Thomson Learning, 2001.

MORETTIN, P. A.; TOLOI, C. M. **Previsão de séries temporais**. 2. ed. São Paulo: Atual, 1987.

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

O'LEARY-KELLY, S., FLORES, B. The integration of manufacturing and marketing/sales decision: impact on organization performance. **Journal of Operations Management**, V. 20, 2002, p. 221-240.

OLIVEIRA, U. M. B.; CARVALHO, F. L. S. Comparação de técnicas de previsão de demanda para controle de estoques de embalagem para computadores. In: ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO, 33, Salvador –BA, 2013. **Anais...** Salvador: Abepro, 2013. p. 1-18.

PAGANELLI, S. S.; LOPES, H. S.; RODRIGUES, M. R.; BARROS, G. P. Análises de modelos quantitativos de previsão da demanda: ajuste e otimização de modelos à demanda do adesivo comum em uma gráfica na cidade de Belém-PA. In: ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO, 35, Fortaleza –CE, 2015. **Anais...** Fortaleza: Abepro, 2015. p. 1-20.

PANDEY, A.; SOMANI, R. K. System for small and medium scale textile industries. **Internacional Journal of Engineering and Innovative Tecnology**, v. 3, n. 4, oct. 2013.

PELLEGRINI, F. R. **Metodologia para implementação de sistemas de previsão de demanda**. 2000. 130 f. Dissertação (Mestrado em Engenharia de Produção) - Departamento de Engenharia de Produção e Transportes. Porto Alegre - Universidade Federal do Rio Grande do Sul, 2000.

PELLEGRINI, F. R.; FOGLIATTO, F. S. Passos para implantação de sistemas de previsão de demanda técnicas e estudo de caso. **Revista Produção**, São Paulo, v. 11, n. 1, p. 43-64, nov. 2001.

PEREIRA, B. M.; CHAVES, G.; BELLUMAT, M. S.; BARBOZA, M. V.; DUTRA, R. V. Gestão da demanda: um estudo de caso em uma empresa de pequeno porte de Jaguaré. In: ENCONTRO NACIONAL DE ENGENHARIA DE PRODUCAO. Perspectivas Globais para a Engenharia de Produção. 35., Fortaleza, CE, 2015. **Anais...** Fortaleza: Abepro, 2015. p. 1-17.

- POLI, M. F. **Gestão da cadeia de suprimentos**. Rio de Janeiro: Editora Uniseb, 2014.
- QUEIROZ, A. A.; CAVALHEIRO, D. Método de previsão de demanda e detecção de sazonalidade para o planejamento da produção de indústrias de alimentos. In: ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO, 23., Ouro Preto, MG, 2003. **Anais...** Ouro Preto: Abepro, 2003. p. 1-8.
- QUEIROZ, A. A.; CAVALHEIRO, D.; VIEIRA, G. R. Método de previsão de demanda aplicada ao planejamento da produção. In: CONGRESSO BRASILEIRO DE ENGENHARIA DE FABRICAÇÃO. 2., 2003, Uberlândia –MG. **Anais...** Uberlândia –MG: ABCM, 2003.
- RIBEIRO, A. R. **Previsão de demanda**: Estudo de caso na cadeia de suprimentos. Dissertação (Mestrado)-Engenharia de Produção do Departamento de Engenharia Industrial da PUC-Rio. Rio de Janeiro, 2009.
- RITZAM, L. P.; KRAJEWSKI, L. J. Previsão. In: **Administração da produção e operações**. Tradução de Roberto Galman. São Paulo: Prentice Hall, 2004. p.259-291.
- RODRIGUES, J. S.; ARGENTON, M. A.; PRUDENCIATO, W. Desenvolvimento de um modelo de previsão da demanda em uma empresa moveleira de pequeno porte. In: ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO. A integração de cadeias produtivas com a abordagem da manufatura sustentável. 28., Rio de Janeiro, RJ, 2008. **Anais...** Rio de Janeiro: Abepro, 2008. p. 1-12.
- ROSSETTO, M.; DEIMLING, M. F.; ZANIN, A.; RODRIGUES, M. P.; NETO, A. R. Técnicas Qualitativas de Previsão de Demanda: um Estudo Multicasos com Empresas do Ramo de Alimentos. In: SIMPÓSIO DE EXCELÊNCIA EM GESTÃO E TECNOLOGIA. 8., 2011, Resende, RJ. **Anais...** Resende: Abepro, 2011.
- SAMOHYL, R. W.; MATTOS, V. L. D.; ROCHA, R. Técnica de amortecimento exponencial simples com taxa de resposta adaptativa: uma reflexão a respeito do comportamento do coeficiente alfa. Repositório institucional da Universidade Federal do Rio Grande – RI FURG. 2001. Disponível em: < <http://repositorio.furg.br/handle/1/3853>>. Acesso em: 04 abr. 2017.
- SAMOHYL, R.W.; SOUZA, G.P.; MIRANDA, R.G. **Métodos simplificados de previsão empresarial**. Rio de Janeiro: Editora Ciência Moderna Ltda., 2008.
- SANTOS, B. C. Gestão de estoques. **Revista de trabalhos acadêmicos - Universo**, Niterói/RJ, v.1, n. 9, p. 1-30, 2014.
- SEBRAE - Serviço Brasileiro de Apoio às Micro e Pequenas. **Anuário do Trabalho na Micro e Pequena Empresa, 2014**. Disponível em: < <https://www.sebrae.com.br/Sebrae/Portal%20Sebrae/Anexos/Anuario-do%20trabalho-na%20micro-e-pequena%20empresa-2014.pdf>>. Acesso em: 17 maio 2017.
- SCIPIONI, T.; SELLITTO, M. A. Previsão de demanda de três produtos fornecidos por um distribuidor de bebidas. **Revista Liberato**, Novo Hamburgo, v. 16, n. 26, p. 101-220, jul./dez. 2015.
- SEBER, G.A.F.; LEE, A.J. Linear regression analysis, second edition. Wiley series in probability and mathematical statistics, 2003.
- SEVERINO, A. J. **Metodologia do trabalho científico**. 23. edição. São Paulo: Cortez, 2007.

SLACK, N.; CHAMBERS, S.; JOHNSON, R. **Administração da Produção**. 2.ed. São Paulo: Atlas, 2007.

SWAMIDASS, P. M. (Ed.). **Encyclopedia of Production and Manufacturing Management**. Massachusetts: Kluwer Academic Publishers, 2000.

TAYLOR, D. **Logística na cadeia de suprimentos: uma perspectiva gerencial**. 4 ed. São Paulo: Pearson Addison Wesley, 2005.

TODD, S. Y.; CROOK, T. A.; LACHOWETZ, T. Agency theory explanations of self-serving sales forecast inaccuracies. **Business and Management Research**, v. 2, n. 2, 2013.

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

TUBINO, D. F. **Planejamento e controle da produção: teoria e prática**. São Paulo: Atlas, 2008.

VEIGA, C. R. P.; VEIGA, C. P.; DUCLÓS, L. C. A Acuracidade dos Modelos de Previsão de Demanda como Fator Crítico de Desempenho Financeiro na Indústria de Alimentos. **Future Studies Research Journal**, São Paulo, v. 2, n. 2, p. 83-107, 2010.

WALTER, O. M. F. C.; HENNING, E.; MORO, G.; SAMOHYL, R. W. Aplicação de um modelo SARIMA na previsão de vendas de motocicletas. **Exacta – EP**, São Paulo, v. 11, n. 1, p. 77-88, 2013.

WERNER, L. Um modelo composto para realizar previsão de demanda através da integração de combinação de previsões e do ajuste baseado na opinião. 2004, 166 f. Tese (Doutorado em Engenharia de Produção) - Departamento de Engenharia de Produção e Transportes. Porto Alegre – Universidade Federal do Rio Grande do Sul, 2004.

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

XIE, J.; LEE, T.S.; ZHAO, X. Impact of forecasting error on the performance of capacitated multi-item production systems. **Computers & Industrial Engineering**, United States, v. 46, p. 205-219, 2004.

YIN, R.K. **Estudo de caso: planejamento e métodos**. 3 ed. Porto Alegre: Bookman, 2005.

YOKOYAMA, T. T.; TAKEDA, S. L. Proposta de aplicação de previsão de vendas de séries temporais para uma indústria metal-mecânica. **Revista Eletrônica de Tecnologia e Cultura**, Jundiaí, SP, ed. 14, p. 141-152, abr. 2014.

ZAN, G. L.; SELBITTO, M. A. Técnicas de previsão de demanda: um estudo de caso triplo com dados de venda de materiais eletro-mecânicos. **GEPROS. Gestão da Produção, Operações e Sistemas**, Bauru, SP, Ano 2, v. 4, p. 95-10, jul-set/ 2007.

ZANELLA, C.; VIEIRA, V.; BARICHELLO, R. Previsão de demanda: um estudo de caso em uma agroindústria de carnes do oeste catarinense. **GEPROS. Gestão da Produção, Operações e Sistemas**, Bauru, SP, Ano 11, n. 1, p. 45-57, jan-mar. 2016.

ZHANG, B.; HU, S.; SONG, J.; CHENG, S. Analysis about Medium-long-term Demands Forecasting and Capacity Decision Based on the Grey GM(1,1) **Improved Models. International Conference on Management Science & Engineering (19th)**, p. 20-22, 2012.