

UNIVERSIDADE DE CAXIAS DO SUL
PROGRAMA DE PÓS-GRADUAÇÃO EM ADMINISTRAÇÃO – PPGA
CURSO DE MESTRADO

MODELO INTEGRADO PARA PREVISÃO DE VENDAS COMO UMA
FERRAMENTA DE COMPETITIVIDADE: UM ESTUDO DE CASO EM
UMA EMPRESA DO SETOR TÊXTIL

GERALDO GIRARDI

Orientadora: Prof^a Maria Emília Camargo, Ph.D.

Caxias do Sul, janeiro de 2008.

GERALDO GIRARDI

**MODELO INTEGRADO PARA PREVISÃO DE VENDAS COMO UMA
FERRAMENTA DE COMPETITIVIDADE: UM ESTUDO DE CASO EM
UMA EMPRESA DO SETOR TÊXTIL**

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Administração da Universidade de Caxias do Sul como requisito parcial à obtenção do grau de Mestre em Administração.

Orientadora: Prof^ª Maria Emília Camargo, Ph.D.

Caxias do Sul, janeiro de 2008.

Dados Internacionais de Catalogação na Publicação (CIP)
Universidade de Caxias do Sul
UCS - BICE - Processamento Técnico

G521m Girardi, Geraldo

Modelo integrado para previsão de vendas como uma ferramenta de competitividade : um estudo de caso em uma empresa do setor têxtil / Geraldo Girardi. 2008.

139 f. : il. ; 30 cm.

Orientação: Prof^a. Dr^a. Maria Emília Camargo.

Dissertação (Mestrado) – Universidade de Caxias do Sul, Programa de Pós-Graduação em Administração, 2008.

1. Empresas – Planejamento estratégico. 2. Vendas – Previsão. 3. Competitividade. 4. Produção – Otimização. 5. Indústria têxtil – Estudo de caso. I. Título.

CDU: 658.012.2

Índice para o catálogo sistemático:

- | | |
|--|--------------|
| 1. Empresas – Planejamento estratégico | 658.012.2 |
| 2. Vendas – Previsão | 658.811 |
| 3. Competitividade | 658.011 |
| 4. Produção – Otimização | 658.5.011 |
| 5. Indústria têxtil – Estudo de caso | 677:65.012.1 |

Catalogação na fonte elaborada pela bibliotecária
Márcia Carvalho Rodrigues – CRB 10/1.411

GERALDO GIRARDI

**MODELO INTEGRADO PARA PREVISÃO DE VENDAS COMO UMA
FERRAMENTA DE COMPETITIVIDADE: UM ESTUDO DE CASO EM
UMA EMPRESA DO SETOR TÊXTIL**

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Administração da Universidade de Caxias do Sul como requisito parcial à obtenção do grau de Mestre em Administração.

Conceito Final: 4.

Aprovada em 04 de janeiro de 2008.

BANCA EXAMINADORA:

Prof.^a Dr.^a Suzana Leitão Russo - UFS

Prof. Dr. Ademar Galelli – UCS

Prof. Dr. Reynaldo Chile Palomino - UCS

Ao amor e à compreensão da minha esposa Inaiara e ao Pedro, nosso amado filho, que ilumina nossas vidas com sua alegria.

AGRADECIMENTOS

Agradeço à Universidade de Caxias do Sul e a todos os professores e funcionários ligados ao Programa de Pós-Graduação em Administração, pela realização do curso que possibilitou meu crescimento pessoal e profissional.

À minha orientadora, professora Maria Emília Camargo, pela grande contribuição, pelo apoio e pelos ensinamentos recebidos.

A todos os meus colegas do curso, em especial ao amigo Esequiel Berra de Mello.

Agradeço, também, à empresa que me possibilitou a realização do estudo contido neste trabalho.

Aos meus pais, Antônio e Bogdana, pelo amor, pela dedicação, orientação, fé e pelo exemplo de vida: valores fundamentais na construção de minha personalidade.

Agradeço aos meus avós (*in memoriam*), especialmente ao meu avô Antônio Papèe, pelo carinho, pela paciência, amizade e pelo estímulo à leitura.

À minha cunhada Caia: obrigado pela ajuda na formatação deste trabalho.

Ao meu querido filho Pedro: muito obrigado
pelas lições de informática que aprendi
contigo.

“A necessidade é a mãe da invenção.”

Taiichi Ohno

RESUMO

No ambiente de negócios, o planejamento das atividades organizacionais aliado à previsão de vendas, possibilita a otimização dos recursos envolvidos na empresa. Assim, esta dissertação teve como objetivo adequar modelos de previsão de vendas de forma a auxiliar o gestor na tomada de decisões, proporcionando maior competitividade para a empresa no mercado de atuação. Para tanto, utilizou-se a metodologia estatística para séries temporais, mais especificamente os modelos Box & Jenkins para a previsão quantitativa. Para a previsão qualitativa, utilizou-se o método de julgamento de valor, ou seja, a opinião dos responsáveis pela previsão de vendas da empresa. Com base nas previsões obtidas pelos dois métodos, encontraram-se modelos combinados, utilizando-se o volume de vendas dos principais produtos produzidos nos últimos cinco anos pelo setor de fabricação de tecidos de malha feitos em máquinas circulares de uma empresa têxtil. Através da análise dos fatores que influenciam as vendas, realizada pelos responsáveis pelo planejamento da empresa, foram calculados os modelos integrados. Vários modelos de previsão foram avaliados, resultando que os modelos integrados para a previsão de vendas a curto prazo, baseados em modelos quantitativos e informações qualitativas foram aqueles que apresentaram maior acurácia no processo de previsão.

Palavras-chave: Previsão; Competitividade; Modelos Box & Jenkins; Modelo Integrado.

ABSTRACT

In the business setting, the planning of the organizational activities along with the sales forecast enables the optimization of the resources involved in the company. The goal of this dissertation was to fit models of sales forecast to help the manager on the decision taking process seeking for the biggest competitiveness in the company and its competitors. For that purpose, this dissertation proposed the statistic methodology for temporal series, more specifically the Box & Jenkins methods to quantitative method of forecast and planning task specialist opinion of those responsible for the sales forecast of the company to qualitative method. Through the forecast of the both methods, we chose combined models, using as variables the volume of sales of main products produced by the department of knitting cloth manufacturing on the circular machines of the company in the last five years. The integrated models were calculated analyzing the sales influencing factors realized by the responsible for the planning of the company. Many models of sales forecast were evaluated, resulting that the integrated models to sales forecast on a short term, based on quantitative and qualitative methods, had a better accuracy in the forecasting process.

Key words: Forecast; Competitiveness; Box & Jenkins Models; Integrated Model

SUMÁRIO

RESUMO	6
ABSTRACT	7
LISTA DE TABELAS	10
LISTA DE FIGURAS	11
LISTA DE QUADROS	14
LISTA DE ABREVIATURA E SIGLAS	15
1 INTRODUÇÃO	16
1.1 IDENTIFICAÇÃO DO PROBLEMA DE PESQUISA.....	18
1.2 OBJETIVOS DA PESQUISA.....	18
1.3 JUSTIFICATIVA E RELEVÂNCIA DO TEMA.....	19
1.4 ESTRUTURA DO TRABALHO.....	20
2 REFERENCIAL TEÓRICO	21
2.1 COMPETITIVIDADE.....	21
2.2 GESTÃO DA DEMANDA.....	23
2.3 PREVISÃO DE VENDAS.....	24
2.4 MÉTODOS DE PREVISÃO.....	29
2.4.1 Métodos Qualitativos	29
2.4.1.1 Método Delphi.....	30
2.4.1.2 Pesquisa de Mercado.....	30
2.4.1.3 Analogia Histórica.....	31
2.4.1.4 Opinião de Executivos.....	31
2.4.2 Métodos Quantitativos	32
2.4.2.1 Séries Temporais.....	32
2.4.2.2 Modelos de Box & Jenkins	37
2.4.2.2.1 Modelos Univariados de Box & Jenkins sem intervenção.....	39
2.4.2.2.2 Modelos Univariados de Box & Jenkins com intervenção.....	54
2.4.2.2.3 Etapas para a construção de um modelo de previsão Box & Jenkins.....	58
2.4.3 Combinação de Métodos de Previsão – Modelo Combinado	63
2.4.4 Modelo Integrado	64
2.4.5 Seleção do Modelo de Previsão	68
2.4.6 Controle do Modelo de Previsão Selecionado	70
2.4.7 Custo da Previsão	72
2.4.8 Síntese do Capítulo	73
3 METODOLOGIA	74
4 ESTUDO DE CASO	78

4.1 ANÁLISE QUANTITATIVA.....	78
4.1.1 Série representativa das vendas do produto A.....	78
4.1.1.1 Modelo sem intervenção para as vendas do produto A.....	79
4.1.1.2 Modelo com intervenção para as vendas do produto A.....	83
4.1.1.3 Previsão para as vendas do produto A.....	84
4.1.2 Série representativa das vendas do produto B.....	84
4.1.2.1 Modelo sem intervenção para as vendas do produto B.....	85
4.1.2.2 Modelo com intervenção para as vendas do produto B.....	87
4.1.2.3 Previsão para as vendas do produto B.....	88
4.1.3 Série representativa das vendas do produto C.....	89
4.1.3.1 Modelo sem intervenção para as vendas do produto C.....	90
4.1.3.2 Modelo com intervenção para as vendas do produto C.....	93
4.1.3.3 Previsão para as vendas do produto C.....	95
4.1.4 Série representativa das vendas do produto D.....	95
4.1.4.1 Modelo sem intervenção para as vendas do produto D.....	97
4.1.4.2 Modelo com intervenção para as vendas do produto D.....	99
4.1.4.3 Previsão para as vendas do produto D.....	100
4.1.5 Série representativa das vendas do produto E.....	101
4.1.5.1 Modelo sem intervenção para as vendas do produto E.....	103
4.1.5.2 Modelo com intervenção para as vendas do produto E.....	106
4.1.5.3 Previsão para as vendas do produto E.....	107
4.1.6 Série representativa das vendas do produto H.....	107
4.1.6.1 Modelo sem intervenção para as vendas do produto H.....	112
4.1.6.2 Modelo com intervenção para as vendas do produto H.....	113
4.1.6.3 Previsão para as vendas do produto H.....	114
4.1.7 Série representativa das vendas do produto M.....	115
4.1.7.1 Modelo sem intervenção para as vendas do produto M.....	117
4.1.7.2 Modelo com intervenção para as vendas do produto M.....	118
4.1.7.3 Previsão para as vendas do produto M.....	119
4.2 ANÁLISE QUALITATIVA.....	120
4.3 MODELOS COMBINADOS.....	122
4.4 MODELOS INTEGRADOS.....	124
4.5 RESULTADOS FINAIS.....	125
5 CONSIDERAÇÕES FINAIS.....	130
5.1 TRABALHOS FUTUROS.....	133
REFERÊNCIAS.....	134

LISTA DE TABELAS

Tabela 1: Medidas descritivas do produto A.....	79
Tabela 2: Medidas descritivas do produto B.....	85
Tabela 3: Medidas descritivas do produto C.....	89
Tabela 4: Medidas descritivas do produto D.....	96
Tabela 5: Medidas descritivas do produto E.....	101
Tabela 6: Medidas descritivas do produto H.....	108
Tabela 7: Medidas descritivas do produto M.....	115

LISTA DE FIGURAS

Figura 1: Sistema genérico de previsão de vendas.....	25
Figura 2: Relação do sistema de previsão com as áreas da empresa e o mercado.....	28
Figura 3: Efeito da tendência em séries temporais.....	34
Figura 4: Efeito da sazonalidade em séries temporais.....	35
Figura 5: Efeito da componente cíclica em séries temporais.....	35
Figura 6: Processo estocástico e série temporal.....	36
Figura 7: Representação teórica de um modelo ARIMA (p,d,q).....	41
Figura 8: Gráficos do modelo AR (1).....	48
Figura 9: Gráficos do modelo AR (2).....	49
Figura 10: Gráficos do modelo MA (1).....	50
Figura 11: Gráficos do modelo MA (2).....	51
Figura 12: Gráficos do modelo ARMA (1,1).....	52
Figura 13: Fluxograma do ciclo iterativo de Box & Jenkins.....	62
Figura 14: Relação entre a acurácia do método e o custo da previsão.....	73
Figura 15: Comportamento da série original do volume de vendas (Kg) do produto A.....	80
Figura 16: Coeficientes da função de autocorrelação da série de vendas do produto A – modelo sem intervenção.....	81
Figura 17: Coeficientes da função de autocorrelação parcial da série de vendas do produto A – modelo sem intervenção.....	81
Figura 18: Coeficientes da função de autocorrelação dos resíduos do produto A – modelo sem intervenção.....	82
Figura 19: Coeficientes da função de autocorrelação dos resíduos do produto A – modelo com intervenção.....	83
Figura 20: Comportamento da série original do volume de vendas (Kg) do produto B.....	85
Figura 21: Coeficientes da função de autocorrelação da série de vendas do produto B – modelo sem intervenção.....	86
Figura 22: Coeficientes da função de autocorrelação parcial da série de vendas do produto B – modelo sem intervenção.....	86
Figura 23: Coeficientes da função de autocorrelação dos resíduos do produto B – modelo sem intervenção.....	87
Figura 24: Coeficientes da função de autocorrelação dos resíduos do produto B – modelo com intervenção.....	88
Figura 25: Comportamento da série original do volume mensal de vendas (Kg) do produto C.....	90

Figura 26: Comportamento da série transformada (raiz quadrada) do volume mensal de vendas (Kg) do produto C.....	91
Figura 27: Coeficientes da função de autocorrelação da série de vendas do produto C.....	91
Figura 28: Coeficientes da função de autocorrelação parcial da série de vendas do produto C.....	92
Figura 29: Coeficientes da função de autocorrelação da série de resíduos do produto C – modelo sem intervenção.....	93
Figura 30: Coeficientes da função de autocorrelação dos resíduos do modelo SARIMA (1,0,0)x(2,0,0) com intervenção das vendas do produto C.....	94
Figura 31: Comportamento da série original do volume mensal de vendas do produto D...	96
Figura 32: Coeficientes da função de autocorrelação da série de vendas do produto D.....	97
Figura 33: Coeficientes da função de autocorrelação parcial da série de vendas do produto D.....	97
Figura 34: Coeficientes da função de autocorrelação da série de resíduos do produto D – modelo sem intervenção.....	98
Figura 35: Coeficientes da função de autocorrelação da série de resíduos do produto D – modelo com intervenção.....	100
Figura 36: Comportamento da série original do volume mensal de vendas do produto E...	101
Figura 37: Coeficientes da função de autocorrelação da série de vendas do produto E.....	102
Figura 38: Coeficientes da função de autocorrelação parcial da série de vendas do produto E.....	102
Figura 39: Comportamento da série transformada do volume de vendas do produto E.....	103
Figura 40: Coeficientes da função de autocorrelação da série transformada do produto E..	104
Figura 41: Coeficientes da função de autocorrelação parcial da série transformada do produto E – modelo sem intervenção.....	104
Figura 42: Coeficientes da função de autocorrelação da série de resíduos do produto E – modelo sem intervenção.....	105
Figura 43: Coeficientes da função de autocorrelação da série de resíduos do produto E – modelo com intervenção.....	106
Figura 44: Comportamento da série original do volume de vendas do produto H.....	108
Figura 45: Coeficientes da função de autocorrelação da série de vendas do produto H.....	109
Figura 46: Coeficientes da função de autocorrelação parcial da série de vendas do produto H.....	109
Figura 47: Comportamento da série transformada (logaritmo) do volume mensal de vendas (Kg) do produto H.....	110
Figura 48: Coeficientes da função de autocorrelação da série transformada (logaritmo) do produto H.....	110
Figura 49: Coeficientes da série transformada (logaritmo e diferença) do volume mensal de vendas (Kg) do produto H.....	111

Figura 50: Coeficientes da função de autocorrelação da série transformada (logaritmo e diferença) para o produto H.....	111
Figura 51: Coeficientes da função de autocorrelação parcial da série transformada (logaritmo e diferença) do produto H.....	112
Figura 52: Coeficientes da função de autocorrelação da série dos resíduos do produto H.....	113
Figura 53: Coeficientes da função de autocorrelação da série de resíduos do produto H-modelo sem intervenção.....	114
Figura 54: Comportamento da série original do volume de vendas do produto M.....	116
Figura 55: Coeficientes da função de autocorrelação da série de vendas do produto M.....	116
Figura 56: Coeficientes da função de autocorrelação parcial da série de vendas do produto M.....	117
Figura 57: Coeficientes de autocorrelação dos resíduos do produto M – modelo sem intervenção.....	118
Figura 58: Coeficientes de autocorrelação da série de resíduos do produto M – modelo com intervenção.....	119

LISTA DE QUADROS

Quadro 1: Características das FAC's e FACP's dos modelos AR, MA e ARMA.....	47
Quadro 2: Características dos processos MA (1) e MA(2).....	50
Quadro 3: Comparação do Método de Box & Jenkins com e sem Intervenção com os Valores Previstos pela Empresa e as vendas reais do produto A através do MAPE.....	84
Quadro 4: Comparação do Método de Box & Jenkins com e sem Intervenção com os Valores Previstos pela Empresa para as vendas do produto B.....	89
Quadro 5: Comparação do Método de Box & Jenkins com e sem Intervenção com os Valores Previstos pela Empresa e as vendas reais do produto C através do MAPE.....	95
Quadro 6: Comparação do Método de Box & Jenkins com e sem Intervenção com os Valores Previstos pela Empresa e as vendas reais do produto D através do MAPE.....	100
Quadro 7: Comparação do Método de Box & Jenkins com e sem Intervenção com os Valores Previstos pela Empresa e as vendas reais do produto E através do MAPE.....	107
Quadro 8: Comparação do Método de Box & Jenkins com e sem Intervenção com os Valores Previstos pela Empresa e as vendas reais do produto H através do MAPE.....	114
Quadro 9: Comparação do Método de Box & Jenkins com e sem Intervenção com os Valores Previstos pela Empresa e as vendas reais do produto M através do MAPE.....	119
Quadro 10: Previsão da empresa quanto às vendas dos principais produtos.....	120
Quadro 11: Análise Qualitativa da previsão de vendas da empresa.....	121
Quadro 12: Cálculo do Modelo Integrado.....	124
Quadro 13: Comparação dos Métodos de Previsão de Vendas do produto A através do MAPE.....	126
Quadro 14: Comparação dos Métodos de Previsão de Vendas do produto C através do MAPE.....	127
Quadro 15: Comparação dos Métodos de Previsão de Vendas do produto D através do MAPE.....	127
Quadro 16: Comparação dos Métodos de Previsão de Vendas do produto E através do MAPE.....	127
Quadro 17: Comparação dos Métodos de Previsão de Vendas do produto H através do MAPE.....	128
Quadro 18: Comparação dos Métodos de Previsão de Vendas do produto M através do MAPE.....	128
Quadro 19: Comparação da Acurácia entre os Modelos de Previsão de Vendas para os produtos analisados.....	128

LISTA DE ABREVIATURAS E SIGLAS

AIC	Critério de Informação de Akaike
AR	Parcela auto-regressiva do modelo ARIMA
ARMA	Modelo auto-regressivo e de média móvel
ARIMA	Modelo auto-regressivo, integrado e de média móvel
BIC	Critério de Informação Bayesiano ou de Schwarz
C	Componente Cíclica de uma série temporal
DAM	Desvio Absoluto Médio
DP	Desvio-Padrão
EQM	Erro Quadrático Médio
FAC	Função de Autocorrelação do modelo Box & Jenkins
FACP	Função de Autocorrelação Parcial do modelo Box & Jenkins
I	Parcela de integração do modelo ARIMA
MA	Parcela de média móvel do modelo ARIMA
MAPE	Erro Médio Percentual Absoluto
PPCP	Sistema de Planejamento, Programação e Controle da Produção
R ²	Coefficiente de Determinação
S	Componente da Sazonalidade de uma série temporal
SA	Sinal de Acompanhamento
SAE	Soma Acumulada dos Erros de Previsão
T	Componente da tendência de uma série temporal
TR	Sinal Trigg

1 INTRODUÇÃO

Com o crescente nível de competitividade no mercado globalizado, pode-se afirmar que o planejamento das atividades, na busca da otimização dos recursos aplicados em uma empresa, é um dos principais objetivos dos gestores. A previsão, principalmente com os avanços da tecnologia em *softwares*, apresenta-se como uma ferramenta capaz de prever as necessidades futuras do mercado, tornando as decisões mais eficazes. Esta orientação perpassa toda a organização, influenciando as áreas de manufatura, de finanças, de marketing e de recursos humanos (CORRÊA; GIANESI; CAON, 2001; SLACK; CHAMBERS; JOHNSTON, 2002).

Em um ambiente de negócios, com mudanças constantes e cada vez mais rápidas, os métodos de previsão têm ajudado na orientação quanto ao direcionamento futuro de variáveis que influenciam os planejamentos de curto, médio e longo prazo. Uma correta orientação aumentará as chances de obter bons resultados que contribuirão para o crescimento da organização (GEORGOFF; MURDICK, 1986).

Previsões de futuro são indispensáveis para o planejamento e formulação de estratégias das empresas. Neste sentido, *Forecasting* ou previsão de vendas permite verificar tendências futuras que poderão impactar na organização. A integração entre *forecasting* e o processo de planejamento aumenta a possibilidade da empresa adaptar-se às oportunidades e aos riscos do mercado, aumentando a probabilidade de sucesso da organização (MAKRIDAKIS, 1996).

A previsão de vendas é importante para que todas as atividades necessárias ao processo industrial sejam adequadamente programadas. Apesar de as previsões serem importantes e úteis para o planejamento das atividades, elas apresentam erros em suas estimativas. Dessa forma, deve-se ter muito cuidado na escolha do modelo de previsão com o objetivo de minimizar os erros (MARTINS; LAUGENI, 2006).

As incertezas das previsões e os erros correspondentes provêm de duas fontes: a primeira refere-se ao mercado, que geralmente apresenta instabilidade e, portanto, baixa previsibilidade, e a segunda corresponde à eficácia do sistema de previsão de vendas, que se baseia nas informações coletadas no mercado e em dados históricos da empresa, buscando antecipar as necessidades dos clientes (CORRÊA; GIANESI; CAON, 2001).

A previsão de vendas fornece informações aos gerentes, permitindo melhorar a eficácia na tomada de decisões. Mesmo com os erros associados a esse processo, torna-se importante para o gerente estabelecer uma prática de revisão freqüente dessas previsões, buscando escolher a metodologia que melhore a acurácia dos resultados, dentro de um custo aceitável (DAVIS; AQUILANO; CHASE, 2001).

Há diversas formas de classificar os modelos e técnicas de previsão. Uma das classificações divide a técnica em:

- a) subjetivas e objetivas;
- b) não causais e causais.

As técnicas subjetivas de previsão estão baseadas na experiência e na intuição dos indivíduos. As técnicas objetivas são aquelas que têm procedimentos especificados e sistemáticos. As técnicas não causais são aquelas que utilizam valores históricos para prever seus valores futuros, como as séries temporais. As técnicas causais procuram fazer previsões com base em uma relação de causa e efeito (SLACK; CHAMBERS; JOHNSTON, 2002).

Nesta dissertação, foi construído um modelo de previsão de vendas, através do qual determinam-se os níveis de produção, de forma a otimizar os recursos disponíveis na empresa para aumentar a sua competitividade no mercado. Segundo Samohyl (2006), a decisão do gestor de fixar os níveis de produção é o resultado de uma previsão de vendas, a qual deverá ser a mais perfeita possível, pois muitos problemas organizacionais resultam de projeções imperfeitas. Errar uma previsão de vendas, para mais ou para menos, demonstra que o profissional de vendas não tem o suficiente controle do negócio, além de gerar prejuízos para a empresa, como o excesso de estoque ou, por outro lado, a falta de produtos e a conseqüente perda de faturamento, além da queda no nível de atendimento ao cliente.

Os dados a serem analisados referem-se ao volume de vendas mensais dos principais produtos do setor analisado, no período de janeiro de 2002 a dezembro de 2006. Optou-se por analisar o total das vendas devido à estratégia competitiva da empresa em atender, de forma rápida, os pedidos dos clientes. Assim, a empresa mantém estoque de produtos semi-elaborados para sustentar esse diferencial competitivo implicando a adequação da área de produção em manter o nível de estoque desses produtos semi-elaborados, com o objetivo de atingir um bom nível de atendimento ao cliente.

1.1 IDENTIFICAÇÃO DO PROBLEMA DE PESQUISA

Atualmente, os responsáveis pelo planejamento da empresa, o gestor do planejamento e do controle da produção e o responsável pela área comercial utilizam apenas a experiência e alguns dados dos vendedores quanto a pedidos confirmados ou perspectivas de vendas. O que pode ser feito, a fim de melhorar as previsões da empresa? Assim, este trabalho buscou encontrar, através da combinação de previsões baseada em métodos quantitativos e qualitativos, um modelo que representasse o comportamento dos dados referentes às vendas dos principais produtos do setor de fabricação de tecidos de malha, feitos em máquinas circulares da empresa têxtil analisada, apresentando, assim, uma ferramenta para projetar o futuro a curto prazo. A modelagem quantitativa e qualitativa do comportamento da demanda permite, de forma geral, previsões mais ajustadas quando comparadas com as previsões baseadas unicamente na experiência do gestor. Através dessa ferramenta, o gestor poderá otimizar os estoques de matéria-prima e materiais de consumo, utilizar de forma eficiente a capacidade das máquinas com a redução das trocas (*set-up*), prever alterações na demanda e sua influência nas necessidades de pessoal, tornando a gestão da organização mais eficaz.

1.2 OBJETIVOS DA PESQUISA

Objetivo Geral: Adequar um modelo de previsão de vendas a fim de auxiliar o gestor na tomada de decisões, na busca da otimização dos recursos disponíveis na empresa, como forma de aumentar a competitividade da organização, aproveitando as oportunidades e minimizando os riscos inerentes ao mercado de atuação.

Objetivos Específicos: A partir do objetivo geral, a presente dissertação foi estruturada em objetivos específicos a seguir:

- a) Selecionar os principais produtos a serem analisados;
- b) Obter previsões quantitativas, aplicando a metodologia de Box & Jenkins aos principais produtos, em termos de vendas, do setor de fabricação de tecidos de malha feitos em máquinas circulares da empresa;

- c) Selecionar o modelo de previsão quantitativo mais adequado;
- d) Obter previsões qualitativas;
- e) Encontrar o modelo combinado, baseado na combinação das previsões quantitativas e qualitativas;
- f) Construir o modelo integrado através das informações qualitativas referentes aos fatores que influenciam as vendas na ótica dos responsáveis pelo planejamento da empresa;
- g) Comparar as previsões obtidas pelos métodos aplicados com o método qualitativo atualmente utilizado na empresa.

1.3 JUSTIFICATIVA E RELEVÂNCIA DO TEMA

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. Dessa forma, a previsão de vendas possibilita o planejamento das diversas áreas da empresa, pois, mediante análise de dados passados ou históricos, combinados com a opinião dos responsáveis pela previsão de vendas da empresa, podem ser realizadas previsões a curto prazo, as quais fornecem as informações necessárias aos gerentes nas tomadas de decisão. Embora os erros estejam presentes nas estimativas, a metodologia utilizada na previsão de demanda permite planejar de forma mais precisa, se comparada ao planejamento baseado unicamente na experiência e na intuição do responsável pela atividade na empresa.

A previsão de vendas é importante para a organização, pois afeta diretamente todas as áreas da empresa. No marketing, ela contribui para um maior nível de atendimento ao cliente. A partir da previsão de vendas, é realizada a compra de matérias-primas e materiais pela área de logística. A busca pela otimização dos estoques afeta a área financeira, com o objetivo de reduzir o ativo imobilizado. Na área de produção, com uma estimativa de vendas futuras, é possível reduzir o número de *set-ups*, ganhando produtividade e competitividade.

Este estudo, desenvolvido por meio de um modelo apropriado de previsão de vendas, permitirá ao gestor da empresa atualizar as informações decorrentes de alterações do mercado, sustentar as tomadas de decisão pelo uso da ferramenta de previsões e planejar ações nas diversas áreas afetadas, com o objetivo de otimizar recursos e atender aos clientes,

melhorando a competitividade da empresa no mercado. Atualmente, a empresa não utiliza nenhum método quantitativo de previsão de vendas.

1.4 ESTRUTURA DO TRABALHO

Este trabalho está dividido em quatro capítulos. O capítulo 1 apresenta a introdução, a identificação do problema de pesquisa, o objetivo geral, os objetivos específicos, a justificativa e a relevância do tema.

Na seqüência, o capítulo 2 aborda o referencial teórico que sustenta a pesquisa, através de uma revisão da literatura relativa aos assuntos tratados. Ressaltam-se a conceituação e a importância da Competitividade, da Gestão da Demanda, da Previsão de Vendas e, finalmente, dos Métodos de Previsão. Este último tópico foi o mais aprofundado no trabalho, devido à importância do tema na pesquisa.

O Capítulo 3 apresenta a metodologia utilizada neste estudo de caso, sendo um trabalho caracterizado como uma pesquisa aplicada, pois dá ênfase à solução de problemas concretos mediante o emprego de procedimentos científicos.

O Capítulo 4 descreve a análise dos dados de vendas dos principais produtos do setor de fabricação de malhas por meio de máquinas circulares dos últimos cinco anos, analisando e aplicando diversos métodos de previsão de forma a obter um modelo de previsão satisfatório. A partir desses modelos, podem-se comparar os resultados obtidos pela modelagem escolhida com o método atual de previsão da empresa baseado apenas na análise qualitativa, além de propor o monitoramento dos erros de previsão, de forma a reestimar o modelo quando necessário.

Finalmente, na conclusão do trabalho são resgatados os principais resultados obtidos na pesquisa, ratificando a importância dos resultados alcançados, além de abordar as limitações do estudo e as oportunidades de aplicação desta pesquisa em trabalhos futuros.

2 REFERENCIAL TEÓRICO

Nesse capítulo é apresentada a estrutura teórica escolhida para dar suporte ao desenvolvimento desta dissertação.

2.1 COMPETITIVIDADE

As mudanças econômicas ocorridas nos últimos tempos, como o processo de globalização e o grande desenvolvimento tecnológico, têm forçado as organizações empresarias a adaptarem-se continuamente ao novo cenário, onde a competitividade da empresa no mercado é uma forma de sobrevivência das organizações. Esta situação requer especial atenção das empresas ao planejamento adequado das atividades envolvidas no processo de produção, a fim de melhorar o fluxo e alocação de informações, materiais e pessoas, e atender satisfatoriamente à demanda pelos seus produtos e tornar-se competitiva.

Assim, com estas freqüentes mudanças que estão ocorrendo no mundo dos negócios, a capacidade de competição das empresas se constitui em elemento fundamental na determinação de seu desempenho futuro, fazendo com que as mesmas realizem freqüentes reavaliações das tendências do mercado e necessitem de um conhecimento aprofundado à respeito de seu posicionamento nesse mercado (EUCLIDES FILHO, 2004).

Para Wacker e Cromatic (1979) a função da previsão de vendas é um fator de equilíbrio entre oportunidades mercadológicas e a utilização de recursos, os quais proporcionam lucratividade do negócio e, como consequência, maior competitividade no mercado de atuação. Previsões de vendas muito altas farão com que a empresa utilize muitos recursos e, caso não forem concretizadas as previsões, ocorrerá queda na rentabilidade da empresa devido ao excesso de recursos utilizados e não aproveitados, como é o caso dos estoques. No caso das previsões serem baixas, mas ocorrer um aumento de demanda no mercado, a empresa irá perder faturamento devido à incapacidade de atender os pedidos dos clientes, causando queda na competitividade.

Segundo Farina (1999) e Ferraz et al. (1996), a competitividade pode ser vista como uma medida de desempenho de uma empresa ou de um produto. No entanto, este desempenho depende de relações sistêmicas, já que as estratégias empresariais podem ser obstadas por gargalos de coordenação vertical ou de logística.

Para Kennedy et al. (1998) o principal indicador de competitividade, nessa contextualização, estaria ligado à participação de um produto ou firma individual em um determinado mercado. A utilização da participação do mercado (*Market Share*) como medida de competitividade é a contribuição mais difundida da economia neoclássica para os estudos de competitividade.

Ferraz et al. (1996) enfocam a competitividade como eficiência das ações estratégicas adotadas pelos agentes econômicos face às restrições do ambiente organizacional. Segundo essa ótica, existiria uma relação causal entre as estratégias adotadas pela firma e o seu desempenho eficiente, o que leva diretamente ao modelo teórico da organização industrial, qual seja, estrutura – conduta – desempenho.

Neste contexto, pode-se dizer que a competitividade é um conceito dinâmico. Para acompanhar o complexo processo concorrencial, as empresas devem ter um olho no passado, para fortalecer os acertos e não repetir erros; os pés firmes no presente, para posicionar-se com segurança diante da instabilidade do mercado; e um olhar atento para o futuro, para fazer os ajustes que forem necessários. No que se refere às empresas, os fatores que determinam a competitividade podem ser classificados em fatores sistêmicos, fatores estruturais e internos (SILVA, 2001).

É no contexto dos fatores estruturais, os quais se referem ao mercado, que a previsão de demanda atua como um elemento determinante para o conhecimento do potencial da empresa no futuro, identificando os seus gargalos e possibilitando um planejamento mais otimizado em relação às necessidades de produção.

A utilização de um sistema de previsão preciso representa um fator de competitividade, pois isto proporciona à empresa uma melhor visão do mercado futuro, podendo, assim, articular-se de forma mais eficiente com seus clientes e manter uma posição competitiva.

Toda a empresa, para ser competitiva, deve, além de conhecer o seu mercado, possuir um bom planejamento. Para isto deve ter uma boa previsão. A previsão da demanda fornece informações fundamentais para o planejamento, sendo a base para se desenvolver o

planejamento mestre da produção, o planejamento da capacidade e o planejamento de estoques.

A tendência atual é que a área produtiva esteja cada vez mais próxima dos clientes e fornecedores, recebendo informações fundamentais do mercado no sentido de agregar valor ao produto e, desta forma, manter a vantagem competitiva da empresa no mercado, como, por exemplo, a entrega rápida dos produtos aos clientes. No passado, a área de produção concentrava-se apenas na minimização dos custos, assumindo um papel reativo, bem diferente do atual, quando a atuação da área produtiva é pró-ativa, a qual busca a maximização do valor agregado de bens e serviços oferecidos pela organização aos clientes (DAVIS; AQUILANO; CHASE, 2001; CHRISTOPHER, 2002).

A chave para criar uma estratégia de produção eficaz está em como agregar valor para os clientes. As prioridades competitivas determinam a agregação de valor ao produto ou serviço, sustentando uma estratégia. As prioridades competitivas básicas são: custo (fornecer produtos de baixo custo), qualidade (produtos de qualidade de forma a satisfazer o cliente), entrega (fornecer os produtos de forma rápida e com confiabilidade da entrega), flexibilidade (oferecer ampla variedade de produtos a seus consumidores) e serviço (como os produtos são acompanhados junto aos clientes). Assim, as empresas devem estabelecer a vantagem competitiva a ser atingida como forma de concorrer no mercado (STALK, 1988; SKINNER, 1969).

2.2 GESTÃO DA DEMANDA

A gestão de demanda engloba um conjunto de processos que fazem a interface da empresa com o mercado consumidor. Dependendo do negócio, esses processos podem incluir o cadastramento de pedidos, a previsão de vendas, a promessa de entrega, o serviço ao cliente e a distribuição física. É fundamental para a administração da produção que a informação de demanda esteja disponível e seja comunicada eficazmente, de modo que o planejamento possa ser feito com a otimização dos recursos (SLACK; CHAMBERS; JOHNSTON, 2002; BALLOU, 2001).

A função gestão de demanda abrange cinco áreas principais, destacando-se a previsão de demanda, a comunicação com o mercado, a influência sobre a demanda, a promessa de prazos de entrega, além da priorização e alocação dos pedidos (CORRÊA; GIANESI; CAON, 2001):

- a) Habilidade para prever a demanda: é importante que a empresa consiga antecipar a demanda com alguma precisão. Isso pode envolver a manutenção de uma base de dados históricos de vendas, assim como informações das variações ocorridas ao longo do tempo. A empresa pode usar modelos matemáticos adequados que ajudem a explicar o comportamento da demanda;
- b) Canal de comunicação com o mercado: os vendedores ou representantes têm um papel muito importante de trazer informações dos clientes e do mercado para a empresa, de forma contínua e permanente, contribuindo para a gestão da demanda;
- c) Poder de influência sobre a demanda: além de prever o comportamento da demanda, é fundamental que a empresa procure influenciá-lo, por meio de propaganda ou por meio de promoção;
- d) Habilidade de prometer prazos: a garantia do desempenho na confiabilidade de entregas é responsabilidade de quem faz a gestão de demanda;
- e) Habilidade de priorização e alocação: o atendimento dos pedidos realizados pelos clientes é o principal objetivo da gestão de demanda.

A gestão de demanda alimenta, com informações do mercado, a área de planejamento, programação e controle da produção. Assim, a atividade do PPCP necessita de informações corretas para incorporá-las ao processo de planejamento da produção. É fundamental que a área comercial, geralmente o responsável pela previsão de vendas, e a área de planejamento trabalhem integradas e coordenadas pelo gestor da organização, que pode utilizar os dados históricos de vendas, os quais alimentam um modelo matemático de previsão, além das valiosas informações do mercado (CORRÊA; GIANESI; CAON, 2001; VOLLMANN; BERRY; WHYBARK, 1997).

2.3 PREVISÃO DE VENDAS

A previsão de vendas é uma forma de estimar a demanda futura através da antecipação do que os compradores provavelmente farão em determinado conjunto de condições. A previsão de vendas fornece uma estimativa da demanda dos produtos individuais, a qual,

quando integrada ao plano agregado de produção, corresponde à produção necessária para o programa mestre de produção, e este gera para a empresa a quantidade e os dados dos produtos finais individuais. O processo de monitorar e de integrar estas informações é denominado gestão da demanda (CAVALHEIRO, 2003).

O sistema de previsão de vendas é o conjunto de procedimentos de coleta, tratamento e análise de informações que objetiva gerar uma estimativa de vendas futuras. As principais informações que devem ser analisadas pelo sistema de previsão de vendas são (CORRÊA; GIANESI; CAON, 2001):

- a) Dados históricos de vendas;
- b) Informações de clientes que possam indicar comportamentos de compra futuros;
- c) Informações do mercado;
- d) Informações sobre a situação econômica atual e previsão futura da conjuntura econômica;
- e) Estratégia da empresa e seus desdobramentos na área comercial.

A Figura 1 ilustra um sistema de previsão de vendas:

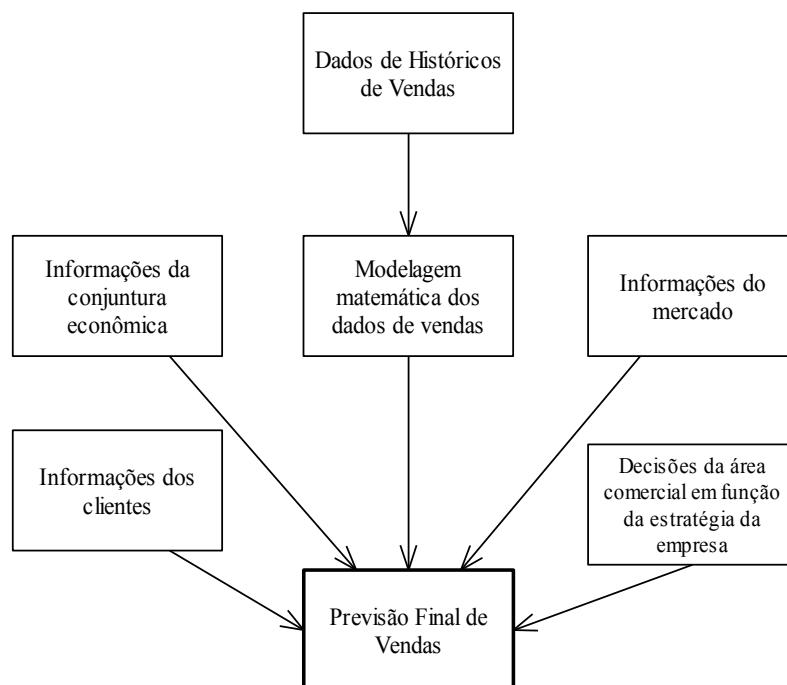


Figura 1: Sistema genérico de previsão de vendas.

Fonte: Adaptado de Corrêa, Gianesi e Caon (2001), p. 247.

Esse modelo de previsão de vendas inicia com um tratamento estatístico, por meio de séries temporais ou modelos causais dos dados históricos de vendas. Podem-se analisar outras variáveis que ajudem a explicar o comportamento das vendas no passado. As demais informações sobre o mercado, os clientes e a própria situação econômica afetam a previsão de vendas. Dessa forma, utiliza-se o tratamento estatístico, pacotes de ferramentas computacionais que auxiliam a empresa no tratamento dos dados históricos, aliado à percepção de mercado, para obter maior acurácia da previsão (CORRÊA; GIANESI; CAON, 2001; FLEURY; WANKE; FIGUEIREDO, 2003). A atividade de realizar a previsão de vendas pode revelar tendências de mercado e contribuir com o planejamento estratégico da empresa, além de auxiliar na solução de problemas de curto prazo (WERNER; RIBEIRO, 2003).

Os modelos estatísticos, por mais sofisticados que sejam, não conseguem considerar toda a gama de fatores que influenciam o comportamento das vendas. As demais informações são consideradas num processo posterior de análise, inclusive a influência da estratégia da empresa na área comercial. Essas variáveis devem ser analisadas de forma sistemática (CORRÊA; GIANESI; CAON, 2001).

Muitas empresas reconhecem a importância da previsão de vendas em todos os níveis e áreas da organização. No nível estratégico, ela é uma informação que auxilia no planejamento a longo prazo. Nas áreas de finanças e contabilidade, a previsão de vendas fornece a base para o planejamento orçamentário e o controle dos custos na empresa. A área da administração da produção a utiliza para a tomada de decisão, envolvendo planejamento de capacidade, nível de estoque de insumos, paradas para manutenção e melhorias de *layout* (DAVIS; AQUILANO; CHASE, 2001).

Embora as previsões de demanda possam fornecer informações aos gestores, permitindo que eles sejam eficazes na execução de suas atividades, é importante reconhecer que as previsões não são perfeitas, pois muitos fatores não podem ser previstos e controlados com segurança. Torna-se fundamental uma revisão periódica das previsões e a busca pelo melhor método de previsão dentro de um custo razoável, ou seja, a relação custo-benefício entre o gasto com o modelo de previsão e a acurácia dos resultados deve ser avaliada (DAVIS; AQUILANO; CHASE, 2001).

A previsão de vendas, quanto ao horizonte, pode ser dividida em (CORRÊA; GIANESI; CAON, 2001):

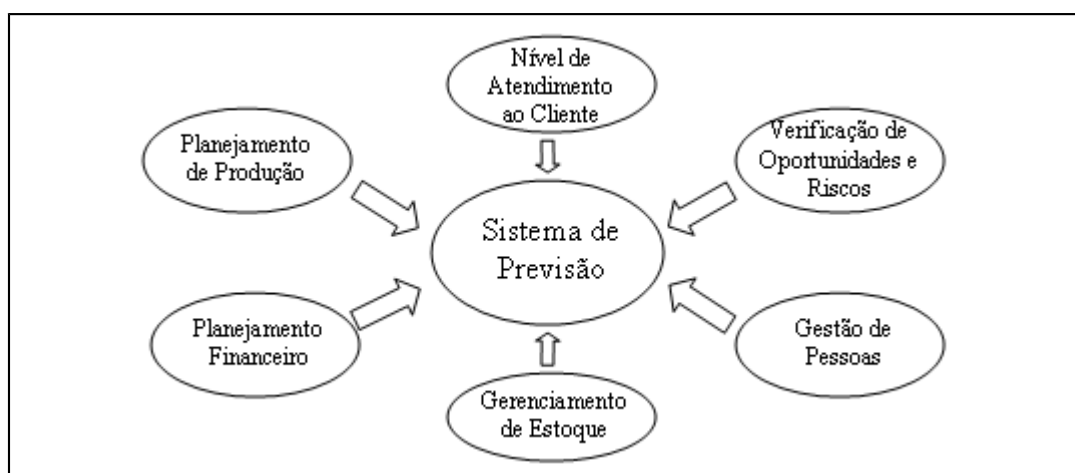
- a) curto prazo: para previsões de até quatro meses aproximadamente, utilizando a hipótese de que o futuro seja uma continuação do passado;
- b) médio prazo: baseia-se na hipótese de que as relações existentes no passado entre as vendas e outras variáveis, continuam a valer no futuro;
- c) longo prazo: ocorre quando o horizonte aumenta vários anos, cuja hipótese é que o futuro não guarda uma relação direta com o passado, pelo menos não uma relação de modelagem matemática, devido, principalmente, aos avanços tecnológicos. A previsão pode ocorrer pela opinião de especialistas ou por modelos econométricos, que descrevem, mediante um conjunto de equações de regressão, as relações de causa-efeito entre as variáveis.

Além de seguir os passos do sistema de previsão de vendas e adotar o modelo de previsão adequado ao horizonte de previsão desejado, existem outros requisitos para alcançar uma boa previsão, dentre os quais destacam-se (CORRÊA; GIANESI; CAON, 2001):

- a) Conhecer os mercados, suas necessidades e comportamentos: é importante segmentar o mercado e agrupar os clientes, segundo suas necessidades e comportamentos, mapeando os clientes de acordo com o segmento de mercado e o tipo de produto consumido;
- b) Conhecer os produtos e seus usos: essas informações ajudam a entender os dados numéricos de vendas, auxiliando na busca das causas dessas variações;
- c) Saber analisar os dados históricos: um dos pontos principais a serem analisados é verificar se os dados de vendas são referentes às quantidades e ao momento em que o cliente gostaria de receber o produto e não às quantidades e datas efetivas de entrega, ou seja, os dados de venda devem refletir a vontade do cliente e não a disponibilidade da empresa em atender ao pedido;
- d) Conhecer a concorrência e seu comportamento: monitorar a concorrência com relação à política de preços, às promoções, aos lançamentos de novos produtos, à prestação de serviço e às demais variáveis que afetam o comportamento dos clientes;
- e) Conhecer as ações da empresa que afetam a demanda: verificar as ações da área comercial da empresa que afetam o comportamento das vendas;

- f) Documentar todas as hipóteses feitas na elaboração da previsão: uma boa previsão deve incluir a revisão, o entendimento e a documentação de hipóteses sobre os diversos aspectos que afetam o comportamento de vendas;
- g) Trabalhar com fatos e não apenas com opiniões: as opiniões, os sentimentos e as intuições são importantes, mas um trabalho mais consistente, baseado também, em fatos, faz parte da elaboração de uma boa previsão;
- h) Articular os diversos setores para elaboração da previsão: o responsável pela previsão de vendas deve coordenar o processo de integração dos diversos setores da empresa, de forma a comprometer cada área ou setor da organização em torno da previsão de vendas.

A Figura 2 demonstra a importância da previsão de vendas para a organização, pois a sua influência ocorre diretamente em todas as áreas da empresa. No marketing, ela contribui para um maior nível de atendimento ao cliente. Na logística, a partir da previsão, é realizada a compra de matérias-primas e materiais. A otimização dos estoques de matérias-primas afeta a área financeira, reduzindo o ativo imobilizado e reduzindo o risco de obsolescência. Na área de produção, com uma estimativa de vendas futuras, é possível reduzir o número de *set-ups* de máquinas, ganhando produtividade e competitividade. A partir de um sistema de previsão, torna-se possível preparar-se para os riscos inerentes à atuação da empresa no mercado, assim como aproveitar as oportunidades que surgem.



F

Figura 2: Relação do sistema de previsão com as áreas da empresa e o mercado.

Fonte: Elaborado pelo autor.

2.4 MÉTODOS DE PREVISÃO

O método de previsão de vendas que uma organização pode adotar depende de vários fatores, entre eles: horizonte de previsão (curto, médio ou longo prazo), disponibilidade de dados históricos, precisão desejada, orçamento disponível e disponibilidade de pessoal qualificado para operacionalizar o modelo (DAVIS; AQUILANO; CHASE, 2001).

Há diversas formas de classificar os métodos e técnicas de previsão, como por exemplo, técnicas subjetivas e objetivas, além de técnicas não causais e causais (SLACK; CHAMBERS; JOHNSTON, 2002). Os diversos métodos de previsão de demanda podem ser classificados em duas categorias principais: os métodos qualitativos e os métodos quantitativos (DAVIS; AQUILANO; CHASE, 2001).

2.4.1 Métodos Qualitativos

Os métodos qualitativos trabalham com opiniões e sentimentos, sendo subjetivos em sua essência. São métodos que se baseiam no julgamento das pessoas que, de forma direta ou indireta, tenham condições de opinar sobre as vendas futuras. São úteis quando da ausência de dados ou no lançamento de novos produtos. As pessoas com conhecimento e experiência no assunto tratado emitem opiniões e julgamentos sobre eventos futuros de interesse da empresa (movimentos do comércio internacional, rumos da tecnologia, tendências de novos produtos, etc.), que afetam a previsão de vendas (MOREIRA, 2004).

Os métodos qualitativos são normalmente utilizados quando os dados históricos são escassos ou inexistentes e o horizonte de previsão é de médio a longo prazo (GEORGOFF; MURDICK, 1986). A utilização de métodos estruturados no processo de previsão subjetiva melhora significativamente a acurácia dos resultados alcançados pelo método utilizado na previsão (ARMSTRONG, 1988). Esses métodos se baseiam em informações, estimativas, opiniões e na intuição. Podem-se citar, como exemplo, os seguintes métodos qualitativos: Método Delphi, Pesquisa de Mercado, Analogia Histórica e Opiniões de Executivos (DAVIS; AQUILANO; CHASE, 2001).

2.4.1.1 Método Delphi

O Método Delphi consiste na reunião de um grupo de pessoas que detém o conhecimento sobre um determinado assunto e que deve opinar a respeito dele, seguindo regras determinadas para a coleta e a avaliação das opiniões. Envolve situações de longo prazo, cujos dados são escassos ou inexistentes, cabendo às pessoas do grupo, geralmente especialistas no assunto a ser tratado, dar opiniões. Geralmente, é organizado um sumário contendo as opiniões e busca-se tabular as opiniões dando enfoque especial àquelas significativamente divergentes. Após, cada pessoa é questionada quanto à manutenção de sua posição inicial. O objetivo é atingir o consenso (MOREIRA, 2004).

O método Delphi tem sido utilizado para prever cenários no futuro, apresentando bons resultados na identificação de pontos de mudança (DAVIS; AQUILANO; CHASE, 2001). Essa técnica é uma das diversas utilizadas para reunir opiniões e previsões de um grupo de especialistas. Em geral, o método utiliza questionários a serem respondidos pelos especialistas, em que as informações do grupo são reunidas, resumidas e apresentadas anonimamente, como *feedback* ao grupo. Cada membro do grupo pode comparar sua previsão com as demais emitidas. Dessa forma, a pessoa pode modificar, ou não, sua primeira previsão. Esse processo é repetido até atingir o consenso (SLACK; CHAMBERS; JOHNSTON, 2002).

O método Delphi parte do pressuposto de que o julgamento coletivo dos especialistas, organizado adequadamente, é mais preciso que a opinião de uma única pessoa, sendo muito importante o critério de seleção das pessoas (WRIGHT; GIOVINAZO, 2000). As características dessa técnica são procedimentos sistemáticos e estruturados, para evitar conflitos no grupo e a comunicação do coordenador do processo com os especialistas, através de *feedback* para o grupo, até alcançar um consenso (PREBLE, 1983). A acurácia do método aumenta à medida que as sucessivas rodadas são realizadas mediante *feedback* aos especialistas, tendo boa precisão em horizontes de médio e longo prazos (DIETZ, 1987; GEORGOFF; MURDICK, 1986).

2.4.1.2 Pesquisa de Mercado

A lógica de buscar a opinião dos consumidores deve-se ao fato de eles determinarem a demanda. O procedimento é, quase sempre, realizado por amostragem para a determinação do

número de consumidores potenciais, sendo esse processo denominado pesquisa de mercado. As pesquisas de mercado requerem conhecimentos especializados e um planejamento bem estruturado para serem confiáveis (MOREIRA, 2004). Em geral, questionários são utilizados para obter os dados e informações sobre o comportamento antecipado do consumidor (MONKS, 1987).

Esse método tem como objetivo avaliar o comportamento dos consumidores de forma a estimar a demanda futura, sustentando o processo de tomada de decisão do gestor (HUTH; EPPRIGHT; TAUBE, 1994). Nessa abordagem, toma-se como base que o consumidor possui a melhor informação sobre a qual se pode basear uma previsão, pois é o seu próprio comportamento que está sendo previsto. É preciso ter cuidado com a forma como são realizadas as perguntas sobre a intenção de compra, para que não exista discrepância entre o que o consumidor gostaria de adquirir e o que ele, de fato, tem condições de adquirir (KOTLER, 1998).

2.4.1.3 Analogia Histórica

Esse método relaciona a previsão de demanda de um produto com a demanda de outro produto similar. É bastante utilizado no planejamento de novos produtos, cuja previsão de demanda do novo produto baseia-se na trajetória de um produto similar existente (DAVIS; AQUILANO; CHASE, 2001). O método de previsão por analogia histórica ocorre pela comparação com um produto idêntico ou similar, introduzido previamente. Apóia-se em dados, mas o caráter de subjetividade permanece, pois a hipótese inicial é que exista comparação do novo produto com um similar lançado anteriormente (MONKS, 1987).

2.4.1.4 Opiniões de Executivos

Em geral, um grupo de altos executivos de diversas áreas da organização se reúne para desenvolver, em conjunto, uma previsão de longo prazo, envolvendo aspectos do planejamento estratégico da empresa. A vantagem dessa técnica é reunir os diversos pontos de

vistas sobre o assunto, podendo gerar uma melhor qualidade e acurácia da tomada de decisão. A desvantagem é que, pela personalidade ou relação de poder estabelecida, possa ocorrer uma influência desproporcional sobre o grupo, distorcendo o resultado (MOREIRA, 2004). Em geral, os gerentes ou diretores das áreas de produção, marketing, logística e finanças preparam uma previsão de demanda conjunta. Nessa técnica, pode ocorrer uma visão pessoal sobre a previsão, causando, em geral, uma baixa objetividade (MONKS, 1987).

2.4.2 Métodos Quantitativos

Os métodos quantitativos são aqueles que utilizam modelos matemáticos, com base na estatística, para análise dos dados, como forma de realizar a previsão, permitindo que diferentes especialistas obtenham previsões idênticas (MOREIRA, 2004). Esses métodos são objetivos e fundamentados, podendo trabalhar com grande volume de dados, mas possuem a desvantagem de não prever mudanças estruturais e dinâmicas dos dados históricos que compõem as séries temporais, o que dificulta suas aplicações (CHAMBERS; MULLICK; SMITH, 1971). Os métodos quantitativos podem ser divididos em dois grandes grupos: séries temporais e métodos causais. Nesta dissertação, em função dos seus objetivos, são abordados os modelos de séries temporais.

2.4.2.1 Séries Temporais

O modelo de séries temporais examina o padrão do comportamento passado de um fenômeno no tempo e utiliza a análise para prever o comportamento futuro desse fenômeno, ou seja, analisa-se o histórico de vendas de um produto, com o objetivo de prever a demanda futura, partindo do pressuposto de que o padrão de comportamento observado no passado forneça informações adequadas para a previsão de valores futuros da demanda. A expressão série temporal indica apenas uma coleção de valores da demanda, tomados em instantes específicos de tempo, normalmente com igual intervalo (MOREIRA, 2004; SLACK; CHAMBERS; JOHNSTON, 2002).

A análise de séries temporais parte do pressuposto de que a tendência que gerou a demanda no passado continuará gerando a demanda no futuro. A análise de séries temporais é geralmente utilizada em situações de curto prazo, pois se ocorrerem alterações no ambiente externo, onde as vendas se realizam, elas irão afetar a precisão da previsão (DAVIS; AQUILANO; CHASE, 2001; FLEURY; WANKE; FIGUEIREDO, 2003).

A previsão de uma série temporal é o estabelecimento dos valores futuros da série, sendo uma previsão estimativa acerca da verossimilhança de eventos futuros, baseados na informação atual e histórica (SOUZA; CAMARGO, 2004).

As séries temporais são um conjunto de observações ordenadas no tempo, baseando-se na idéia de que a história dos acontecimentos, ao longo do tempo, pode ser usada para prever o futuro. Na análise da série temporal, alguns objetivos são básicos: modelagem matemática do fenômeno, com base na estatística, obtenção de conclusões e avaliação do modelo em termos de precisão (MORETTIN; TOLOI, 1987).

Dependendo dos objetivos da análise, vários problemas com as observações podem ocorrer, sendo necessário tomar algumas medidas para evitá-los ou amenizá-los. Dessa forma, um dos primeiros cuidados na análise de uma série temporal é o planejamento amostral e a preparação de dados. Neste sentido o tratamento dos dados deve seguir os seguintes passos (MORETTIN; TOLOI, 1987):

- a) Planejamento: o pesquisador deve determinar o número de observações e o intervalo de amostragem, planejando previamente a obtenção dos dados;
- b) Estacionariedade: uma série temporal é estacionária quando se desenvolve no tempo aleatoriamente ao redor de uma média constante, refletindo uma forma de equilíbrio estável. Na prática, a maior parte das séries apresenta alguma forma de não-estacionariedade (ex: tendências);
- c) Transformação: uma das razões para transformar os dados originais é a presença de não-estacionariedade. A transformação mais comum consiste em tomar diferenças sucessivas da série original, até obter-se uma série estacionária;
- d) Observações Perdidas e Irregulares: mesmo que se tenham observações em instantes de tempos com igual espaçamento, podem-se ter observações perdidas ou irregulares. De acordo com a frequência das mesmas, pode ser usada a interpolação ou técnicas específicas para o caso;

- e) *Outliers*: são os valores aberrantes ou muito diferentes da maioria das outras observações. O importante é identificar as causas de tais observações;
- f) Registros Curtos: quando temos poucas observações, é importante ter cuidado com a conclusão e utilizar técnicas apropriadas para a análise.

É importante salientar que a previsão não constitui um fim em si mesma, mas é apenas uma forma de fornecer informações para uma tomada de decisão mais eficaz, visando atingir determinados objetivos (MORETTIN; TOLOI, 1987).

Os movimentos característicos de uma série temporal podem ser observados em um gráfico em que os valores da demanda são colocados no eixo das ordenadas (vertical) e o tempo no eixo das abscissas (horizontal), permitindo distinguir quatro movimentos característicos ou efeitos de uma série temporal (MOREIRA, 2004):

- a) Tendência (T): esse efeito confere à demanda uma propensão de crescer ou de decrescer com o tempo, sendo identificada como um movimento persistente e a longo prazo em alguma direção (crescente ou decrescente) do gráfico (DAVIS; AQUILANO; CHASE, 2001). Tendências também são conhecidas como movimentos de longo prazo ou seculares, conforme está indicado na Figura 3 pela curva de tendência. Para algumas séries temporais, essa curva pode ser uma reta de tendência (SPIEGEL, 1993). Geralmente, as séries temporais apresentam um movimento suave em função do tempo (MORETTIN; TOLOI, 1987). A Figura 3 mostra a curva de demanda de um produto em função do tempo, caracterizando a tendência de crescimento da demanda com o decorrer do tempo:




Figura 3: Efeito da tendência em séries temporais.

Fonte: Elaborado a partir de Spiegel (1993), p. 427.

- b) Variação Sazonal (S): esse efeito representa o fato de que a demanda dos produtos assume comportamentos semelhantes em épocas bem definidas no ano (MOREIRA, 2004). Refere-se a padrões praticamente idênticos a que uma série temporal parece obedecer durante períodos definidos. Essas variações sazonais também são chamadas de variações estacionais, sendo que a periodicidade relativa pode expressar qualquer intervalo de tempo inferior a um ano, conforme Figura 4 (SPIEGEL, 1993; MORETTIN; TOLOI, 1987):




Figura 4: Efeito da sazonalidade em séries temporais.

Fonte: Elaborado a partir de Spiegel (1993), p. 427.

- c) Componente Cíclica (C): as variações cíclicas referem-se às oscilações a longo prazo, geralmente de vários anos, ou aos desvios em torno da curva de tendência. Esses ciclos podem ou não ser periódicos, isto é, podem ou não seguir exatamente padrões análogos, depois de intervalos de tempos iguais. Nas atividades econômicas, os movimentos são considerados cíclicos quando ocorrem depois de intervalos de tempo superiores a um ano, conforme Figura 5 (SPIEGEL, 1993):




Figura 5: Efeito da componente cíclica em séries temporais.

Fonte: Elaborado a partir de Spiegel (1993), p. 427.

d) Movimentos irregulares (I): são as variações devidas a causas não identificadas, ocorrendo no curto prazo, sendo que essas variações não podem ser previstas pelos modelos de previsão (MOREIRA, 2004). São chamados, também, de movimentos aleatórios ou deslocamentos esporádicos das séries temporais, provocados por eventos casuais como enchentes, greves, etc. (SPIEGEL, 1993). Estatisticamente, quando todas as causas conhecidas para a demanda (média, tendência, sazonalidade e cíclica) são subtraídas da demanda total, o que sobra é uma parte remanescente inexplicável da demanda. Se não for descoberta a causa dessa sobra, ela é considerada puramente aleatória (DAVIS; AQUILANO; CHASE, 2001). Para Morettin e Tolo (1987), essa sobra é a componente aleatória, também conhecida como ruído branco, com média zero e variância constante.

Além desses componentes, existe freqüentemente uma autocorrelação, que indica a persistência de tal ocorrência, ou seja, a demanda esperada em qualquer ponto é altamente correlacionada com seus próprios valores anteriores. Normalmente, as linhas de tendência são o ponto de partida no desenvolvimento de uma previsão. Essas linhas são ajustadas para os efeitos sazonais, cíclicos e a qualquer outro valor que possa influenciar a previsão de demanda (DAVIS; AQUILANO; CHASE, 2001).

A seqüência de estudo de uma série temporal inicia de uma dada realidade (processo estocástico), quando se retira uma amostra finita de observações com igual espaçamento no tempo (série temporal). Pelo estudo dessa amostra (análise de séries temporais), busca-se o melhor modelo estocástico, que tem como objetivo inferir sobre o comportamento dessa realidade analisada, conforme Figura 6. O modelo estocástico é caracterizado por uma família de variáveis aleatórias, sendo um modelo probabilístico (SOUZA; CAMARGO, 2004).




Figura 6: Processo estocástico e série temporal.

Fonte: Elaborado a partir de Souza; Camargo (2004), p. 23.

2.4.2.2 Modelos de Box & Jenkins

Inicialmente são definidas as funções de autocorrelação (ACF) e de autocorrelação parcial (PACF), as quais são necessárias para verificar se uma série temporal é estacionária ou não e, também, para a determinação da ordem dos modelos de Box & Jenkins.

Para séries temporais estacionárias, ambos os coeficientes ACF e PACF tendem a zero, enquanto que as séries não-estacionárias apresentam coeficientes significativamente diferentes de zero para vários períodos de tempo da série temporal (BOX; JENKINS; REINSEL, 1994).

Função de Autocorrelação: A autocorrelação é a autocovariância padronizada. Utiliza-se para medir o comprimento e a memória de um processo, ou seja, a extensão para a qual o valor tomado no tempo t depende daquele tomado no tempo $t \pm k$, ou seja, separado por k intervalos de tempo. A autocorrelação de defasagem k é definida como:

$$\rho_k = \frac{\gamma_k}{\gamma_0} = \frac{\text{Cov}[Y_t, Y_{t+k}]}{\sqrt{\text{Var}(Y_t) \text{Var}(Y_{t+k})}} \quad (1)$$

onde:

$$\text{Var}(Y_t) = \text{Var}(Y_{t+k}) = \gamma_0 = \text{variância do processo}$$

$$\rho_0 = 1 \text{ e } \rho_k = \rho_{-k}.$$

Em outras palavras, a função de autocorrelação é simétrica sobre a origem $k = 0$. O gráfico dos coeficientes de autocorrelação ρ_k versus k , é chamado de correlograma.

Função de Autocorrelação Amostral: Para uma série temporal observada Y_1, Y_2, \dots, Y_n , a autocorrelação amostral é dada por:

$$\hat{\rho}_k = \frac{\hat{\gamma}_k}{\hat{\gamma}_0} = \frac{\sum_{t=1}^{n-k} (Y_t - \bar{Y})(Y_{t+k} - \bar{Y})}{\sum_{t=1}^n (Y_t - \bar{Y})^2}, \quad k = 0, 1, \quad (2)$$

2,

Box & Jenkins (1976) argumentam que, para obter-se uma boa estimativa da função de autocorrelação, precisa-se de pelo menos 50 observações. As autocorrelações, $\hat{\rho}_k$, seriam calculadas para $k=0, 1, \dots, j$, onde j não deve ser maior que $n/4$, sendo n o número de observações.

Função de Autocorrelação Parcial: A idéia de autocorrelação pode ser estendida. Se medirmos a correlação entre duas observações seriais Y_t e Y_{t+k} , eliminando a dependência dos termos intermediários, $Y_{t+1}, Y_{t+2}, \dots, Y_{t+k-1}$, tem-se o que se denomina autocorrelação parcial, que é uma medida de ordem k condicionada ao conhecimento das autocorrelações em todas as defasagens de ordem inferior a k . É definida por Φ_{kk} e dada por:

$$\Phi_{kk} = \frac{|\rho_k^*|}{|\rho_k|} \quad (3)$$

Sendo:

ρ_k : é a matriz de autocorrelação;

$|\rho_k|$: é o determinante da matriz de autocorrelação;

ρ_k^* : é a matriz que difere de ρ_k somente pela última coluna, substituída por $\{\rho_1, \rho_2, \dots, \rho_k\}$

$|\rho_k^*|$: é o determinante da matriz ρ_k^* .

Operadores

Alguns operadores utilizados na metodologia Box & Jenkins são os seguintes:

- O operador translação para o passado “B” representa uma defasagem de k períodos de tempo para trás, sendo definido por:

$$BZ_t = Z_{t-1}$$

$$B^2Z_t = Z_{t-2}$$

⋮

$$B^k Z_t = Z_{t-k} \quad (4)$$

- O operador soma é definido por:

$$SZ_t = \sum_{j=0}^{\infty} Z_{t-j} = Z_t + Z_{t-1} + \dots = (1 + B + B^2 + \dots) Z_t \quad (5)$$

- O operador diferença é uma transformação nos dados, que consiste em tomar diferenças sucessivas da série original, sendo definido por $\nabla^d = (1-B)^d$.

2.4.2.2.1 Modelos univariados de Box & Jenkins sem intervenção

Esse item abordará um resumo sobre a metodologia de Box & Jenkins para modelos univariados sem intervenção.

i) Modelo Geral

O modelo Auto-regressivo-Integrado-Médias Móveis Sazonal, ou denominado SARIMA de ordem $(p,d,q) \times (P,D,Q)_s$ sem intervenção, descrito por Box & Jenkins (1976), tem sido uma ferramenta muito importante na modelagem de dados autocorrelacionados sazonais. O modelo é dado por:

$$\phi(B)\Phi(B^s)(1-B^s)^D Y_t = \theta(B)\Theta(B^s) \quad (6)$$

onde:

$\phi(B) = (1 - \phi_1 B - \dots - \phi_p B^p)$, operador não sazonal auto-regressivo (AR) ou polinômio de ordem p tal que as raízes da equação característica $\phi(B)=0$ devem estar fora do círculo unitário ($\phi(B)$ um polinômio em B de grau p , tenha todas as suas raízes $\phi(B)=0$ maiores que 1, em valores absolutos, ou seja, todas as raízes devem estar fora do círculo unitário) para garantir a estacionariedade e os $\phi_i, i=1,2,\dots, p$ são os parâmetros auto-regressivos não sazonais;

$\nabla^d = (1 - B)^d$, onde ∇^d é o operador diferença não sazonal de ordem d , usualmente $d = 0, 1$ ou 2 ;

B : operador de retardo, tal que, $B^k Z_t = Z_{t-k}$;

$\Phi(B^s) = (1 - \Phi_1 B^s - \dots - \Phi_p B^{ps})$, operador sazonal auto-regressivo (AR) ou polinômio de ordem p , tal que as raízes da equação característica $\Phi(B^s)=0$ devem estar fora do círculo unitário para garantir a estacionariedade e os Φ_i , $i=1,2,\dots, p$ são os parâmetros auto-regressivos sazonais;

$\theta(B) = (1 - \theta_1 B - \dots - \theta_q B^q)$, operador não sazonal médias móveis (MA) ou polinômio de ordem q , tal que as raízes da equação características $\theta(B)=0$ devem estar fora do círculo para garantir a inversibilidade do processo e os θ_i , $i=1,2,\dots, q$ são os parâmetros médias móveis não sazonais;

$\Theta(B) = (1 - \Theta_1 B^s - \dots - \Theta_q B^{qs})$, operador sazonal de médias móveis (MA) ou polinômio de ordem q , tal que as raízes da equação características $\Theta(B^s)=0$ devem estar fora do círculo para garantir a inversibilidade do processo e os Θ_i , $i=1,2,\dots, q$ são os parâmetros médias móveis sazonais;

a_t : processo de ruído branco, normalmente e identicamente distribuído, com média zero e variância constante σ_a^2 ou seja, NID $(0, \sigma_a^2)$;

Y_t : é a série em estudo para o período t ;

(AR): operador não sazonal auto-regressivo que modela a dependência de um valor atual sobre os valores passados;

(I): operador de integração que remove a tendência de uma série temporal, tornando-a estacionária;

(MA): operador não sazonal de média móvel, onde os valores atuais são dependentes de erros de previsão de períodos passados;

p : ordem máxima dos parâmetros auto-regressivos simples;

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

q : ordem máxima dos parâmetros de média móvel simples;

P : ordem máxima dos parâmetros auto-regressivos sazonais;

D : número de diferenciações sazonais aplicadas para tornar uma série temporal estacionária;

Q : ordem máxima dos parâmetros de média móvel sazonal;

s : comprimento sazonal.

ii) Modelo ARIMA(p,d,q)

Os modelos ARIMA (p,d,q) assumem que a série temporal Y_t é uma realização particular de um processo estocástico gerado pela passagem sucessiva de um processo ruído branco a_t a uma seqüência de dois filtros lineares: um estável e outro instável, como apresentado na Figura 7.




Figura 7 - Representação teórica de um modelo ARIMA (p,d,q).

Fonte: Elaborado a partir de Box; Jenkins, 1976.

Quando se tem uma série não estacionária, deve-se, antes de ajustá-la a um modelo estacionário (MA, AR, ARMA), torná-la estacionária pela remoção de padrões não-estacionários (por exemplo, tendência e sazonalidade) da série temporal analisada. Desta forma, a série temporal deve ser transformada para tornar-se estacionária em relação a sua média, obtida através da diferenciação discreta (∇^d : operador de diferença de ordem d), e estacionária em relação à variância, através de transformações logarítmica, raiz quadrada ou exponencial (MAKRIDAKIS; WHELLWRIGHT; HYNDMAN, 1998).

A segunda filtragem é repetida quantas vezes forem necessárias, até que se obtenha, na saída, um processo com as características necessárias para representar o processo não-estacionário homogêneo. Uma condição necessária para aplicação dos modelos ARIMA é de que o processo que gerou a série temporal seja estacionário de segunda ordem, ou seja, que sua média e variância sejam constantes no tempo.

Se $w_t = \nabla^d Y_t$ é estacionária, pode-se representar w_t por um modelo ARMA (p,q), ou seja:

$$\Phi(B) w_t = \Theta(B) a_t \quad (7)$$

Se w_t é uma diferença de Y_t , então Y_t é uma integral (soma) de w_t , daí diz-se que Y_t segue um modelo Auto-Regressivo-Integrado-Médias Móveis, ou modelo ARIMA(p,d,q), assim:

$$\Phi(B) = \nabla^d Z_t = \Theta(B) a_t \text{ de ordem } (p,d,q) \quad (8)$$

iii) Modelo Autoregressivo de ordem p – AR(p)

O modelo AR(p) é definido pela equação (9), representando uma regressão da variável dependente em função dos valores históricos. Essa equação pode ser representada em termos do operador B , através da equação (10), ou de sua forma simplificada na equação (11), descrita a seguir (BOX; JENKINS; REINSEL, 1994):

$$Y_t = \mu + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + \varepsilon_t \quad (9)$$

$$\varepsilon_t = (1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p) Y_t \quad (10)$$

$$\varepsilon_t = \phi(B) Y_t \quad (11)$$

onde:

μ : constante;

ϕ_i : coeficiente auto-regressivo do período i ;

ε_t : erro aleatório do período t ;

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

Fazendo-se $\pi_j = 0, j > p$, no modelo $\pi(B) \tilde{Y}_t = a_t$, obtém-se um modelo chamado de Auto-Regressivo de ordem p , denotado por AR(p), isto é:

$$\tilde{Y}_t = \phi_1 \tilde{Y}_{t-1} + \phi_2 \tilde{Y}_{t-2} + \dots + \phi_p \tilde{Y}_{t-p} + a_t \quad (12)$$

Definindo-se o operador auto-regressivo de ordem p:

$$\phi(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p \quad (13)$$

$$\text{tem-se: } \phi(B) \tilde{Y}_t = a_t \quad (14)$$

Com relação a estacionariedade e invertibilidade dos modelos AR(p), pode-se afirmar que, como $\pi(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p$ é finito, tem-se assegurada invertibilidade. Por outro lado, para $\phi(B)$ convergir, as raízes de $\phi(B) = 0$ devem cair fora do círculo unitário, ou seja, um modelo AR(p) é estacionário se todas as raízes de $\phi(B) = 0$ caírem fora do círculo unitário.

A função de autocorrelação dos modelos AR(p) pode ser obtida através dos seguintes passos:

Multiplicando-se por \tilde{Y}_{t-j} ambos os lados da equação:

$$\tilde{Y}_t = \phi_1 \tilde{Y}_{t-1} + \phi_2 \tilde{Y}_{t-2} + \dots + \phi_p \tilde{Y}_{t-p} + a_t$$

Aplicando-se o valor esperado, obtém-se:

$$E(\tilde{Y}_t \tilde{Y}_{t-j}) = \phi_1 E(\tilde{Y}_{t-1} \tilde{Y}_{t-j}) + \phi_2 E(\tilde{Y}_{t-2} \tilde{Y}_{t-j}) + \dots + \phi_p E(\tilde{Y}_{t-p} \tilde{Y}_{t-j}) + E(a_t \tilde{Y}_{t-j}) \quad (15)$$

Assim:

a) Para $j = 0$, obtém-se:

$$\gamma_0 = \text{Var}(\tilde{Y}_t) = \phi_1 \gamma_1 + \dots + \phi_p \gamma_p + \sigma_a^2 \Rightarrow 1 = \phi_1 \rho_1 + \dots + \phi_p \rho_p + \frac{\sigma_a^2}{\gamma_0}$$

ou seja:

$$\gamma_0 = \frac{\sigma_a^2}{1 - \phi_1 \rho_1 - \dots - \phi_p \rho_p} \quad (16)$$

b) Para $j > 0$, tem-se $E(a_t \tilde{Y}_{t-j}) = 0$, visto que \tilde{Y}_{t-j} só envolve ruídos até a_{t-j} , sendo estes não correlacionados com a_t . Dessa forma:

$$\gamma_j = \phi_1 \gamma_{j-1} + \phi_2 \gamma_{j-2} + \dots + \phi_p \gamma_{j-p}$$

Dividindo-se esta equação por γ_0 , obtém-se:

$$\rho_j = \phi_1 \rho_{j-1} + \phi_2 \rho_{j-2} + \dots + \phi_p \rho_{j-p} \quad (17)$$

sendo que, para $j = 1, 2, \dots, p$, estas equações são denominadas Yule-Walker, que, em forma matricial, escreve-se:

$$\begin{bmatrix} 1 & \rho_1 & \cdots & \rho_{p-1} \\ \rho_1 & 1 & \cdots & \rho_{p-2} \\ \vdots & & & \vdots \\ \rho_{p-1} & \rho_{p-2} & \cdots & 1 \end{bmatrix} \begin{bmatrix} \phi_1 \\ \phi_2 \\ \vdots \\ \phi_p \end{bmatrix} = \begin{bmatrix} \rho_1 \\ \rho_2 \\ \vdots \\ \rho_p \end{bmatrix}$$

Observações:

1. Pode-se estimar $\phi_1, \phi_2, \dots, \phi_p$ do modelo AR(p), através do sistema acima, substituindo ρ_j por sua estimativa r_j .
2. Dado o modelo:

$$\tilde{Y}_t = \phi_1 \tilde{Y}_{t-1} + \phi_2 \tilde{Y}_{t-2} + \dots + \phi_p \tilde{Y}_{t-p} + a_t$$

tem-se:

$$\begin{aligned} Y_t - \mu &= \phi_1(Y_{t-1} - \mu) + \phi_2(Y_{t-2} - \mu) + \dots + \phi_p(Y_{t-p} - \mu) + a_t \\ &= \phi_1 Y_{t-1} - \mu \phi_1 + \phi_2 Y_{t-2} - \mu \phi_2 + \dots + \phi_p Y_{t-p} - \mu \phi_p + a_t \Rightarrow \\ Y_t &= \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + \mu(1 - \phi_1 - \dots - \phi_p) + a_t \end{aligned} \quad (18)$$

iv) Modelo de Média Móvel de ordem q – MA(q)

O modelo de média móvel MA(q) realiza a regressão da variável Y_t com os erros passados (ϵ_{t-q}), conforme as equações (19) e (20), sendo que, esta última, representa a forma polinomial da equação (19) (BOX; JENKINS; REINSEL, 1994)

$$Y_t = \mu - \theta_1 \epsilon_{t-1} - \theta_2 \epsilon_{t-2} - \dots - \theta_q \epsilon_{t-q} + \epsilon_t \quad (19)$$

$$Y_t = \theta(B) \epsilon_t \quad (20)$$

onde:

θ_j : coeficiente de média móvel do período i ;

$\theta(B)$: polinômio de média móvel de ordem q .

Fazendo-se $\Psi_j = 0, \forall j > q$, no modelo:

$$Y_t = \mu + a_t + \Psi_1 a_{t-1} + \Psi_2 a_{t-2} + \dots \quad (21)$$

obtem-se o processo de Médias Móveis de ordem q , denotado por MA(q). Usualmente emprega-se a notação $-\theta_j$, ao invés de Ψ_j , ou seja, $\Psi_1 = -\theta_1, \Psi_2 = -\theta_2, \dots, \Psi_q = -\theta_q$ e $\Psi_k = 0$, se $k > q$. Assim, um MA(q) tem a forma:

$$Y_t = \mu + a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q} \quad (22)$$

ou seja:

$$\tilde{Y}_t = (1 - \theta_1 B - \dots - \theta_q B^q) a_t = \theta(B) a_t \quad (23)$$

sendo:

$$\theta(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q \quad (24)$$

o operador de médias móveis, de ordem q .

Por exemplo: Sendo $\tilde{Y}_t = a_t - \theta a_{t-1}$, pode-se escrever $\tilde{Y}_t = (1 - \theta B) a_t$, de modo que $\theta(B) = 1 - \theta B$. Assim, como $\Psi(B) = \theta(B)$ é finito, esse processo é estacionário. Nesse caso, temos também:

$$a_t = (\theta(B))^{-1} \tilde{Y}_t = (1 - \theta B)^{-1} \tilde{Y}_t = (1 + \theta B + \theta^2 B^2 + \dots) \tilde{Y}_t = \pi(B) \tilde{Y}_t \quad (25)$$

ou seja, $\pi(B)$ converge, se $|\theta| < 1$, significando dizer que a raiz de $\theta(B) = 1 - \theta B = 0$ fica fora do círculo unitário.

Com relação à estacionariedade e à invertibilidade do modelo, dado que $\Psi(B) = \theta(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q$, não há restrições sobre os parâmetros θ_j para que o processo seja estacionário. Por outro lado, pode-se verificar que a condição de invertibilidade para um MA(q) é que as raízes de $\theta(B)=0$ caiam fora do círculo unitário.

A função de autocorrelação do modelo pode ser expressa por:

$$\tilde{Y}_t = a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q} \quad (26)$$

Onde pode-se ter:

$$\gamma_j = E(\tilde{Y}_t \tilde{Y}_{t-j}) = E\left\{\left[a_t - \sum_{k=1}^q \theta_k a_{t-k}\right]\left[a_{t-j} - \sum_{l=1}^q \theta_l a_{t-j-l}\right]\right\}$$

(27)

ou seja:

$$\gamma_j = E(a_t a_{t-j}) - \sum_{k=1}^q \theta_k E(a_{t-j} a_{t-k}) - \sum_{l=1}^q \theta_l E(a_t a_{t-j-l}) + \sum_{k=1}^q \sum_{l=1}^q \theta_k \theta_l E(a_{t-k} a_{t-j-l})$$

(28)

Sabendo-se que:

$$E(a_t a_{t-j}) = \begin{cases} \sigma_a^2, & \text{se } j = 0 \\ 0, & \text{se } j \neq 0 \end{cases}$$

Assim:

$$\gamma_0 = \text{Var}(\tilde{Y}_t) = (1 + \theta_1^2 + \dots + \theta_q^2) \sigma_a^2$$

(29)

Fazendo $E(a_t a_{t-j}) = \gamma_a(j)$, para $j \neq 0$, tem-se:

$$\begin{aligned} \gamma_j &= \gamma_a(j) - \sum_{k=1}^q \theta_k \gamma_a(k-j) - \sum_{l=1}^q \theta_l \gamma_a(j+l) + \sum_{k=1}^q \sum_{l=1}^q \theta_k \theta_l \gamma_a(j+l-k) = (-\theta_j + \sum_{k=j+1}^q \theta_k \theta_{k-j}) \sigma_a^2 \\ &= (-\theta_j + \sum_{s=1}^{q-j} \theta_s \theta_{j+s}) \sigma_a^2 \Rightarrow \begin{cases} (-\theta_j + \theta_1 \theta_{j+1} + \theta_2 \theta_{j+2} + \dots + \theta_{q-j} \theta_q) \sigma_a^2, & 1 \leq j \leq q \\ 0, & \text{se } j > q \end{cases} \end{aligned}$$

Dividindo γ_j por γ_0 , obtém-se:

$$\rho_j = \begin{cases} \frac{-\theta_j + \theta_1 \theta_{j+1} + \theta_2 \theta_{j+2} + \dots + \theta_{q-j} \theta_q}{1 + \theta_1^2 + \dots + \theta_q^2}, & 1 \leq j \leq q \\ 0, & \text{se } j > q \end{cases}$$

(30)

v) Modelos Mistos Autoregressivos-Média Móvel – ARMA(p,q)

Os processos auto-regressivos e de Média Móvel ARMA(p,q) combinam as características de processos AR(p) e MA(q). Qualquer série estacionária pode ser modelada como um processo ARMA(p,q). O modelo é apresentado nas equações (31) e (32) (BOX; JENKINS; REINSEL, 1994):

$$Y_t = \mu + \phi_1 Y_{t-1} + \dots + \phi_p Y_{t-p} + e_t - \theta_1 e_{t-1} - \dots - \theta_q e_{t-q} \quad (31)$$

$$\phi(B) Y_t = \mu + \theta(B) e_t \quad (32)$$

Os modelos ARMA(p, q) contêm termos auto-regressivos e de médias móveis, sendo, portanto, dados por:

$$\tilde{Y}_t = \Phi_1 \tilde{Y}_{t-1} + \dots + \Phi_p \tilde{Y}_{t-p} + a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q} \quad (33)$$

onde, considerando-se $\phi(B)$ e $\theta(B)$ como os operadores auto-regressivos e de médias móveis, respectivamente, pode-se escrever um ARMA(p, q) na forma:

$$\phi(B) \tilde{Y}_t = \theta(B) a_t \quad (34)$$

O Quadro 1 apresenta as principais características teóricas das FAC's e FACP's dos modelos estacionários e não sazonais AR, MA e ARMA.


Quadro 1- Características das FAC's e FACP's dos modelos AR, MA e ARMA.

Processo	FAC	FACP
AR	Decai para zero (exponencialmente ou através de senóides amortecidas)	É zero depois do <i>lag p</i>
MA	É zero depois do <i>lag q</i>	Decai para zero (exponencialmente ou através de senóides amortecidas)
ARMA	Decai para zero	Decai para zero

Fonte: Adaptado de Box; Jenkins; Reinsel (1994).

Nas Figuras 8 e 9, apresentam-se os correlogramas que ilustram a identificação de alguns modelos particulares. Pode-se notar semelhanças nas FAC's dos dois primeiros casos ("a" e "b") do modelo AR(2), apresentado na Figura 9, com as FAC's dos dois casos do AR(1), disposto na Figura 8. Em geral, não se pode determinar, a partir da FAC estimada, se ocorre um modelo AR(1) ou um AR(2). Nestes casos, a FACP é quem define a ordem do processo, visto que no AR(1), apresentado na Figura 8, a FACP tem um único pico.

1. Processo AR(1), com $\phi_1 > 0$.



2. Processo AR(1), com $\phi_1 < 0$.





Figura 8: Gráficos do modelo AR (1).


Fonte: Adaptado de Box; Jenkins; Reinsel (1994).

A seguir, tem-se as FAC's e FACP's de quatro tipos de AR(2):


a) $\phi_1 > 0$ e $\phi_2 > 0$



b) $|\phi_1| < 0$ e $\phi_2 > 0$



c) $|\phi_1| > 0$ e $\phi_2 < 0$



d) $|\phi_1| < 0$ e $\phi_2 < 0$




Figura 9: Gráficos do modelo AR (2).

Fonte: Adaptado de Box; Jenkins; Reinsel (1994).

No Quadro 2, resumem-se as características dos processos MA(1) e MA(2).

Quadro 2- Características dos processos MA(1) e MA(2).

Processo	FAC	FACP
MA(1)	Tem pico somente no <i>lag</i> 1, sendo esse positivo, se $\theta_1 < 0$, ou negativo, se $\theta_1 > 0$	Decai exponencialmente: a. Partindo do lado positivo e alternando o sinal, se $\theta_1 < 0$; b. Do lado negativo, se $\theta_1 > 0$.
MA(2)	Tem picos somente nos <i>lags</i> 1 e 2	Uma mistura de exponencial e senóide amortecida. O padrão exato depende dos sinais e dos valores de θ_1 e θ_2

Fonte: Adaptado de Box; Jenkins; Reinsel (1994).

Na Figura 10, os gráficos ilustram a identificação do modelo MA(1):




Figura 10: Gráficos do modelo MA (1).

Fonte: Adaptado de Box; Jenkins; Reinsel (1994).

Na Figura 11, tem-se as FAC's e FACP's de quatro tipos de MA(2):




Figura 11: Gráficos do modelo MA (2).

Fonte: Adaptado de Box; Jenkins; Reinsel (1994).

Tem-se a seguir, as principais características do processo ARMA(1, 1):

a) FAC – Decai exponencialmente após o *lag* 1:

- (1) o sinal de ρ_1 é igual ao sinal de $(\phi_1 - \theta_1)$;
- (2) todos têm o mesmo sinal, se $\phi_1 > 0$;
- (3) os sinais são alternados, se $\phi_1 < 0$.

b) FACP – Decai exponencialmente após o *lag* 1:

- (1) $\phi_{11} = \rho_1$;
- (2) todos têm o mesmo sinal, se $\theta_1 > 0$;
- (3) os sinais são alternados, se $\theta_1 < 0$.

Na Figura 12, tem-se as ilustrações gráficas:




Figura 12: Gráficos do modelo ARMA (1,1).

Fonte: Adaptado de Box; Jenkins; Reinsel (1994).




Figura 12: Gráficos do modelo ARMA (1,1).

Fonte: Adaptado de Box; Jenkins; Reinsel (1994).

2.4.2.2.2 Modelos univariados de Box & Jenkins com intervenção

O objetivo da análise de intervenção consiste em avaliar o impacto de um ou mais choques exógenos no comportamento de uma determinada série temporal (*output*). Os modelos de intervenção, desenvolvidos por Box e Tiao (1975), são um caso particular dos modelos de função transferência de Box e Jenkins (1970), nos quais as variáveis *input* são acontecimentos exógenos e de natureza determinística que são denominadas de intervenções quando o momento de ocorrência é conhecido a priori. São exemplos de intervenções: greves, alterações legislativas, crises econômicas, decisões políticas, perturbações climáticas, campanhas de publicidade e promoção, etc.

Segundo Box e Jenkins (1970), os modelos de intervenção representam generalizações de métodos usados para a análise de dados, usualmente não expressos na forma de séries temporais, aos quais os estatísticos referem-se pelo título geral de Delineamento e Análise de Experimentos. Apesar do modelo parecer simples, ele descreve um grande número de efeitos simultâneos.

O modelo proposto para a análise de intervenção é dado pela seguinte equação:

$$Y_t = \sum_{i=1}^k v_i(B)I_{j,t} + \eta_t \quad (35)$$

onde:

Y_t : variável-resposta do modelo;

k : número de intervenções da série;

$v_i(B)$: valor da função e transferência;

$I_{j,t}$: variável binária;

η_t : ruído do modelo, representado por um modelo ARIMA.

Na utilização dos modelos de Box & Jenkins, é necessário que a série seja estacionária, ou seja, não apresente tendência e sazonalidade. Assim, o modelo (35), pode ser expresso pela equação (36) por meio de um modelo ARMA(p,q) com intervenção (BOX; TIAO, 1975).

$$\hat{Y}_t = \sum_{j=1}^k \frac{\varpi_j(B)B^{bj}}{\delta_j(B)} I_{jt} + \frac{\theta(B)}{\phi(B)} a_t \quad (36)$$

onde:

\hat{Y}_t : variável estimada pelo modelo no período t ;

$\phi(B) = (1 - \phi_1 B - \dots - \phi_p B^p)$: polinômio autoregressivo não sazonal de ordem p ;

$\theta(B) = (1 - \theta_1 B - \dots - \theta_q B^q)$: polinômio de médias móveis não sazonal de ordem q ;

a_t : é uma seqüência de ruído branco que segue uma $N(0, \sigma_a^2)$;

I_{jt} : representa as variáveis de intervenção para $j= 1, \dots, k$; para a observação (t) onde ocorreu a intervenção.

$$\varpi_j(B) = (\varpi_0 - \varpi_1 B - \dots - \varpi_s B^s);$$

(37)

$$\delta_j(B) = (\delta_0 - \delta_1 B - \dots - \delta_r B^r).$$

(38)

Os ϖ_i 's representam os efeitos iniciais da intervenção e δ_i 's representam os efeitos permanentes da intervenção.

Uma intervenção pode mudar abruptamente o nível da série (para cima ou para baixo) a partir de um determinado momento ou após um curto período de tempo, podendo os seus efeitos serem permanentes ou apenas temporários. Para caracterizar e quantificar a natureza e a magnitude desses efeitos, podem-se distinguir os seguintes tipos de variáveis de intervenção:

i) Função *step* ou “degrau”: representa uma intervenção que ocorre a partir do instante $t=T$ e que permanece atuando na série.

$$S_t^T = \begin{cases} 0, & t < T \\ 1, & t \geq T \end{cases} \quad (39)$$

ii) Função impulso: correspondente a uma intervenção que ocorre no momento $t=T$ e que tem efeito apenas nesse instante,

$$P_t^T : \begin{cases} 0, t \neq T \\ 1, t = T \end{cases} \quad (40)$$

iii) Variável impulso sazonal: correspondente a uma intervenção que ocorre no momento $t=s$ e que tem efeito nos instantes s e seus múltiplos, $2s, 3s, \dots$

$$P_t^s : \begin{cases} 0, t \neq s \\ 1, t = s \end{cases} \quad (41)$$

Identificação de *outliers*

Quando as datas de ocorrência dos fenômenos que influenciam o comportamento da série não são conhecidas *a priori*, os *inputs* tomam o nome de *outliers*. A detecção de *outliers* em séries temporais foi inicialmente introduzida por Fox (1972), ao propor dois modelos paramétricos: *Additive Outlier* e *Innovation Outlier*.

Em desenvolvimentos mais recentes, incluindo autores como Tsay (1986,1988), Chang; Tiao; Chen (1988) e Ljung (1993), propõem métodos iterativos para a identificação de diferentes tipos de *outliers* e alguns procedimentos para a especificação dos respectivos modelos.

Os efeitos das intervenções em momentos desconhecidos podem causar distorções nas autocorrelações e nas autocorrelações parciais e dessa forma enviesar os parâmetros do modelo ARMA.

Nesse sentido, é importante que se identifique esses fenômenos exógenos (*outliers*) e se removam os seus efeitos das observações, para melhor compreender a estrutura da série em estudo.

Existem essencialmente quatro modelos paramétricos para a identificação de *outliers* que podem ser caracterizados segundo os efeitos que produzem na série *output*. São eles:

- **Additive Outlier** : representa uma variável do tipo “impulso”, cujo efeito apenas ocorre em $t = T$, sendo nulo o efeito nos restantes momentos. É definido através do modelo:

$$Y_t = X_t + \omega I_t^{(T)} = \frac{\theta_q(B)}{\phi_p(B)} a_t + \omega I_t^{(T)} \quad (42)$$

onde X_t representa a série sem a presença de *outliers*, que segue um processo ARMA(p,q) invertível e estacionário: $\phi_p(B)Z_t = \theta_q(B)a_t$ e $I_t^{(T)}$ é uma variável binária que indica a presença ou ausência de um *outlier* no momento T , através da relação: $I_t^{(T)} = 1$ se $t = T$ e $I_t^{(T)} = 0$ se $t \neq T$.

- **Innovation Outlier** : traduz-se num choque na série residual, cujo efeito se faz sentir em todas as observações a partir do momento t ($Y_t, Y_{t+1}, Y_{t+2}, \dots$) segundo a estrutura do sistema descrito por $\theta_q(B)/\phi_p(B)$. Pode descrever-se através da relação,

$$Y_t = \frac{\theta_q(B)}{\phi_p(B)} (a_t + \omega I_t^{(T)}) = X_t + \frac{\theta_q(B)}{\phi_p(B)} \omega I_t^{(T)} \quad (43)$$

- **Level Step**: corresponde a uma variável do tipo “degrau”, cujo efeito ocorre em $t = T$ e mantém-se atuando depois desse momento. Define-se através da expressão:

$$Y_t = X_t + \frac{\omega}{1-B} I_t^{(T)} = \frac{\theta_q(B)}{\phi_p(B)} a_t + \frac{\omega}{1-B} I_t^{(T)} \quad (44)$$

- **Transient Change**: refere-se a um choque na série para $t \geq T$, cujo efeito tende a diminuir a um ritmo exponencial após um impacto inicial. Este *outlier* é definido através do modelo:

$$Y_t = X_t + \frac{\omega}{1-B} I_t^{(T)} = \frac{\theta_q(B)}{\phi_p(B)} a_t + \frac{\omega}{1-\delta B} I_t^{(T)} \quad (45)$$

onde $0 < \delta < 1$. Generalizando, uma série com k *outliers* de diferentes tipos pode ser representada pela seguinte relação:

$$Y_t = X_t + \sum \omega_i v_i(B) I_t^{(T)} \quad (46)$$

onde $X_t = \theta_q(B)/\phi_p(B)a_t$; $v_i(B) = 1$ para um *additive outlier*, $v_i(B) = \theta_q(B)/\phi_p(B)$ para um *innovation outlier*, $v_i(B) = 1/(1-B)$ para um *level step* e $v_i(B) = 1/(1-\delta B)$ para um *transient change*; e $I_t^{(T_i)} = 1$ se $t=T_i$ e $I_t^{(T_i)} = 0$ se $t \neq T_i$.

A identificação de *outliers* (essencialmente de dois tipos, *Additive Outlier* e *Level Step*) pode ser feita automaticamente pelo *package* AUTOBOX (o AUTOBOX apenas faz a detecção de no máximo cinco *outliers*), que começa construindo um modelo ARIMA para a série original do *output* Y_t , supondo que não existe nenhum *outlier*, seguindo-se um processo iterativo de regressão dos resíduos obtidos sobre potenciais *outliers*, até conseguir-se, avaliando os efeitos dos seus choques, encontrar “todos” os *Additive Outlier* e *Level Step*. Uma vez encontrados, os *outliers* (cujos momentos de ocorrência passam a ser conhecidos) são incluídos como variáveis de intervenção (“Impulso” e “Degrau”) nos modelos de intervenção introduzidos por Box e Tiao (1975), procedendo-se à identificação da função transferência ou da resposta do *output* às intervenções e de um modelo ARIMA para a série residual com coeficientes estatisticamente significativos. Uma vez especificada a forma do modelo, passa-se às etapas habituais de estimação e avaliação das qualidades estatística e do ajustamento.

2.4.2.2.3 Etapas para a construção de um modelo de previsão

As etapas para a construção de um modelo de previsão, baseado na metodologia de Box & Jenkins, são apresentadas a seguir (BOX; JENKINS, 1976):

i) *Identificação do modelo*: abrange a análise e a preparação dos dados que compõem a série temporal e a seleção do modelo SARIMA, ou seja, consiste em descobrir qual, dentre as várias versões dos modelos Box & Jenkins, melhor descreve o comportamento da série.

Para a construção dos modelos SARIMA, é necessário identificar a ordem dos parâmetros $(p,d,q) \times (P,D,Q)$. O primeiro parâmetro a ser identificado é o grau de diferenciação, d ou D , necessário à estabilização dos dados. Isso é feito pela análise do comportamento do correlograma, ou seja, do diagrama da função de autocorrelação (FAC), no qual são apresentados os valores das autocorrelações em relação aos *lags* k . Se as autocorrelações decrescerem de forma linear, realizam-se diferenciações na série, até que o diagrama apresente um corte abrupto para um valor qualquer de autocorrelação, quando a série será considerada estacionária.

A ordem auto-regressiva p ou P (sazonal) é determinada pela verificação da função de autocorrelação parcial (FACP), ϕ_{kk} , da série que está sendo analisada. A ordem médias móveis q ou Q (sazonal) é determinada pela verificação da função de autocorrelação (FAC) da série que está sendo analisada.

A partir de 1970 foram propostos procedimentos para a identificação do modelo que melhor descreve o comportamento da série, dentre os quais se podem citar: o Critério de Informação de Akaike (AIC) (AKAIKE, 1973, 1974) e o Critério Bayesiano (BIC) (AKAIKE, 1977). Esses critérios visam identificar a ordem do modelo SARIMA a ser utilizado, minimizando uma função que penaliza o ajuste de modelos não parcimoniosos, ou seja, que possuem uma grande quantidade de parâmetros.

O Critério de Informação de Akaike (AIC) para o processo ARIMA (Ozaki, 1977) é dado por:

$$AIC(p, d, q) = N \ln(\hat{\sigma}_a^2) + \frac{N}{N-d} 2(p+q+1+\delta_0) + N \ln(2\pi) \quad (47)$$

onde:

$$\delta_0 = \begin{cases} 1, d = 0 \\ 0, d \neq 0 \end{cases}$$

N : número de observações da série em estudo;

$\hat{\sigma}_a^2$: variância estimada dos resíduos;

p, q : graus dos polinômios $\phi(B)$ e $\theta(B)$;

d : número de diferenças utilizadas para estacionarizar a série.

O Critério de SCHWARZ, também conhecido como BIC (Bayesian Information Criterion), é dado pela seguinte expressão:

$$BIC(p, d, q) = N \ln(\hat{\sigma}_a^2) + (p+q) \frac{\ln(N)k}{N} \quad (48)$$

onde:

k : número de parâmetros.

Estes dois critérios são equivalentes e medem as verossimilhanças dos modelos mais a parcimônia paramétrica. São baseados nas previsões dentro da amostra. O modelo selecionado deve ser o que apresentar o menor AIC ou BIC, já que quanto mais próximo de zero for o valor calculado, melhor será o ajuste e maior a parcimônia (HAIR; ANDERSON; TAHTAM: BLACK, 2005).

ii) *Estimação dos parâmetros*: essa fase compreende a estimação de parâmetros dos modelos potenciais. Essa etapa da metodologia consiste em estimar os parâmetros de cada um dos modelos Autoregressivos (Φ), de médias móveis (Θ) e a variância dos erros. Posteriormente, verifica-se a aleatoriedade dos resíduos. Esta estimação é realizada através do método de máxima verossimilhança. Desta forma, deve-se identificar o melhor modelo e, após, estimar os parâmetros.

Para testar se um parâmetro é zero ou não, pode-se usar a estatística t de *student*, ou seja:

$$t = \frac{\text{Estimativa do parâmetro}}{\text{Estimativa do desvio padrão desse parâmetro}} \quad (49)$$

sendo que, como regra prática, rejeita-se a hipótese de que o parâmetro é zero quando o valor absoluto dessa estatística é maior que 1,96.

iii) *Verificação da adequação do modelo*: essa etapa consiste em avaliar o ajuste do modelo por meio do comportamento da função de autocorrelação residual.

Na etapa de verificação do modelo, calculam-se as autocorrelações dos resíduos $\hat{\rho}_k(\mathbf{a})$, dadas por:

$$\hat{\rho}_k(\mathbf{a}) = \frac{\sum_{t=1}^{n-k} (a_t - \bar{a})(a_{t+k} - \bar{a})}{\sum_{t=1}^n (a_t - \bar{a})^2} \quad (50)$$

No teste t , para testar a hipótese $H_0: \rho_k(\mathbf{a}) = 0$, para cada autocorrelação residual, tem-se que a estatística do teste é:

$$t = \frac{\hat{\rho}_k(\mathbf{a})}{s[\hat{\rho}_k(\mathbf{a})]} \quad (51)$$

sendo $s(\hat{\rho}_k)$ um estimador do desvio padrão de $s(\rho_k)$, que é dado por:

$$s(\hat{\rho}_k) = n^{-1/2} [1 + 2 \sum_{j=1}^{k-1} \hat{\rho}_j^2]^{1/2} \quad (52)$$

onde:

n : número de elementos da série de resíduos.

Os limites de confiança para o desvio padrão das autocorrelações dos resíduos são dados por:

$$LC(\hat{\rho}_k(a)) = n^{-1/2} [1 + 2 \sum_{j=1}^{k-1} \hat{\rho}_j^2]^{1/2} . (\pm) \quad (53)$$

Na prática, se $|t| < 1,25$, nos *lags* 1, 2 e 3 e $|t| < 1,6$ nos demais *lags*, conclui-se que os erros são não correlacionados. Caso contrário, rejeita-se H_0 , ou seja, conclui-se que os erros são correlacionados.

No teste de Portmanteau, proposto por Box & Jenkins (1970), modificado para o teste Q , seguindo uma distribuição de χ^2 (Qui-quadrado), tem-se:

$$H_0: \rho_1(a) = \rho_2(a) = \dots = \rho_v(a) = 0$$

A estatística do teste é:

$$Q^* = N(N+2) \sum_{k=1}^v (N-k)^{-1} \rho_k^2(a) \quad (54)$$

sendo N o número de observações usadas para estimar o modelo e v o número de autocorrelações. A distribuição de Q^* é aproximadamente qui-quadrado com $(v-m)$ graus de liberdade, sendo m o número de parâmetros estimados no modelo SARIMA. Pode-se testar a validade do modelo, dentro de um nível de significância, comparando o valor de Q^* com o valor tabelado da distribuição Qui-quadrado.

iv) *Previsão*: é a etapa da extrapolação dos dados históricos através do modelo encontrado. Existem várias medidas de avaliação. Uma medida de avaliação muito usada é o MAPE (Mean Absolute Percent Error), também conhecido como erro médio percentual absoluto.

Esta estatística indica o erro percentual absoluto médio das previsões sobre todo o conjunto de teste, sendo expressa pela seguinte equação:

$$MAPE = \frac{\sum_{t=1}^n \left| \frac{Y_t - \hat{Y}_t}{Y_t} \right|}{n} \quad (55)$$

onde:

Y_t : valor atual da série;

\hat{Y}_t : valor previsto;

n : número de observações utilizadas para cálculo do MAPE.

Esta última fase de execução do modelo de Box & Jenkins é utilizada para verificar se o modelo é adequado para a previsão de observações futuras. É importante avaliar se o modelo estimado é adequado para descrever o comportamento dos dados. Caso o modelo não seja adequado, o ciclo é repetido, voltando-se para a fase de identificação. Na figura 13, apresenta-se o fluxograma do ciclo iterativo de Box & Jenkins.

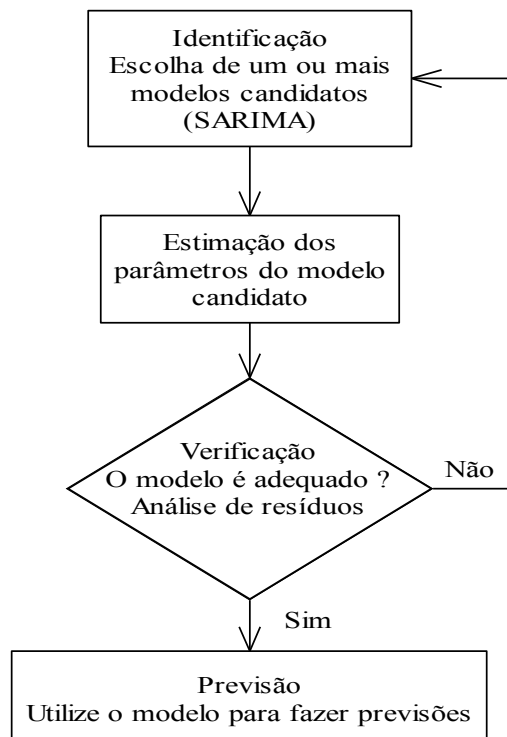


Figura 13 – Fluxograma do ciclo iterativo de Box & Jenkins.

Fonte: Adaptado de Box; Jenkins (1970).

Nessa dissertação, dentre os vários modelos de séries temporais, escolheu-se trabalhar com os modelos de Box & Jenkins, porque, quando comparados com os demais métodos de previsão, a metodologia Box & Jenkins apresenta resultados mais precisos e os modelos apresentam um menor número de parâmetros (MORETTIN; TOLOI, 1997).

2.4.3 Combinação de Métodos de Previsão – Modelo Combinado

O artigo de Bates e Granger (1969) é considerado o marco inicial para a extensa produção sobre métodos combinados de previsões, cujo princípio refere-se à possibilidade de aumentar a precisão das previsões, beneficiando-se da complementaridade da informação contida em cada previsão individual. Esse trabalho decorre da proposição de que a variância esperada dos erros de previsão combinada é inferior à menor das variâncias individuais, e requer que as previsões sejam não-viesadas e não apresentem elevada correlação. Outro aspecto relevante a ser observado é que a interação entre a variância e a correlação dos erros das previsões individuais é determinante para a performance da combinação.

Essa formulação foi proposta por Granger (1980) através da combinação linear de previsões pontuais calculadas por meio de modelos com características distintas. Esta metodologia é baseada no seguinte argumento científico: se duas previsões pontuais, as melhores em termos de uma medida de eficiência (Erro Médio Percentual Absoluto ou Erro Médio Quadrático), obtidas em modelos com metodologias distintas, então, se as previsões são combinadas linearmente, o resultado da previsão final será sempre melhor que as previsões não combinadas ou individualizadas.

A combinação de métodos de previsão de demanda é muito utilizada no sentido de melhorar a acurácia da previsão (CHEN; KUNG, 1984; BOPP, 1985 apud LEMOS, 2006).

No caso particular dos dois modelos, que serão utilizados neste trabalho de pesquisa, produzindo previsões pontuais $\hat{Y}_{t+1}^{(1)}$ e $\hat{Y}_{t+1}^{(2)}$ respectivamente, a um passo à frente, a previsão combinada \hat{Y}_{t+1}^c é obtida pela seguinte combinação linear:

$$\hat{Y}_{t+1}^c = \alpha \hat{Y}_{t+1}^{(1)} + (1 - \alpha) \hat{Y}_{t+1}^{(2)} \quad (56)$$

Aqui α é o peso, sendo que o seu cálculo é feito de modo a minimizar a variância do erro de previsão combinada. Bates e Granger (1969) mostram que os pesos obtidos são inversamente proporcionais às variâncias das previsões individuais.

A variância da previsão combinada, para o caso em que os erros estão correlacionados é dada por:

$$\sigma_c^2 = \alpha^2 \sigma_1^2 + (1 - \alpha)^2 \sigma_2^2 + 2\rho \alpha (1 - \alpha) \sigma_1 \sigma_2 \quad (57)$$

onde: σ_1^2 e σ_2^2 são as variâncias dos erros das previsões a serem combinadas; ρ é o coeficiente de correlação entre os erros das previsões; α é o peso dado à previsão 1, um passo à frente.

Para minimizar a variância σ_c^2 faz-se a diferenciação da equação (57) com relação a α e iguala-se o resultado a zero. Assim, o valor mínimo de σ_c^2 ocorre quando α assume o valor dado pela equação (58).

$$\alpha = \frac{\sigma_2^2 - \rho \sigma_1 \sigma_2}{\sigma_1^2 + \sigma_2^2 - 2\rho \sigma_1 \sigma_2} \quad (58)$$

Quando os erros das previsões não estão correlacionados, ou seja, $\rho = 0$, α fica reduzido ao valor dado pela seguinte equação.

$$\alpha = \frac{\sigma_2^2}{\sigma_1^2 + \sigma_2^2} \quad (59)$$

2.4.4 Modelo Integrado

A partir do modelo combinado, procede-se ao ajuste das previsões de acordo com o julgamento fornecido pelos responsáveis pela realização das previsões de vendas na empresa, encontrando-se o modelo integrado. Os procedimentos a seguir estão baseados em Werner e Ribeiro (2006), onde o ajuste ao modelo combinado deve seguir as etapas descritas a seguir:

1- Estabelecer o percentual máximo e mínimo de ajuste

Os responsáveis pela previsão da empresa estabelecem um percentual máximo e um percentual mínimo por meio dos quais a previsão pode ser ajustada, considerando o contexto global da empresa e a sua inserção no mercado. O ajuste será realizado tomando-se por base o percentual médio obtido entre o número de especialistas existentes na empresa.

2- Organizar a listagem dos fatores

Os especialistas, que estão envolvidos no processo de previsão, devem fornecer os fatores que podem influenciar o comportamento da demanda. Com os fatores indicados pelos responsáveis pela realização das previsões, elabora-se uma lista única de fatores considerados importantes na definição da previsão futura. Essa lista é formada a partir das prioridades atribuídas pelos próprios responsáveis.

3- Mensurar o impacto de cada um dos fatores

Identificados os fatores, os responsáveis pela previsão de vendas atribuem pesos para cada um dos fatores, visando identificar a sua possível influência sobre a demanda futura (pequena, média ou grande). A escala aqui sugerida é baseada na escala de Likert (Malhotra, 2007), que segue os mesmos princípios da escala utilizada por Saaty (1991) e por Werner e Ribeiro (2006). Assim, a escala ficou com a seguinte pontuação:

- grau 1: se a importância do fator i for muito fraca;
- grau 2: se a importância do fator i for fraca;
- grau 3: se a importância do fator i for moderada;
- grau 4: se a importância do fator i for forte;
- grau 5: se a importância do fator i muito forte;

4- Encontrar os pesos normalizados

Os pesos normalizados são encontrados pela equação (60):

$$PN = \frac{P_i}{\sum P_i} * 100$$

(60)

onde:

PN: é o peso normalizado de cada fator de influência na demanda;

Pi: é o peso atribuído a cada fator de influência na demanda por cada um dos responsáveis pela previsão de vendas na empresa;

$\sum P_i$: é a soma dos pesos de cada fator de influência para cada responsável pela previsão.

5- Mensurar a opinião dos responsáveis pela previsão de vendas da empresa em função da intensidade do impacto do fator

Neste caso será atribuída uma pontuação entre -1 e +1 para a intensidade do impacto de cada fator para o próximo período. Será atribuído o valor -1 se a intensidade do impacto for altamente negativa, +1 se for altamente positiva e zero se for uma intensidade igual (ou seja, o fator de influência nas vendas, no momento da análise, manterá uma condição neutra ou sem um impacto significativo). Por exemplo, o preço de venda do produto, em um determinado momento, pode ser considerado com uma pontuação -1, pois quanto maior for o preço do produto menor será a quantidade vendida do mesmo.

6- Encontrar as médias ponderadas

As médias ponderadas são obtidas somando-se o produto dos pesos normalizados com a opinião, através da quantificação da intensidade do impacto, para todos os fatores, considerando-se a análise de cada responsável pela previsão de vendas da empresa.

7 - Encontrar o percentual médio de ajuste

As médias ponderadas devem ser multiplicadas pelo percentual mínimo ou máximo de ajuste, conforme item nº 1 deste procedimento, indicado pelos responsáveis pela previsão.

Após encontrar o valor do ajuste percentual para cada responsável, o qual pode ser positivo ou negativo, calcula-se a média aritmética dos percentuais de ajuste de todos os responsáveis pela previsão de vendas da empresa, obtendo-se o percentual médio de ajuste.

8- Calcular a previsão final

Para proceder com o ajuste da previsão combinada, adiciona-se o valor 1 ao percentual de ajuste médio e, ao multiplicar o valor desta soma pela previsão combinada, será obtida a previsão final ajustada por meio da opinião dos responsáveis pelas previsões da empresa.

Diversos estudos apontam que uma melhor acurácia das previsões é obtida pela integração de métodos qualitativos e quantitativos, através da utilização do conhecimento contextual nos processos matemáticos de previsão (RINGUEST; TANG, 1987; CLEMEN, 1989; BLATTBERG; HOCH, 1990; COLLOPY; ARMSTRONG, 1992; WRIGHT; LAWRENCE; COLLOPY, 1996). O sucesso no desenvolvimento de sistemas que respaldam a tomada de decisões pelos gestores da empresa tem produzido ambientes nos quais as análises subjetivas e matemáticas podem ser facilmente integradas (WRIGHT; LAWRENCE; COLLOPY, 1996).

Em situações ocasionadas por eventos especiais, mudanças internas na empresa ou alterações no mercado reforçam a necessidade de uma previsão subjetiva agregada ao método quantitativo para prever eventos futuros (GOODWIN, 2000; ARMSTRONG, 2001 apud LEMOS, 2006).

O ajuste subjetivo analisa a estimativa quantitativa, avaliando-a mediante os conhecimentos dos responsáveis pela previsão de vendas da empresa, de acordo com o tipo de indústria e conhecimento do mercado para alcançar a previsão final (LEMOS, 2006). Esse modo de integração tem a vantagem de apresentar uma boa relação custo-benefício, mas tem a desvantagem de depender da interpretação correta do especialista sobre os fatores contextuais que embasam o processo de previsão (WEBBY; O'CONNOR, 1996). A acurácia desse tipo de integração é maior quando o ajuste qualitativo possui informações que o modelo quantitativo não aborda, como previsões futuras de alteração da demanda (SANDERS; RITZMAN, 2001 apud LEMOS, 2006).

Tão importante quanto a utilização de métodos quantitativos é a estruturação de um processo que trate as questões relativas ao mercado, de forma a integrar o método quantitativo e o qualitativo, com o objetivo de obter maior acurácia na previsão, através da participação e

da co-responsabilidade das pessoas tomadoras de decisões na empresa (FLEURY; WANKE; FIGUEIREDO, 2003).

2.4.5 Seleção do Modelo de Previsão

Para selecionar o modelo de previsão que melhor se ajusta aos dados, podem ser utilizados vários métodos. Nenhum esforço de previsão terá sucesso se os erros, definidos como a diferença entre os valores reais e os valores previstos, não forem apontados e analisados com o objetivo de reavaliar hipóteses e modificar o modelo de previsão (CORRÊA; GIANESI; CAON, 2001; MARTINS; LAUGENI, 2006). Os erros aleatórios, embora indesejáveis, estão implícitos em todo processo de previsão. O objetivo é escolher o melhor processo de previsão, ou seja, aquele que gera menores erros para que o planejamento seja menos afetado (CORRÊA; GIANESI; CAON, 2001). Algumas medições para quantificar o erro associado a uma previsão de demanda são as seguintes (DAVIS; AQUILANO; CHASE, 2001):

a) Desvio Absoluto Médio (DAM)

O desvio absoluto médio é um método simples e muito utilizado, sendo o erro médio da previsão, pois utiliza valores absolutos. Assim como o desvio padrão mede a dispersão dos valores observados em torno de alguns valores esperados, o DAM é calculado pelo valor absoluto do erro (o módulo da diferença entre a demanda real e a previsão da demanda). Ele é calculado pela soma dos desvios absolutos dividido pelo número de dados. À medida que o tempo avança, o desvio médio absoluto passa a ser calculado por um número maior de períodos, o que diminui a velocidade de ajustamento aos dados (DAVIS; AQUILANO; CHASE, 2001):

$$\text{DAM} = \frac{\sum_{t=1}^n |A_t - F_t|}{n}$$

(61)

onde:

DAM: desvio absoluto médio;

A_t : demanda real do período t ;

F_t : demanda prevista para o período t ;

n : número total de períodos.

b) Erro Quadrático Médio (EQM):

O erro quadrático médio penaliza a previsão muito mais para os desvios extremos do que para os pequenos desvios. Assim, ao aplicar o critério do erro quadrático médio, obtêm-se erros menores quando os desvios forem pequenos, do contrário, com grandes desvios do valor da previsão, o erro tende a aumentar muito (WHEELWRIGHT; MAKRIDAKIS, 1985 apud CAVALHEIRO, 2003):

$$\text{EQM} = \frac{\sum_{t=1}^n (A_t - F_t)^2}{n - 1}$$

(62)

onde:

EQM: erro quadrático médio;

A_t : demanda real do período t ;

F_t : demanda prevista para o período t ;

n : número total de períodos.

c) Soma Acumulada dos Erros de Previsão (SAE)

Esta forma de cálculo tem a desvantagem de que os erros, positivos e negativos, se compensam no somatório final (MARTINS; LAUGENI, 2006):

$$\text{SAE} = \sum_{t=1}^n (A_t - F_t)$$

(63)

onde:

SAE: soma acumulada dos erros;

A_t : demanda real do período t ;

F_t : demanda prevista para o período t ;

n : número total de períodos.

d) Desvio Padrão (DP)

Quando os erros que ocorrem na previsão são normalmente distribuídos, o desvio padrão relaciona-se com o desvio médio absoluto, da seguinte forma (DAVIS; AQUILANO; CHASE, 2001):

$$DP = 1,25 \cdot DAM \quad (64)$$

No modo estatístico, se os limites de controle forem fixados a mais ou menos três vezes o desvio padrão (ou 3,75. DAM), tem-se 99,7% dos dados dentro desses limites. O desvio padrão é a raiz quadrada do erro quadrático médio (DAVIS; AQUILANO; CHASE, 2001):

$$DP = \sqrt{EQM} \quad (65)$$

e) Coeficiente de Determinação

É definido, segundo Harvey (1984), como sendo a Soma dos Quadrados dos Resíduos estimados (SQR), comparando-a com a correspondente Soma dos Quadrados Totais.

Assim, R^2 pode ser determinado como a fração da variação total (SQT) que mede o percentual de explicação pelo modelo com relação a variação da série original e a variância residual ($\hat{\sigma}_a^2$), dado por:

$$R^2 = 1 - \frac{SQR}{SQT} \quad (66)$$

O coeficiente de determinação pode variar de zero a um (0 a 1). Quanto maior o valor de R^2 , maior é o poder de explicação da equação de regressão e, portanto, melhor a previsão da variável dependente (HAIR; ANDERSON; TATHAM; BLACK, 2005).

2.4.6 Controle do Modelo de Previsão Selecionado

Tendo sido selecionado o modelo de previsão que melhor se ajusta aos dados, este é utilizado para prever os valores dos próximos períodos. Mas, é importante garantir, periodicamente, que o modelo selecionado continue a representar a demanda de vendas. Assim, é fundamental que se utilizem ferramentas para acompanhar o modelo escolhido. As duas ferramentas para controle do modelo de previsão selecionado são (MARTINS; LAUGENI, 2006; DAVIS; AQUILANO; CHASE, 2001):

a) Sinal de Acompanhamento (SA):

O sinal de acompanhamento, monitoramento ou rastreamento é a medição que indica se a média prevista está se mantendo 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. O sinal de acompanhamento pode ser calculado da seguinte forma (DAVIS; AQUILANO; CHASE, 2001):

$$SA = \frac{SAE}{DAM} \quad (67)$$

onde:

SA: sinal de acompanhamento, monitoramento ou rastreamento;

SAE: soma acumulada dos erros;

DAM: desvio absoluto médio.

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). O sinal de acompanhamento é uma variável de média zero e desvio padrão igual à unidade. Dessa forma, aceita-se o modelo de previsão como válido se o valor do sinal de acompanhamento ficar entre -3 e +3, ou seja, $-3 \leq SA \leq +3$. Caso isto não ocorra, deve-se iniciar o processo tentando identificar um novo modelo (MARTINS; LAUGENI, 2006).

b) Sinal de Trigg (TR):

O sinal de Trigg (TR) procura corrigir a distorção causada pelo sinal de rastreamento, 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 média exponencial (MARTINS; LAUGENI, 2006; DAVIS; AQUILANO; CHASE, 2001):

$$DAM_t = \alpha (A_{t-1} - F_{t-1}) + (1 - \alpha) \cdot DAM_{t-1}$$

(68)

onde:

DAM_t : desvio absoluto médio no período t ;

α : constante de ajuste entre zero e a unidade (normalmente entre 0,05 e 0,2);

A_{t-1} : demanda real para o período $t-1$;

F_{t-1} : demanda prevista para o período $t-1$;

DAM_{t-1} : desvio absoluto médio no período $t-1$.

2.4.7 Custo da Previsão

O nível ótimo de previsão é aquele cujo custo de execução de um método de previsão compensa exatamente o custo de se trabalhar com uma previsão inadequada. À medida que a acurácia do método aumenta, os custos envolvidos no processo também aumentam. Por outro lado, se utilizarmos previsões de baixa qualidade ou inadequadas, isto pode resultar em custos não-previstos de mão-de-obra, pessoal, matéria-prima e de capital (MONKS, 1987).

O critério para avaliar a previsão é a acurácia, quantificando a representação dos dados pelo modelo escolhido (WHEELWRIGHT; MAKRIDAKIS, 1985 apud CAVALHEIRO, 2003). Ao aplicar mais recursos financeiros para a previsão, através de métodos mais

complexos e caros, atinge-se maior acurácia na previsão. Isso acarreta maior certeza na tomada de decisão do gestor da empresa. A Figura 14 mostra que o custo de utilizar apenas a sensibilidade do gestor na previsão de vendas é alto devido aos erros de previsão, implicando baixa acurácia. 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. Dessa forma, tem-se um ponto ótimo ou ideal de operação, representado pelo ponto ideal de operação, e que apresenta a melhor relação no *trade-off* entre o custo total e a acurácia ou precisão (MONTGOMERY; JOHNSON, 1976; FLEURY; WANKE; FIGUEIREDO, 2000).




Figura 14: Relação entre a acurácia do método e o custo da previsão.

Fonte: Adaptado de Monks (1987), p.196 e Fleury; Wanke; Figueiredo (2000), p. 240.

Curva A: Representa o custo total

Curva B: Representa o custo da previsão

Curva C: Representa os custos das más-previsões (perdas geradas pela incerteza na tomada de decisão).

Dentre os custos a que se incorre com uma previsão de vendas de baixa acurácia, podem ser citados: o custo de estoque de produto fabricado em quantidade superior à necessária, custo do não-atendimento do cliente por falta do produto fabricado, alto nível de

estoque e compras de emergência, gerando maior custo de transporte (FLEURY; WANKE; FIGUEIREDO, 2003).

2.4.8 Síntese do Capítulo

Neste capítulo, foi apresentado o referencial conceitual teórico necessário para o desenvolvimento desta dissertação. No próximo capítulo será apresentada a metodologia para o desenvolvimento deste trabalho de pesquisa.

3 METODOLOGIA

Este capítulo aborda a metodologia a ser utilizada para realização deste trabalho. Segundo Gil (1995), o objetivo fundamental de uma pesquisa é descobrir respostas para problemas mediante o emprego de procedimentos científicos.

Lakatos e Marconi (1996) sustentam que toda pesquisa científica tem como característica comum o emprego de métodos científicos. O método de pesquisa ou metodologia compreende o conjunto das atividades sistemáticas e racionais que, com maior segurança, possibilitam o alcance do objetivo, traçando o caminho a ser seguido, detectando erros e auxiliando nas decisões do investigador.

Segundo Gil (1995), o método científico é definido como um conjunto de procedimentos técnicos e intelectuais com o objetivo de atingir o conhecimento ou conhecer determinada realidade. O método identifica a forma pela qual os objetivos propostos pelo trabalho serão alcançados (OLIVEIRA, 1999).

A pesquisa aplicada tem ênfase prática na solução de problemas (COOPER; SCHINDLER, 2003), sendo este trabalho caracterizado como uma pesquisa aplicada, cujos dados históricos foram utilizados, principalmente, na forma quantitativa. A pesquisa aplicada é motivada pela necessidade de resolver problemas concretos. Tem, portanto, finalidade prática, ao contrário da pesquisa pura, que é impulsionada pela curiosidade intelectual do pesquisador (VERGARA, 2006).

Um estudo de caso bem planejado pode representar um desafio importante para uma teoria e, simultaneamente, ser a fonte de novas hipóteses e constructos (COOPER; SCHINDLER, 2003).

A presente dissertação está baseada, também, numa pesquisa aplicada quantitativa, que segundo Menezes e Silva (2001), tem como objetivo gerar conhecimentos para aplicação prática dirigida à solução de problemas específicos, com o uso de técnicas de modelagem estatística.

Para o desenvolvimento da pesquisa, utilizou-se o estudo de caso, procedimento justificável pelo caráter exploratório da pesquisa (TRIPODI et al., 1975). De acordo com Yin

(1994), a opção de estudo de caso, como estratégia de pesquisa, se justifica quando o estudo focaliza o âmbito das decisões, isto é, tenta esclarecer o motivo pelo qual as decisões foram tomadas, como foram implementadas e quais os resultados encontrados.

Esta dissertação aborda a construção de um modelo de previsão de vendas em uma empresa do setor têxtil, constituindo-se num estudo de caso. O estudo de caso tem caráter de profundidade e detalhamento, estando circunscrito a uma empresa, órgão público, comunidade ou mesmo um país (VERGARA, 2006).

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

A primeira etapa: Revisão bibliográfica sobre os métodos de previsão de vendas.

Dentre os vários métodos de previsão, escolheu-se trabalhar com os modelos de Box & Jenkins, pois estes apresentam resultados mais precisos e contêm um número pequeno de parâmetros quando comparados com os demais métodos de previsão (MORETTIN; TOLOI, 1987).

Também foram utilizadas informações decorrentes da literatura citada na bibliografia que, de acordo com Cervo e Bervian (2002), busca conhecer e analisar as contribuições culturais ou científicas do passado, existentes sobre um determinado assunto, para servir de base fundamental para o desenvolvimento da dissertação.

Utilizou-se, também, uma ferramenta muito importante – a Internet – como fonte de pesquisa, pois, para Severino (2002), a Internet, tornou-se uma indispensável fonte de pesquisa para os diversos campos do conhecimento. Severino (2002) destaca ainda que a Internet possui um extraordinário acervo de dados que está colocado à disposição de todos interessados, e que pode ser acessado com extrema facilidade por todos eles, graças à sofisticação dos recursos atuais.

A segunda etapa: Coleta de dados.

Dados são números e fatos brutos não analisados, enquanto informações são dados que foram organizados ou analisados de modo significativo (STONER; FREMAN, 1999). Nesta etapa foram coletados os dados referentes às vendas dos principais produtos do setor de fabricação de tecidos de malha feito em máquinas circulares, no período de janeiro de 2002 a dezembro de 2006. Foi realizada uma entrevista com os responsáveis pela previsão de vendas,

com o objetivo de obter os dados qualitativos, por meio do Quadro 11 (página 121). A empresa que forneceu os dados para o desenvolvimento deste trabalho de pesquisa foi designada de Empresa Padrão, por questão de sigilo das informações.

A terceira etapa: Tratamento dos dados.

Vergara (2006) afirma que o tratamento de dados refere-se àquela seção na qual se explica para o leitor como se pretende tratar os dados, justificando por que tal tratamento é adequado aos propósitos desta pesquisa. Assim, os dados analisados neste trabalho levam em consideração os objetivos pré-definidos. Nessa etapa, foi realizada uma análise exploratória dos dados referentes às vendas dos principais produtos do setor analisado e construído um modelo que melhor represente o comportamento de cada um dos produtos.

Atualmente, existem vários programas disponíveis para a previsão de demanda, sendo que as pessoas não precisam ser especialistas em técnicas estatísticas de previsão para utilizá-los, pois, em sua maioria, são de fácil uso e entendimento (DAVIS; AQUILANO; CHASE, 2001).

Pellegrini (2000) classifica os pacotes computacionais estatísticos em duas classes: de uso genérico e de uso específico. Os pacotes de uso genérico, em sua maioria, apresentam uma opção de análise de *forecasting*, sendo utilizados quando é necessária uma análise estatística e gráfica detalhada dos dados. Os pacotes mais conhecidos são: NCSS (*Number Cruncher Statistical System*), que utiliza os modelos ARIMA, suavização exponencial e decomposição de séries temporais; *Statgraphics*, que possui os mesmos modelos do NCSS, o SPSS (*Statistical Package for Social Science*) e o Statistica. Os pacotes de uso específico contêm apenas as ferramentas estatísticas para análise das séries temporais. Os pacotes específicos para a previsão de demanda mais utilizados são o Forecast Pro e o Autobox. O Forecast Pro oferece a escolha automática do modelo que melhor representa a série temporal. O Autobox permite a análise através dos modelos SARIMA com e sem intervenção, suavização exponencial, além da análise de regressão e modelos de função de transferência.

Para o desenvolvimento desta dissertação foram utilizados os programas Autobox e o Statistica versão 7.0.

A quarta etapa: Análise dos Resultados.

A última etapa discute os resultados obtidos com a aplicação da modelagem estocástica e da análise qualitativa.

O método de previsão de vendas foi baseado na análise quantitativa e qualitativa, ou seja, utilizando-se de dados históricos de vendas de produtos para prever as vendas futuras, além da opinião dos responsáveis pelo planejamento da empresa.

As ferramentas auxiliares utilizadas, para a análise dos dados, foram os pacotes computacionais *Statistica* e o *AutoBox*. O pacote computacional *Statistica* foi utilizado para a análise exploratória dos dados, para a modelagem através de modelos de médias móveis e para a modelagem de Regressão.

O *Statistica* foi desenvolvido pela *Statsoft* e serve para a análise estatística em micro-computadores do tipo PC. Trata-se de um sistema interativo, dirigido através de menus conectados hierarquicamente. Em qualquer estágio de uma sessão, tornam-se disponíveis ao usuário várias facilidades que podem ser executadas através da seleção de um menu apropriado. Além de análises estatísticas, possui uma variedade de atividades com os dados. Possui um menu bem explicativo e é de fácil uso. Possibilita, também, uma fácil importação dos dados.

O pacote computacional *AutoBox* foi utilizado para a análise dos modelos gerais SARIMA (Autoregressivo-Integrado-Médias Móveis) sazonais.

4 ESTUDO DE CASO

Na primeira parte deste capítulo será apresentada a aplicação da metodologia de Box & Jenkins para a previsão de vendas dos principais produtos do setor de máquinas circulares, sendo analisados os dados de vendas no período de janeiro de 2002 a dezembro de 2006 para os produtos A, B, C. No período de setembro de 2002 a dezembro de 2006, analisou-se o produto D. No período de março de 2002 a dezembro de 2006, foram analisadas as vendas para os produtos E e H. No intervalo de agosto de 2003 a dezembro de 2006, foram analisadas as vendas do produto M. Os dados referentes aos meses de janeiro a abril de 2007 não foram considerados no processo de construção dos modelos e aplicação das técnicas de previsão, para serem utilizados na previsão fora da amostra.

Após a metodologia quantitativa, apresenta-se a análise qualitativa a partir das opiniões dos responsáveis pela previsão de vendas na empresa. Finalmente, descreve-se uma combinação destes dois modelos, bem como o ajuste nas previsões obtidas através do modelo combinado, obtendo-se assim, o modelo integrado de previsão de vendas para os principais produtos do setor analisado da empresa. O objetivo é obter um modelo que forneça previsões mais precisas, auxiliando o gestor na tomada de decisões, de forma a otimizar os recursos disponíveis na empresa, na busca de maior competitividade da empresa no mercado de atuação.

4.1 ANÁLISE QUANTITATIVA

A modelagem dos principais produtos fabricados no setor de máquinas circulares da empresa padrão em estudo, designados por A, B, C, D, E, H e M, será realizada através da metodologia de Box & Jenkins. Para a análise serão considerados modelos de séries temporais com e sem a presença de intervenção.

4.1.1 Série representativa das vendas do produto A:

Neste item, apresenta-se a análise descritiva da série original, os correlogramas das funções de autocorrelação e autocorrelação parcial para analisar a estacionariedade, a homocedasticidade da variância da série e a presença da componente sazonal, bem como a determinação da ordem autoregressiva e de médias móveis dos dados.

Apresenta-se, também, a análise descritiva da série original e os correlogramas das funções de autocorrelação e autocorrelação parcial para a determinação do modelo que melhor se ajusta aos dados.

As medidas descritivas estão colocadas na tabela 1:

Tabela 1: Medidas descritivas do Produto A no período de janeiro de 2002 a dezembro de 2006.

<i>Medidas descritivas do Produto A</i>	<i>Valores</i>
Média (Kg)	6845
Desvio Padrão (Kg)	4153
Coefficiente de Variação (%)	61

Fonte: Elaborado pelo autor com base nos dados.

4.1.1.1 Modelo sem intervenção para as vendas do produto A

A Figura 15 apresenta o comportamento da série original representativa das quantidades mensais vendidas do produto A (em Kg) no período de janeiro de 2002 a dezembro de 2006. Observa-se que a série apresentou uma mudança de nível significativa ($p < 0,05$) no mês de março de 2003, correspondente ao mês 15 da amostra. Portanto, pode-se dizer que ela se desenvolve no tempo aleatoriamente ao redor de uma média, a partir do mês de abril de 2003, correspondente ao mês 16. Quanto à variância, a série apresenta uma heterocedasticidade constante, o que foi constatado através do teste F para um nível de significância de 5%, para os subperíodos. Neste caso não há a necessidade de se fazer transformação na série para estabilizar a variância.




Figura 15:Comportamento da série original do volume mensal de vendas (kg) do Produto A.

Fonte: Elaborado pelo autor.

A Figura 16 apresenta o comportamento da função de autocorrelação. Assim, analisando-se a função de autocorrelação, pode-se confirmar que a série de vendas mensais é estacionária, pois apresenta um decaimento rápido para zero a partir do *lag* $k=3$, apresentando uma indicação inicial de que o modelo verdadeiro contém componentes de médias móveis. Para confirmar esta hipótese, foram calculados os coeficientes da função de autocorrelação parcial representado na Figura 17. Pela Figura 17, observa-se que somente $\phi_{kk}=1$ apresenta valor significativo, para $p<0,05$, indicando que a série de vendas mensais do Produto A possui um componente auto-regressivo de ordem 1.

Assim, analisando o comportamento conjunto das funções de autocorrelação e autocorrelação parcial, existem dois modelos que podem ser ajustados, um modelo ARIMA (1,0,3) ou um modelo ARIMA(1,0,1).




Figura 16: Coeficientes da função de autocorrelação da série de vendas do produto A – modelo sem intervenção

Fonte: Elaborado pelo autor.

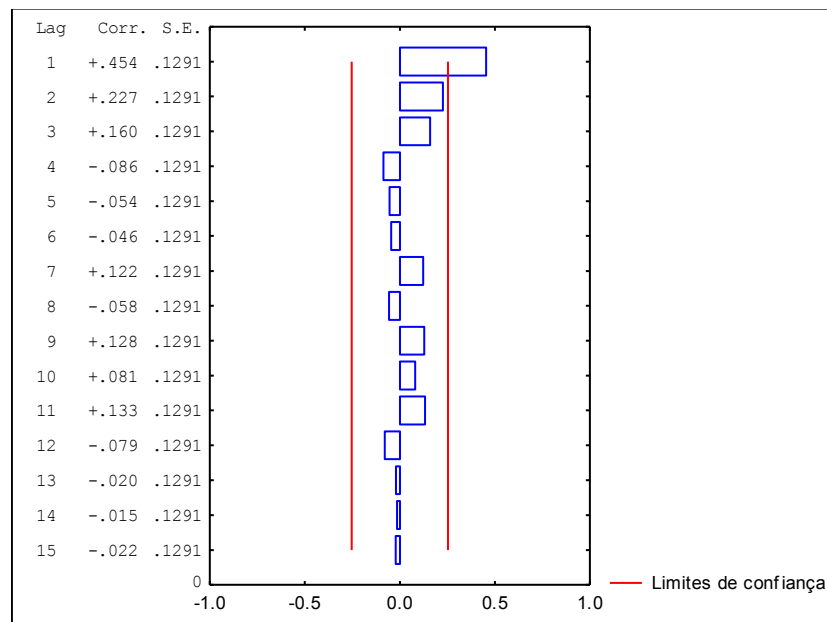


Figura 17: Coeficientes da função de autocorrelação parcial da série de vendas do produto A – modelo sem intervenção

Fonte: Elaborado pelo autor.

O modelo sem intervenção é representado por:

$$\hat{Y}_t = 6602 + \overset{(5,37)}{0,84} Y_{t-1} + \overset{(7,50)}{0,472} a_{t-1} + \overset{(2,84)}{a_t}$$

As estatísticas de ajuste foram: $R^2 = 29\%$, o Critério de Informação de Akaike (AIC) = -1,99 e o Critério de Schwarz (BIC) = -1,85. Desta forma, verifica-se que o coeficiente de determinação R^2 apresenta um valor baixo, pois está longe do valor unitário, o que prejudica a acurácia da modelagem. Os critérios de Akaike e Schwarz, que medem a verossimilhança e a parcimônia dos modelos, devem apresentar baixos valores, quanto mais próximos de zero forem os valores dos critérios de Akaike e Schwarz, maior acurácia será obtida na previsão de vendas.

Pela análise dos coeficientes de autocorrelação, pode-se observar pela Figura 18 que todos os coeficientes estão dentro dos limites de confiança ($\pm 2 \sigma$), indicando que não existe correlação entre eles, ou seja, não existe *lag* significativo (nenhum ultrapassa o intervalo de confiança). Desta forma, os resíduos formam um processo de ruído branco.




Figura 18: Coeficientes da função de autocorrelação dos resíduos do produto A – modelo sem intervenção.

Fonte: Elaborado pelo autor.

4.1.1.2 Modelo com intervenção para as vendas do produto A:

Foi encontrada uma intervenção significativa, referente a uma mudança na média do processo na observação 15, ou seja, março de 2003. O modelo representativo está apresentado na equação a seguir:

$$\hat{Y}_t = 11.079 + 0,60 Y_{t-1} + 0,39 Y_{t-2} - 5.638 I_{1,15} + a_t$$

(9,53)
(2,18)
(1,97)
(-4,28)

As estatísticas de ajuste foram de $R^2 = 44\%$, $AIC = -2,27$ e $BIC = -2,17$, as quais foram melhores do que as encontradas através do modelo ARIMA(1,0,1) sem intervenção, pois o coeficiente de determinação passou de 29% no modelo sem intervenção para 44% no modelo com intervenção. A função de autocorrelação da série de resíduos não apresentou nenhum ponto fora dos limites de controle, indicando que o modelo gerou uma série de erros aleatórios, portanto pode-se utilizar o modelo para fazer previsões, conforme a Figura 19.




Figura 19: Coeficientes da função de autocorrelação dos resíduos do Produto A - modelo com intervenção.

Fonte: Elaborado pelo autor.

4.1.1.3 Previsão para as vendas do produto A

Foram calculadas as previsões para o período de janeiro a abril de 2007, pelos modelos sem intervenção, com intervenção e as previsões fornecidas pela empresa, que estão apresentadas no Quadro 3.

O critério utilizado para escolher o melhor modelo de previsão foi o MAPE, equação nº 55 da página 62, que está apresentado no Quadro 3. Verifica-se, de forma clara, que o atual método de previsão utilizado pela empresa apresenta o maior erro (MAPE = 53,23%) quando comparado com os dois métodos de Box & Jenkins, ou seja, apresenta a menor acurácia na previsão de vendas.

Quadro 3: Comparação do Método de Box & Jenkins com Intervenção e sem Intervenção com os Valores Previstos pela Empresa e as Vendas Reais (em Kg) do Produto A através do MAPE.

Meses 2007	Modelo sem Intervenção	Modelo com Intervenção	Valor Previsto pela Empresa	Venda Real do Produto A
Janeiro	5284	6780	7420	7634
Fevereiro	5499	5266	10000	5201
Março	5679	4972	7000	4590
Abril	5830	4120	5000	3024
MAPE (%)	38,26	14,25	53,23	-

Fonte: Elaborado pelo autor com base nos dados.

4.1.2 Série representativa das vendas do produto B:

Neste item, apresenta-se a análise descritiva da série original e os correlogramas das funções de autocorrelação e autocorrelação parcial para a determinação do modelo que melhor se ajusta aos dados.

As medidas descritivas estão colocadas na Tabela 2:

Tabela 2: Medidas descritivas do Produto B no período de janeiro de 2002 a dezembro de 2006.

<i>Medidas descritivas do Produto B</i>	<i>Valores</i>
Média (Kg)	5316
Desvio Padrão (Kg)	7724
Coefficiente de Variação (%)	145

Fonte: Elaborado pelo autor com base nos dados.

4.1.2.1 Modelo sem intervenção para as vendas do produto B:

A Figura 20 apresenta o comportamento da série original representativa das quantidades mensais vendidas do produto B (em Kg) no período de janeiro de 2002 a dezembro de 2006. Na Figura 20, observa-se que a série apresenta vários *outliers* significativos ($p < 0,05$), portanto pode-se dizer que ela se desenvolve no tempo aleatoriamente ao redor de uma média, podendo ser considerada estacionária, em relação à variância. Pode-se afirmar, com base no teste F para um nível de significância de 5% para os subperíodos, que ela é constante, não havendo a necessidade de se fazer transformações na série original para estabilizar a variância.




Figura 20: Comportamento da série original do volume mensal de vendas (kg) do Produto B.

Fonte: Elaborado pelo autor.

Analisando-se as Figuras 21 e 22, pode-se afirmar que a série é estacionária tanto na média como na variância, pois os gráficos da função de autocorrelação e autocorrelação parcial têm coeficientes que tendem a zero rapidamente, sugerindo um modelo ARIMA (1,0,1) sem intervenções.




Figura 21: Coeficientes da função de autocorrelação da série de vendas do produto B – modelo sem intervenção.

Fonte: Elaborado pelo autor.




Figura 22: Coeficientes da função de autocorrelação parcial da série de vendas do produto B – modelo sem intervenção.

Fonte: Elaborado pelo autor.

O modelo sem intervenção é representado por:

$$\hat{Y}_t = 6602 + \overset{(5,37)}{0,84} Y_{t-11} + \overset{(7,50)}{0,472} a_{t-1} + a_t \quad \overset{(2,84)}{}$$

As estatísticas de Ajuste foram: $R^2 = 22\%$, o Critério de Informação de Akaike (AIC) = -0,50 e o Critério de Schwarz (BIC) = -0,46. Embora os dois critérios, de Akaike e

Schwarz, tenham valores próximos de zero, o que melhora a previsão, tem-se um valor muito baixo do coeficiente de determinação R^2 , o que baixa a acurácia do modelo.

Na Figura 23 mostra-se o comportamento dos coeficientes de autocorrelação para a série de resíduos.




Figura 23: Coeficientes da Função de autocorrelação dos resíduos do Produto B - modelo sem intervenção.

Fonte: Elaborado pelo autor.

Observando-se a Figura 23, pode-se dizer que o modelo é adequado, pois todos os coeficientes de autocorrelação estão dentro dos limites de confiança, ou seja, demonstram que a série de resíduos é um ruído branco.

4.1.2.2 Modelo com intervenção para as vendas do produto B:

Foram detectadas cinco intervenções significativas nos períodos t iguais a 16, 27, 38, 39 e 49, do tipo *outliers*. O modelo está representado por:

$$\hat{Y}_t = 3589,9 - 0,68 a_{t-1} + 4,9582 I_{1,49} + 1,6912 I_{2,38} + 1,5526 I_{3,16} + 0,95449 I_{4,27} + 1,2361 I_{5,39} a_t$$

As estatísticas de ajuste foram de $R^2 = 92\%$; $AIC = -2,82$; $BIC = -2,57$, as quais foram melhores do que as encontradas através do modelo $ARIMA(1,0,1)$ sem intervenção, pois o coeficiente de determinação passou de 22% no modelo sem intervenção para 92% no modelo com intervenção, ficando mais próximo de 100% ou valor unitário, melhorando a capacidade de previsão do modelo. A função de autocorrelação da série de resíduos não apresentou nenhum ponto fora dos limites de controle indicando que o modelo gerou uma série de erros aleatórios. Portanto, pode-se utilizar o modelo para fazer previsões.




Figura 24: Coeficientes da Função de autocorrelação dos resíduos do Produto B - modelo com intervenção.

Fonte: Elaborado pelo autor.

4.1.2.3 Previsão para as vendas do produto B

Foram calculadas as previsões para o período de janeiro a abril de 2007, pelos modelos sem intervenção, com intervenção e as previsões fornecidas pela empresa, que estão apresentados no Quadro 4.

Com relação a este produto não foi possível fazer a análise referente à precisão das previsões, pois, para o período em análise, só havia o valor real para o mês de janeiro de 2007, impossibilitando assim o cálculo do MAPE para dados fora da amostra.

Quadro 4: Comparação do Método de Box & Jenkins com Intervenção e sem Intervenção com os Valores Previstos pela Empresa para as vendas do Produto B.

Meses 2007	Modelo sem Intervenção	Modelo com Intervenção	Valor Previsto pela Empresa
Janeiro	7475	9558	7800
Fevereiro	6348	8429	12800
Março	7559	9120	12800
Abril	4876	8679	11500

Fonte: Elaborado pelo autor com base nos dados.

4.1.3 Série representativa das vendas do produto C:

Neste item, apresenta-se a análise descritiva da série original e os correlogramas das funções de autocorrelação e autocorrelação parcial para a determinação do modelo que melhor se ajusta aos dados de vendas do produto C.

As medidas descritivas estão colocadas na Tabela 3:

Tabela 3: Medidas descritivas do Produto C no período de janeiro de 2002 a dezembro de 2006.

<i>Medidas descritivas do Produto C</i>	<i>Valores</i>
Média (Kg)	4756
Desvio Padrão (Kg)	2734
Coefficiente de Variação (%)	57

Fonte: Elaborado pelo autor com base nos dados.

4.1.3.1 Modelo sem intervenção para as vendas do produto C

Na Figura 25, apresenta-se o comportamento da série representativa do Produto C. Pode-se dizer que ela se desenvolve no tempo aleatoriamente ao redor de uma média, podendo ser considerada estacionária. Quanto à variância, a série não apresenta uma

homocedasticidade constante, o que também foi confirmado através do teste F para um nível de significância de 5%, para os subperíodos de 2002 e 2005, cujo valor da estatística calculada foi de 5,02 sendo que a estatística tabelada é de 2,69, para um nível de significância de 5%. Neste caso há a necessidade de se fazer transformações na série original para estabilizar a variância, após várias tentativas, optou-se pela raiz quadrada, pois foi a melhor transformação encontrada.




Figura 25: Comportamento da série original do volume mensal de vendas (kg) do Produto C.

Fonte: Elaborado pelo autor.

A Figura 26 apresenta o comportamento da série transformada. Aplicando-se o teste F para um nível de significância de 5%, cujos valores da estatística calculada para todos os subperíodos encontrados foram 1,98; 1,30; 1,25 e 2,66, sendo que a estatística tabelada é de 2,69. Assim, pode-se concluir que a transformação aplicada estabilizou a variância, apresentando um *outlier* no período 34 correspondendo ao mês de outubro de 2004.




Figura 26: Comportamento da série transformada (raiz quadrada) do volume mensal de vendas (kg) do Produto C.

Fonte: Elaborado pelo autor.

Nas Figuras 27 e 28 apresenta-se o comportamento das funções de autocorrelação e autocorrelação parcial.




Figura 27: Coeficientes da função de autocorrelação da série de vendas do produto C.

Fonte: Elaborado pelo autor.

Analisando a Figura 27, pode-se concluir que a série é estacionária, pois possui um decaimento rápido para zero, apresentando somente um $lag\ k=18$ significativo, ou seja, fora dos limites de confiança, indicando que o modelo pode possuir componentes de médias

móveis. Da mesma forma, a Figura 28 mostra que o coeficiente de autocorrelação parcial referente ao *lag* $k=18$ está fora dos limites de confiança, indicando que a série de vendas mensais do Produto C pode possuir componentes auto-regressivos.




Figura 28: Coeficientes da função de autocorrelação parcial da série de vendas do produto C.

Fonte: Elaborado pelo autor.

Com base na análise das funções de autocorrelação e autocorrelação parcial, ajustaram-se dois modelos, um sem intervenção e outro com intervenção, que estão apresentados a seguir.

O modelo ajustado sem intervenção foi do tipo SARIMA(1,0,0)x(2,0,0):

$$\hat{Y}_t = 4751 + \overset{(11,45)}{0,19} Y_{t-1} - \overset{(-0,39)}{0,06} Y_{t-6} - \overset{(-0,15)}{0,02} Y_{t-12} + a_t$$

Como os coeficientes autoregressivos ϕ_1 , Φ_6 e Φ_{12} não são significativos para $p < 0,05$, ou seja, são menores que o valor 1,96, correspondente ao nível de significância de 5%, o modelo sem intervenção se resume à equação abaixo:

$$\hat{Y}_t = \overset{(11,45)}{4751} + a_t$$

As estatísticas de ajuste foram $R^2 = 96\%$, os critérios (AIC) = -2,62 e (BIC) = -2,55, demonstrando um coeficiente de determinação R^2 muito próximo a 100% ou valor unitário, revelando boa capacidade de previsão do modelo.

Pela análise dos coeficientes de autocorrelação dos resíduos, mostrados pela figura 29, pode-se observar que todos os coeficientes estão dentro dos limites de confiança ($\pm 2\sigma$), correspondente ao nível de significância de 5%, o que mostra que a série é um ruído branco e pode ser utilizada para previsão.




Figura 29: Coeficientes da função de autocorrelação da série de resíduos do produto C – modelo sem intervenção.

Fonte: Elaborado pelo autor.

4.1.3.2 Modelo com intervenção para as vendas do produto C

Foi adicionada uma variável de intervenção, relativa a outubro de 2004, correspondente ao mês 34 da amostra. O impacto de curto prazo ($\omega_0 = 10.764$) foi instantâneo (isto é $b=0$), ou seja, sem defasagem temporal e com magnitude de 10.764. Em outras palavras, esse impacto de intervenção em outubro de 2004 sobre as vendas foi responsável pela elevação do nível das vendas em 10.764 kilos.

O modelo ajustado foi do tipo:

$$\hat{Y}_t = 4453 + \overset{(10,01)}{0,09} Y_{t-1} + \overset{(0,66)}{0,16} Y_{t-6} + \overset{(1,03)}{0,06} Y_{t-12} + a_t$$

Como os coeficientes autoregressivos ϕ_1 , Φ_6 e Φ_{12} não são significativos para $p < 0,05$, pois os valores são inferiores ao valor 1,96 correspondente ao nível de significância de 5%, o modelo com intervenção se resume à equação abaixo:

$$\hat{Y}_t = \overset{(10,01)}{4453} + \overset{(4,09)}{10,764} I_{1,34} + a_t$$

As estatísticas de ajuste foram de $R^2 = 98\%$; $AIC = -2,78$; $BIC = -2,71$. As estatísticas de ajuste do modelo com intervenção foram melhores do que as encontradas através do modelo SARIMA(1,0,0)x(2,0,0) sem intervenção, pois o coeficiente de determinação passou de 96% no modelo sem intervenção para 98% no modelo com intervenção, ficando ainda mais próximo de 100% ou do valor unitário, que é a situação ideal.

A Figura 30 representa a etapa de verificação, avaliando se o modelo estimado é adequado para fazer as previsões. Conforme pode-se verificar na Figura 30, todos os coeficientes estão dentro dos limites de confiança, demonstrando que a série de resíduos é um ruído branco (aleatório), ou seja, o modelo pode ser utilizado para prever as vendas do produto C.




Figura 30: Coeficientes da Função de autocorrelação dos resíduos do modelo SARIMA (1,0,0)x(2,0,0) com intervenção das vendas do Produto C.

Fonte: elaborado pelo autor.

4.1.3.3 Previsão para as vendas do produto C

Foram calculadas as previsões para o período de janeiro a abril de 2007, pelos modelos sem intervenção, com intervenção e as previsões fornecidas pela empresa, que estão apresentados no Quadro 5.

O critério utilizado para escolher o melhor modelo de previsão foi o MAPE, que está apresentado no Quadro 5.

Quadro 5: Comparação do Método de Box & Jenkins com Intervenção e sem Intervenção com os Valores Previstos pela Empresa e as Vendas Reais (em Kg) através do Produto C através do MAPE.

Meses 2007	Modelo sem Intervenção	Modelo com Intervenção	Valor Previsto pela Empresa	Venda Real do Produto C
Janeiro	4864	4289	2857	3351
Fevereiro	4558	5078	5000	4876
Março	4778	4432	5200	4436
Abril	4615	4887	5000	5910
MAPE (%)	20,37	12,38	12,60	-

Fonte: Elaborado pelo autor com base nos dados.

4.1.4 Série representativa das vendas do produto D

Neste item, apresenta-se a análise descritiva da série original e os correlogramas das funções de autocorrelação e autocorrelação parcial para a determinação do modelo que melhor se ajusta aos dados referentes às quantidades vendidas do produto D.

As medidas descritivas estão colocadas na Tabela 4:

Tabela 4: Medidas descritivas do Produto D no período de setembro de 2002 a dezembro de 2006.

<i>Medidas descritivas do Produto D</i>	<i>Valores</i>
Média (Kg)	5348

Desvio Padrão (Kg)	4078
Coefficiente de Variação (%)	76

Fonte: Elaborado pelo autor com base nos dados.

A variação pode ser em função dos *outliers* ocorridos nos períodos de junho de 2003 (mês 10) e março de 2004 (mês 19), quando houve uma redução de 65% e um aumento percentual nas vendas em 67%, respectivamente, bem como uma mudança de nível em fevereiro de 2006 na magnitude de 163% (mês 42).

A Figura 31 apresenta o comportamento da série original representativa das quantidades mensais vendidas (em Kg) no período de setembro de 2002 a dezembro de 2006, do Produto D. Observando-se a Figura 31, a série apresentou dois *outliers* e uma mudança de nível.




Figura 31: Comportamento da série original do volume mensal de vendas (kg) do Produto D.

Fonte: Elaborado pelo autor.

Pelos correlogramas, Figuras 32 e 33, pode-se dizer que ela se desenvolve no tempo aleatoriamente ao redor de uma média, podendo ser considerada estacionária.




Figura 32: Coeficientes da função de autocorrelação da série de vendas do produto D.
 Fonte: Elaborado pelo autor.




Figura 33: Coeficientes da função de autocorrelação parcial da série de vendas do produto D.

Fonte: Elaborado pelo autor.

4.1.4.1 Modelo sem intervenção para as vendas do produto D

Aparentemente a série apresenta uma componente sazonal de ordem $s=3$. Quanto à variância, a série apresenta uma homocedasticidade constante, o que foi constatado através do

teste F para um nível de significância de 5% para os subperíodos analisados. Os valores de F para os cinco subperíodos foram 7,83 ($F_{5\%, 11, 3} = 8,79$) e 1,94; 3,10; 1,59; 1,19, enquanto que o $F_{5\%, 11, 11} = 2,69$. Neste caso não há a necessidade de se fazer transformação na série para estabilizar a variância. Também ficou visível a presença de uma componente sazonal trimestral.

Assim, com base nestas informações, o modelo ajustado sem intervenção SARIMA(2,0,0)x(0,0,2)₃ foi:

$$\hat{Y}_t = 5498 + \overset{(5,65)}{0,67} Y_{t-1} - \overset{(4,45)}{0,67} Y_{t-2} - \overset{(-0,83)}{0,12} a_{t-3} + \overset{(-0,72)}{0,27} a_t + \overset{(0,78)}{a_t}$$

Os valores entre parênteses representam a estatística “t” calculada para as estimativas dos parâmetros, a qual é significativa para $p < 0,05$ ($t = 1,96$). As estatísticas de ajuste foram $R^2 = 46\%$, o (AIC): -2,26 e o (BIC): -2,14. O coeficiente de determinação apresentou um valor baixo comparado com o ideal, próximo de 100% ou do valor unitário. O coeficiente a_t é o resíduo, que é independente e identicamente distribuído, portanto um ruído branco, conforme a Figura 34.

Pela análise dos coeficientes de autocorrelação, pode-se observar pela Figura 34, que todos os coeficientes estão dentro dos limites de confiança ($\pm 2\sigma$), logo o modelo é adequado para a realização de previsões.




Figura 34: Coeficientes da função de autocorrelação da série de resíduos do produto D – modelo sem intervenção.

Fonte: Elaborado pelo autor.

4.1.4.2 Modelo com intervenção para as vendas do produto D

Para as quantidades vendidas do produto D, o ARIMA que melhor se ajustou foi um modelo contendo dois parâmetros autoregressivos de ordem $p=1$ e $p=4$ e três variáveis de intervenção, que correspondem às seguintes datas junho de 2003 (mês 10); março de 2004 (mês 19) e fevereiro de 2006 (mês 42). As intervenções ocorridas em junho de 2003 (mês 10) e março de 2004 (mês 19) representam intervenções do tipo impulso, isto é, os seus efeitos ocorrem somente nos períodos onde houve a intervenção. A intervenção ocorrida em fevereiro de 2006 é do tipo *step*, ou seja, mudança de nível. Esse modelo pode ser escrito da seguinte forma:

$$\hat{Y}_t = 10.973 + \overset{(7,20)}{0,65} Y_{t-1} - \overset{(-2,60)}{0,24} Y_{t-4} - \overset{(-4,14)}{7.559} I_{1,10} + \overset{(2,70)}{4.327} I_{2,19} + \overset{(7,12)}{11.820} I_{3,42} + a_t$$

O coeficiente do parâmetro autoregressivo de ordem 1 ($\phi_1 = 0,65$) mostra que 65% das quantidades vendidas no período $t-1$ transmite-se às quantidades vendidas no período t , ou seja, no mês seguinte, e que o de ordem 4 ($\phi_2 = 0,24$), mostra que as quantidades vendidas no próximo mês são reduzidas em 24% em função das vendas ocorridas em 4 meses passados. Em relação à magnitude dos parâmetros das intervenções, pode-se dizer $\omega_0 = -6.614$, ocasionando uma redução de 6.614 kg, enquanto que $\omega_1 = 4.309$ proporciona um aumento de 4.309 kg e $\omega_3 = 11.259$ é responsável pela alteração do nível da série em 11.259 kg.

As estatísticas de ajuste foram de $R^2 = 81\%$; $AIC = -3,19$ e $BIC = -2,96$, demonstrando que foram melhores do que as encontradas através do modelo SARIMA $(2,0,0) \times (0,0,2)_3$ sem intervenção, pois o coeficiente de determinação passou de 46% para 81%, indicando que o modelo tem condições de realizar uma previsão com maior acurácia. Os valores do Critério de Informação de Akaike e o Critério de Schwarz, que medem a verossimilhança dos modelos – relacionada com a minimização da soma dos quadrados dos resíduos do modelo e a parcimônia – vinculada a um pequeno número de parâmetros para a representação matemática da série, apresentam valores um pouco acima de zero (situação ideal).

A função de autocorrelação da série de resíduos não apresentou nenhum ponto fora dos limites de controle. Isto indica que o modelo gerou uma série de erros aleatórios, conforme Figura 35, portanto pode-se utilizar o modelo para fazer previsões.




Figura 35 - Coeficientes da função de autocorrelação da série de resíduos do produto D modelo com intervenção.

Fonte: Elaborado pelo autor.

4.1.4.3 Previsão para as vendas do produto D

Foram calculadas as previsões para o período de janeiro a abril de 2007, pelos modelos sem intervenção, com intervenção, as quais estão apresentadas no quadro 6, juntamente com as previsões fornecidas pela empresa.

O critério utilizado para escolher o melhor modelo de previsão foi o MAPE, que está apresentado no Quadro 6.

Quadro 6: Comparação do Método de Box & Jenkins com Intervenção e sem Intervenção com os Valores Previstos pela Empresa e as Vendas Reais (em Kg) do Produto D através do MAPE.

Meses 2007	Modelo sem Intervenção	Modelo com Intervenção	Valor Previsto pela Empresa	Venda Real do Produto D
Janeiro	8128	8691	8740	9139
Fevereiro	7390	9450	11000	13226
Março	6526	8356	15000	10210
Abril	5440	4386	11500	3820
MAPE (%)	33,42	16,61	67,29	-

Fonte: Elaborado pelo autor com base nos dados.

O modelo com intervenção é o melhor modelo univariado, principalmente em relação ao valor previsto pela empresa, mostrando que os modelos com intervenção fornecem informações adicionais, ou seja, as variações atípicas ocorridas nos meses de junho de 2003 (mês 10), março de 2004 (mês 19) e fevereiro de 2006 (mês 42).

4.1.5 Série representativa das vendas do produto E

Neste item, apresenta-se análise descritiva da série original e os correlogramas das funções de autocorrelação e autocorrelação parcial para a determinação do modelo que melhor se ajusta aos dados.

Tabela 5: Medidas descritivas do Produto E no período de março de 2002 a dezembro de 2006.

<i>Medidas descritivas do Produto E</i>	<i>Valores</i>
Média (Kg)	2103
Desvio Padrão (Kg)	1338
Coefficiente de Variação (%)	64

Fonte: Elaborado pelo autor com base nos dados.

A variação é em função do *outlier* existente no mês de setembro de 2003 (mês 19), quando houve um aumento percentual nas vendas em 175%, que, ao nível de significância de 5%, foi significativo. A Figura 36 representa o comportamento da série:




Figura 36: Comportamento da série original do volume mensal de vendas (kg) do Produto E.

Fonte: Elaborado pelo autor.

As Figuras 37 e 38 representam, respectivamente, a função de autocorrelação e a função de autocorrelação parcial da série de vendas do produto E.




Figura 37: Coeficientes da função de autocorrelação da série de vendas do produto E.

Fonte: Elaborado pelo autor.




Figura 38: Coeficientes da função de autocorrelação parcial da série de vendas do produto E.

Fonte: Elaborado pelo autor.

4.1.5.1 Modelo sem intervenção para as vendas do produto E

A Figura 36 apresenta o comportamento da série original representativa das quantidades mensais vendidas (em Kg) no período de março de 2002 a dezembro de 2006, do Produto E. Na Figura 36, observa-se que a série apresentou um outlier significativo ($p < 0,05$) no mês de setembro de 2003 (mês 19). Pelos correlogramas, pode-se dizer que ela se desenvolve no tempo aleatoriamente ao redor de uma média, podendo ser considerada estacionária. Quanto à variância, a série apresenta uma heterodasticidade constante, o que foi constatado através do teste F para um nível de significância de 5% para os subperíodos analisados. Os valores de F para os cinco subperíodos foram 5,76; 1,44; 1,58; 1,16; 2,19, enquanto que o valor de F para o primeiro período é $F_{5\%, 11, 10} = 2,9$, e para os outros quatro períodos é $F_{5\%, 11, 11} = 2,69$. Neste caso há a necessidade de se fazer transformação na série para estabilizar a variância em função do primeiro ano. A transformação que estabilizou a variância foi a logarítmica. A representação da série transformada se encontra na Figura 39.




Figura 39: Comportamento da série transformada do volume mensal de vendas (kg) do produto E.

Fonte: Elaborado pelo autor.

As Figuras 40 e 41 representam, respectivamente, a função de autocorrelação (que indica a ordem dos parâmetros de médias móveis) e a função de autocorrelação parcial (que indica a ordem dos parâmetros autoregressivos) da série transformada.




Figura 40: Coeficientes da função de autocorrelação da série transformada do produto E.

Fonte: Elaborado pelo autor.




Figura 41: Coeficientes da função autocorrelação parcial da série transformada do produto E.

Fonte: Elaborado pelo autor.

Assim, com base nestas informações o modelo ajustado sem intervenção SARIMA(0,0,2)x(1,0,0)₁₂ foi:

$$\hat{Y}_t = 1355,47 - 0,3885 a_{t-1} - 0,4323 a_{t-2} + 0,4732 Y_{t-12} + a_t$$

(27,49) (-2,89) (-2,89) (2,73)
(27,49) (-2,89) (-2,89) (2,73)

As estatísticas de Ajuste foram: $R^2 = 60\%$, o Critério de Informação de Akaike (AIC) = -2,54 e o Critério de Schwarz (BIC) = -2,48. O coeficiente de determinação apresentou um valor razoável, pois, quanto mais próximo de 100% ou do valor unitário, melhor a capacidade de previsão do modelo.

Pela análise dos coeficientes de autocorrelação pode-se observar pela figura 42 que todos os coeficientes estão dentro dos limites de confiança ($\pm 2\sigma$). Desta forma, a função de autocorrelação da série de resíduos não apresentou nenhuma *lag* fora dos limites de controle, indicando que o modelo gerou uma série de erros aleatórios, portanto, o modelo é adequado para a realização de previsões.




Figura 42: Coeficientes da função de autocorrelação da série de resíduos do produto E – modelo sem intervenção.

Fonte: Elaborado pelo autor.

4.1.5.2 Modelo com intervenção para as Vendas do Produto E

Foi encontrada uma intervenção significativa, referente a um *outlier* na observação 19, ou seja, setembro de 2003. O modelo representativo está apresentado na equação a seguir:

$$\hat{Y}_t = 6455 + \overset{(3,84)}{0,63} Y_{t-1} - \overset{(-1,99)}{0,28} Y_{t-2} - \overset{(-1,97)}{1925} I_{1,23} + a_t$$

As estatísticas de ajuste foram de $R^2 = 78\%$; $AIC = -3,32$ e $BIC = -3,17$, as quais foram melhores do que as encontradas através do modelo $SARIMA(0,0,2) \times (1,0,0)_{12}$ sem intervenção, pois o Coeficiente de Determinação passou de 60% para 78%, mostrando que o modelo com intervenção, por este critério, demonstra maior acurácia. Nos Critérios de Akaike e Schwarz, houve uma pequena piora do modelo sem intervenção para o modelo com intervenção, pois os valores afastaram-se do zero, valor ideal por estes parâmetros.

A função de autocorrelação da série de resíduos não apresentou nenhum ponto fora dos limites de controle. Isto indica que o modelo gerou uma série de erros aleatórios, portanto pode-se utilizar o modelo para fazer previsões, conforme Figura 43.




Figura 43: Coeficientes da função de autocorrelação da série de resíduos do produto E – modelo com intervenção.

Fonte: Elaborado pelo autor.

4.1.5.3 Previsão para as vendas do produto E

Foram calculadas as previsões para o período de janeiro a abril de 2007, pelos modelos sem intervenção, com intervenção e as previsões fornecidas pela empresa, que estão apresentados no Quadro 7.

O critério utilizado para escolher o melhor modelo de previsão foi o MAPE, que está apresentado no Quadro 7.

Quadro 7: Comparação do Método de Box & Jenkins com Intervenção e sem Intervenção com os Valores Previstos pela Empresa e as Vendas Reais (em Kg) do Produto E através do MAPE.

Meses 2007	Modelo sem Intervenção	Modelo com Intervenção	Valor Previsto pela Empresa	Venda Real do Produto E
Janeiro	980	740	1700	304
Fevereiro	1350	1120	1000	1092
Março	1189	1089	1500	1036
Abril	2470	2115	2600	2641
MAPE (%)	66,81	42,75	128,49	-

Fonte: Elaborado pelo autor com base nos dados.

O modelo com intervenção é o melhor modelo univariado, principalmente em relação ao valor previsto pela empresa. Novamente, verifica-se uma grande oportunidade da empresa melhorar a previsão de vendas, pois o atual método de previsão é o pior, uma vez que apresenta a menor acurácia ou o maior erro se comparado com os demais métodos.

4.1.6 Série representativa das vendas do produto H

Neste item, apresenta-se análise descritiva da série original e os correlogramas das funções de autocorrelação e autocorrelação parcial para a determinação do modelo que melhor se ajusta aos dados.


Tabela 6: Medidas descritivas do Produto H no período de março de 2002 a dezembro de 2006.

<i>Medidas descritivas do Produto H</i>	<i>Valores H</i>
Média (Kg)	1958
Desvio Padrão (Kg)	1533
Coefficiente de Variação (%)	78

Fonte: Elaborado pelo autor com base nos dados.

A variação é em função do *outlier* existente no mês de setembro de 2002 (mês 7), quando houve um aumento percentual nas vendas em 778%, que ao nível de significância de 5%, foi significativo.

A Figura 44 apresenta o comportamento da série original representativa das quantidades mensais vendidas do produto H (em Kg) no período de março de 2002 a dezembro de 2006.

**Figura 44: Comportamento da série original do volume mensal de vendas (kg) do Produto H.**

Fonte: Elaborado pelo autor.

Pelos correlogramas, Figuras 45 e 46, pode-se afirmar que a série não é estacionária tanto na média como na variância, pois os coeficientes das funções não tendem a zero rapidamente. Neste caso há a necessidade de se fazer transformação na série para estabilizar tanto a média como a variância.




Figura 45: Coeficientes da função de autocorrelação da série de vendas do produto H.

Fonte: Elaborada pelo autor.




Figura 46: Coeficientes da função de autocorrelação parcial da série de vendas do produto H.

Fonte: Elaborada pelo autor.

A Figura 47 apresenta a série com transformação logarítmica, aquela que melhor se adequou ao modelo de forma a estabilizar a variância.




Figura 47: Comportamento da série transformada (logaritmo) do volume mensal de vendas (kg) do Produto H.

Fonte: Elaborado pelo autor.

Analisando a função de autocorrelação da série transformada, Figura 48, verifica-se que a variância foi estabilizada, mas a média não ficou estacionária.




Figura 48: Coeficientes da função autocorrelação da série transformada (logaritmo) do produto H.

Fonte: Elaborada pelo autor.

Com o objetivo de estabilizar a média, será realizada uma diferenciação na série transformada, de ordem 12, conforme Figura 49.




Figura 49: Comportamento da série transformada (logaritmo e diferença) do volume mensal de vendas (kg) do Produto H.

Fonte: Elaborada pelo autor.

Observando-se as Figuras 50 e 51, pode-se afirmar que a série é estacionária na média e na variância, fornecendo como indicado o ajuste de um modelo ARIMA(1,1,1).




Figura 50: Coeficientes da função de autocorrelação da série transformada (logaritmo e diferença) para o produto H.

Fonte: Elaborada pelo autor.




Figura 51: Coeficientes da função de autocorrelação parcial da série transformada (logaritmo e diferença) do produto H.

Fonte: Elaborada pelo autor.

4.1.6.1 Modelo sem intervenção para as vendas do produto H

Assim, com base nas informações dos correlogramas, o modelo ajustado sem intervenção ARIMA(1,1,1) foi:

$$\hat{Y}_t = 1392,33 + \overset{(2,72)}{0,5397} Y_{t-1} + \overset{(2,01)}{0,1512} a_{t-1} + \overset{(1,97)}{a_t}$$

As estatísticas de Ajuste foram $R^2 = 60\%$, o Critério de Informação de Akaike (AIC) = -2,54 e o Critério de Schwarz (BIC) = -2,48, mostrando um coeficiente de determinação de 60%, que fica um pouco distante do valor ideal unitário, que proporcionaria uma melhor previsão.

Pela análise dos coeficientes de autocorrelação pode-se observar pela Figura 52 que todos os coeficientes estão dentro dos limites de confiança ($\pm 2 \sigma$), portanto o modelo é adequado para realização da previsão.




Figura 52: Coeficientes da função de autocorrelação da série de resíduos do produto H – modelo sem intervenção.

Fonte: Elaborada pelo autor.

4.1.6.2 Modelo com intervenção para as vendas do produto H

Foi encontrada uma intervenção significativa, referente a um outlier na observação 7, ou seja, setembro de 2002. O modelo representativo está apresentado na equação a seguir:

$$\hat{Y}_t = 2342,29^{(2,63)} + 0,3009^{(2,09)} Y_{t-1} + 1555 I_{1,7}^{(4,64)} + a_t$$

As estatísticas de ajuste foram de $R^2 = 78\%$; $AIC = -3,32$ e $BIC = -3,17$, as quais foram melhores do que as encontradas através do modelo ARIMA(1,1,1) sem intervenção, pois o coeficiente de determinação passou de 60% do modelo sem intervenção para 78% no modelo com intervenção.

A função de autocorrelação da série de resíduos, Figura 53, não apresentou nenhum ponto fora dos limites de controle ou intervalo de confiança. Isto indica que o modelo gerou uma série de erros aleatórios, portanto pode-se utilizar o modelo para fazer previsões.




Figura 53: Coeficientes da função de autocorrelação dos resíduos do produto H – modelo com intervenção.

Fonte: Elaborada pelo autor.

4.1.6.3 Previsão para as vendas do produto H

Foram calculadas as previsões para o período de janeiro a abril de 2007, pelos modelos sem intervenção, com intervenção e as previsões fornecidas pela empresa. O critério utilizado para escolher o melhor modelo de previsão foi o MAPE, apresentado no Quadro 8.

Quadro 8: Comparação do Método de Box & Jenkins com Intervenção e sem Intervenção com os Valores Previstos pela Empresa e as Vendas Reais (em Kg) do Produto H através do MAPE.

Meses 2007	Modelo sem Intervenção	Modelo com Intervenção	Valor Previsto pela Empresa	Venda Real do Produto H
Janeiro	3923	3537	2400	3215
Fevereiro	4897	4938	4800	6110
Março	4050	4033	7200	3971
Abril	4958	4977	6700	5845
MAPE (%)	14,56	11,40	35,68	—

Fonte: Elaborado pelo autor com base nos dados.

Novamente, verifica-se através do Quadro 8, a baixa acurácia da previsão de vendas da empresa. O modelo com intervenção é o melhor modelo univariado, principalmente em relação ao valor previsto pela empresa.

4.1.7 Série representativa das vendas do produto M

Neste item, apresenta-se a análise descritiva da série original e os correlogramas das funções de autocorrelação e autocorrelação parcial para a determinação do modelo que melhor se ajusta aos dados.

Tabela 7: Medidas descritivas do Produto M no período de agosto de 2003 a dezembro de 2006.

<i>Medidas descritivas do Produto M</i>	<i>Valores</i>
Média (Kg)	898
Desvio Padrão (Kg)	542
Coefficiente de Variação (%)	60

Fonte: Elaborado pelo autor com base nos dados

A variação é em função principalmente do *outlier* do mês de dezembro de 2005 (mês 29), quando houve uma redução nas vendas de 1105 kg, que, ao nível de significância de 5%, foi considerado significativo.

A Figura 54 apresenta o comportamento da série original representativa das quantidades mensais vendidas do produto H (em Kg) no período de agosto de 2003 a dezembro de 2006.

Observando-se as Figuras 55 e 56, dos gráficos da função de autocorrelação e autocorrelação parcial, pode-se afirmar que a série é estacionária na média e na variância, fornecendo como indicado, o ajuste de um modelo SARIMA(1,0,1)X(0,0,1)₁₂.




Figura 54: Comportamento da série original do volume mensal de vendas (kg) do Produto M.

Fonte: Elaborado pelo autor.




Figura 55: Coeficientes da função de autocorrelação da série de vendas do produto M.

Fonte: Elaborada pelo autor.




Figura 56: Coeficientes da função de autocorrelação parcial da série de vendas do produto M.

Fonte: Elaborada pelo autor.

4.1.7.1 Modelo sem intervenção para as vendas do produto M

11

Assim, com base nas informações dos correlogramas, Figuras 55 e 56, o modelo ajustado sem intervenção SARIMA(1,0,1)X(0,0,1)₁₂ foi:

$$\hat{Y}_t = 400,49 - 0,5830 Y_{t-1} + 0,5957 a_{t-1} - 0,7320 a_{t-12} + a_t$$

As estatísticas de Ajuste foram $R^2 = 57\%$, o Critério de Informação de Akaike (AIC) = -2,46 e o Critério de Schwarz (BIC) = -2,42. Novamente, o modelo sem intervenção apresentou um Coeficiente de Determinação um pouco baixo, pois o valor de 57% está um pouco longe do ideal, que é o valor unitário.

Pela análise dos coeficientes de autocorrelação, pode-se observar pela Figura 57 que todos os coeficientes estão dentro dos limites de controle ou intervalo de confiança de dois erros padrões ($\pm 2\sigma$), para um nível de significância de 5%. Desta forma, não há *lags* significativos na função de autocorrelação dos resíduos. Desta forma, a série é um ruído branco. Portanto, o modelo é adequado para fazer previsões.




Figura 57: Coeficientes de autocorrelação dos resíduos do produto M – modelo sem intervenção.

Fonte: Elaborada pelo autor.

4.1.7.2 Modelo com intervenção para as vendas do produto M

Foi encontrada uma intervenção significativa, referente a um *outlier* na observação 29, ou seja, dezembro de 2005. O modelo representativo está apresentado na equação a seguir:

$$\hat{Y}_t = 392,20 + \overset{(23,08)}{0,3682} a_{t-1} - \overset{(2,67)}{0,5568} a_{t-2} - \overset{(-6,524)}{1237} I_{1,25} + a_t$$

As estatísticas de ajuste foram de $R^2 = 78\%$, $AIC = -3,32$ e $BIC = -3,17$. As estatísticas do modelo com intervenção foram melhores do que as encontradas através do modelo SARIMA(1,0,1)x(0,0,1)₁₂ sem intervenção, pois o valor do Coeficiente de Determinação passou de 57% no modelo sem intervenção para 78% no modelo com intervenção, ficando mais próximo de 100%, que é o valor ideal para a obtenção de uma melhor previsão.

A função de autocorrelação da série de resíduos, Figura 58, não apresentou nenhum ponto fora dos limites de controle, indicando que o modelo gerou uma série de erros aleatórios, portanto pode-se utilizar o modelo para fazer previsões.




Figura 58: Coeficientes de autocorrelação da série de resíduos do produto M – modelo com intervenção.

Fonte: Elaborada pelo autor.

4.1.7.3 Previsão para as vendas do produto M

Foram calculadas as previsões para o período de janeiro a abril de 2007, pelos modelos sem intervenção, com intervenção e as previsões fornecidas pela empresa, que estão apresentados no quadro 9.

O critério utilizado para escolher o melhor modelo de previsão foi o MAPE, que está apresentado no Quadro 9.

Quadro 9: Comparação do Método de Box & Jenkins com Intervenção e sem Intervenção com os Valores Previstos pela Empresa e as Vendas Reais (em Kg) do Produto M através do MAPE.

Meses 2007	Modelo sem Intervenção	Modelo com Intervenção	Valor Previsto pela Empresa	Venda Real do Produto M
Janeiro	728	594	615	687
Fevereiro	509	438	500	316
Março	1180	1198	1050	1216
Abril	1098	1120	1050	1111
MAPE (%)	17,92	13,61	21,96	-

Fonte: Elaborado pelo autor com base nos dados.

O modelo com intervenção é o melhor modelo univariado, principalmente em relação ao valor previsto pela empresa, pois apresenta um Erro Médio Percentual Absoluto (MAPE) menor que os demais métodos. Ratifica-se que o modelo de previsão atual da empresa apresenta o maior erro em relação aos demais métodos de previsão analisados.

4.2 ANÁLISE QUALITATIVA

A análise qualitativa foi realizada em dois momentos. No primeiro, foram levantadas, por meio dos registros, as previsões utilizadas pelos responsáveis pela previsão de vendas da empresa, que estão apresentadas no Quadro 10.

Quadro 10 - Previsão da empresa quanto às vendas dos principais produtos (Kg) para o período de janeiro a abril de 2007.

Vendas 2007	A	B	C	D	E	H	M
Janeiro	7420	7800	2857	8740	1700	2400	615
Fevereiro	10000	12800	5000	11000	1000	4800	500
Março	7000	12800	5200	15000	1500	7200	1050
Abril	5000	11500	5000	11500	2600	6700	1050

Fonte: Elaborado pelo autor a partir dos dados fornecidos pela empresa.

No segundo momento, foi realizada uma entrevista com os responsáveis pelo planejamento da empresa, envolvendo o responsável pelo Departamento Comercial e o responsável pelo Planejamento, Programação e Controle da Produção. O Quadro 11, contém os fatores e os respectivos pesos relativos, que na opinião dos responsáveis, influenciam as vendas ou demanda do mercado. Na primeira coluna do quadro encontra-se o fator que influencia a demanda. Cada responsável colocou a sua opinião, listando quais os fatores que influenciam as vendas. Na segunda coluna, os responsáveis pelas previsões da empresa colocaram o peso que cada fator possui na demanda. Na terceira coluna, calculou-se o peso de cada fator em relação ao total, ou seja, o peso relativo de cada um, denominado PN ou peso Normalizado, conforme a equação nº 69 descrita a seguir:

$$PN = \frac{P_i}{\sum P_i} * 100$$

(69)

Na última coluna, a ser preenchida pelo responsável pela previsão de vendas da empresa, colocou-se a intensidade de manifestação de cada fator que influencia a demanda ou as vendas, de acordo com o item 2.4.4 deste trabalho. Os resultados obtidos encontram-se no Quadro 11.

Quadro 11 - Análise Qualitativa com os responsáveis pela previsão de vendas da empresa.

Fatores que influenciam a demanda	Responsável 1			Responsável 2		
	P	PN (%)	I	P	PN (%)	I
Preço do Produto	5	11,1 (5/45)	- 1	5	10,2 (5/49)	- 1
Disponibilidade do produto (Rapidez na entrega)	5	11,1 (5/45)	+ 1	5	10,2 (5/49)	+ 1
Concorrência no mercado de atuação	5	11,1 (5/45)	- 1	5	10,2 (5/49)	- 1
Sazonalidade dos produtos (épocas definidas de acordo com a estação)	4	8,9 (4/45)	0	5	10,2 (5/49)	0
Qualidade do produto	3	6,7 (3/45)	0	4	8,2 (4/49)	0
Suporte Técnico Pós-Venda	2	4,4 (2/45)	0	3	6,0 (3/49)	0
Customização dos produtos (clientes montam o produto de acordo com as suas necessidades)	5	11,1 (5/45)	+ 1	5	10,2 (5/49)	0
Inovação nos Produtos (desenvolvimento de novos produtos)	3	6,7 (3/45)	0	3	6,0 (3/49)	0
Atendimento de pedidos pequenos (baixa quantidade a ser produzida e vendida)	3	6,7 (3/45)	0	4	8,2 (4/49)	0
Quantidade de produtos e cores ofertados ao mercado	2	4,4 (2/45)	0	2	4,3 (2/49)	0
Crescimento do setor têxtil	4	8,9 (4/45)	0	4	8,2 (4/49)	0
Situação econômica do País (taxa de câmbio)	4	8,9 (4/45)	0	4	8,2 (4/49)	- 1
Total dos Pesos	45	100 %		49	100 %	

Fonte: Elaborado pelo autor.

Por exemplo, o responsável 1 (pela previsão de vendas da empresa), quantificou o preço como um fator de alta influência nas vendas. Assim, pela escala apresentada no item 2.4.4 deste trabalho, ele recebeu peso 5. O peso normalizado para cada fator é encontrado dividindo-se o peso atribuído ao fator pelo somatório de todos os pesos de cada um dos fatores (por isto, a indicação de 5/45, ou seja, 11,1% é atribuído ao fator preço). Na avaliação do mesmo responsável 1, a intensidade do impacto do preço nas vendas é alta e negativa, pois

o sinal negativo nos diz que quanto maior for o preço do produto, menor será a quantidade vendida segundo avaliação do responsável 1.

No caso da disponibilidade do produto, ou seja, entrega rápida do pedido ao cliente, o responsável entendeu que este fator é importante para as vendas recebendo peso 5, mas com intensidade igual a + 1, ou seja, quanto maior for a disponibilidade de produto ou mais rápido a empresa fornecer o produto ao cliente, maior será a quantidade vendida, pois este é um fator ganhador de pedido, sendo um diferencial competitivo para a empresa.

Após, multiplica-se o peso normalizado de cada fator pela intensidade do impacto de cada fator nas vendas para cada responsável. Somando-se o resultado da multiplicação do peso normalizado pela intensidade, para cada fator, obtém-se a média ponderada para cada responsável pela previsão da empresa.

Com a média ponderada calculada para cada fator, multiplica-se o percentual de ajuste pela média ponderada, para cada um dos responsáveis. Desta forma, calcula-se a média aritmética das médias ponderadas, obtendo-se o percentual médio de ajuste. Somando-se o valor +1 ao percentual médio de ajuste, obtém-se o índice a ser multiplicado pelo modelo combinado para que seja encontrado o modelo integrado.

4.3 MODELOS COMBINADOS

A combinação dos modelos quantitativos e qualitativos possibilita a obtenção de melhores resultados de previsão quando comparados à utilização de cada um dos métodos individualmente.

Para encontrar o modelo combinado, utilizou-se o método de Box & Jenkins como o modelo quantitativo e a previsão dos responsáveis pela previsão na empresa como o método qualitativo de previsão de vendas. Através da metodologia proposta por Granger (1980), através da combinação linear de previsões e utilizando os dois modelos de previsão acima citados, a previsão combinada é obtida através da equação nº 56, mostrada no item 2.4.3 deste trabalho:

$$\hat{Y}_{t+1}^c = \alpha \hat{Y}_{t+1}^{(1)} + (1 - \alpha) \hat{Y}_{t+1}^{(2)}$$

Conforme foi descrito no item 2.4.3, o valor de α é o peso dado à previsão 1, ou seja, o peso dado à previsão baseada no método Box & Jenkins, sendo que o peso dado à previsão 2, realizada pelos responsáveis pela empresa, será $(1 - \alpha)$.

É necessário calcularmos as variâncias dos erros das previsões a serem combinadas para encontrarmos o valor de α . Desta forma, utilizando o modelo de Box & Jenkins, que melhor descreve o comportamento da série de cada um dos produtos, os valores previstos pela empresa e os valores reais de vendas de cada um dos produtos para os meses de janeiro a abril de 2007, pode-se calcular a variância dos erros de cada um dos modelos, conforme equação nº 70 descrita a seguir:

$$\sigma_e^2 = \frac{\sum_{t=1}^n (Y_t - \hat{Y}_t)^2}{n - 2}$$

(70)

onde:

- σ_e^2 : Variância do erro da previsão;
- Y_t : Valor real de venda do produto;
- \hat{Y}_t : Valor estimado pelo método de previsão.

Com o cálculo das variâncias dos erros de previsão para cada um dos dois métodos, através da equação nº 70, pode-se determinar o valor do peso α . Quando os erros das duas previsões não estão correlacionados, o cálculo de α é obtido através da equação nº 59 do item 2.4.3 desta dissertação:

$$\alpha = \frac{\sigma_2^2}{\sigma_1^2 + \sigma_2^2}$$

Com o valor de α encontrado, procede-se o cálculo do modelo combinado, utilizando o método quantitativo e qualitativo, através da equação nº 56 deste trabalho. No item 4.5, Resultados Finais, será abordado um exemplo deste procedimento através da aplicação em um dos produtos analisados.

4.4 MODELOS INTEGRADOS

Para o cálculo do modelo integrado, é necessário determinar o ajuste da previsão combinada. Utilizando o Quadro 11, organizado a partir do levantamento e da quantificação dos fatores que influenciam as vendas dos produtos, elaborou-se o Quadro 12 de forma a exemplificar a forma do cálculo proposto:

Quadro 12 – Cálculo do Modelo Integrado.

Fatores que influenciam a demanda	Responsável 1	Responsável 2
	Peso Normalizado x Intensidade	Peso Normalizado x Intensidade
Preço do Produto	$0,111 \times -1 = -0,111$	$0,102 \times -1 = -0,102$
Disponibilidade do produto (Rapidez na entrega)	$0,111 \times +1 = +0,111$	$0,102 \times +1 = +0,102$
Concorrência no mercado	$0,111 \times -1 = -0,111$	$0,102 \times -1 = -0,102$
Sazonalidade dos produtos (épocas definidas de acordo com a estação)	$0,089 \times 0 = 0$	$0,102 \times 0 = 0$
Qualidade do produto	$0,067 \times 0 = 0$	$0,082 \times 0 = 0$
Suporte Técnico Pós-Venda	$0,044 \times 0 = 0$	$0,06 \times 0 = 0$
Customização dos produtos (clientes montam o produto de acordo com as suas necessidades)	$0,111 \times +1 = +0,111$	$0,102 \times 0 = 0$
Inovação nos Produtos (desenvolvimento de novos produtos)	$0,067 \times 0 = 0$	$0,06 \times 0 = 0$
Atendimento de pedidos pequenos (baixa quantidade a ser produzida e vendida)	$0,067 \times 0 = 0$	$0,082 \times 0 = 0$
Quantidade de produtos e cores ofertados ao mercado	$0,044 \times 0 = 0$	$0,043 \times 0 = 0$
Crescimento do setor têxtil	$0,089 \times 0 = 0$	$0,082 \times 0 = 0$
Situação econômica do País (taxa de câmbio)	$0,089 \times 0 = 0$	$0,082 \times -1 = -0,082$
Média Ponderada (Somatório da multiplicação do PN x I)	0	-0,184
Percentual de Ajuste (45%)	$0 \times 0,45 = 0$	$-0,184 \times 0,45 = -0,0828$
Percentual Médio de Ajuste	$(0 - 0,0828) / 2 = -0,0414$	
Cálculo da Previsão Final	$(-0,0414 + 1) \times \text{previsão combinada} = 0,96 \times \text{previsão combinada}$	

Fonte: Elaborado pelo autor.

4.5 RESULTADOS FINAIS

O produto C foi escolhido para a exemplificação da metodologia utilizada neste trabalho. No método quantitativo, foi escolhido o modelo de Box & Jenkins com intervenção porque apresentou o menor erro (menor MAPE), conforme Quadro 5. No método qualitativo, escolheu-se a previsão de vendas realizada pelos responsáveis pela empresa.

Para encontrar o modelo integrado ou combinado, a partir da metodologia proposta por Granger (1980), através da combinação linear de previsões é necessário calcular a variância dos erros de cada um dos modelos, conforme equação nº 70:

$$\sigma_e^2 = \frac{\sum_{t=1}^n (Y_t - \hat{Y}_t)^2}{n - 2}$$

onde:

- σ_e^2 : Variância do erro da previsão;

- Y_t : Valor real de venda do produto;

- \hat{Y}_t : Valor estimado pelo método de previsão.

Assim, para ao método de Box & Jenkins, tem-se:

$$\sigma_1^2 = \frac{(3351 - 3630)^2 + (4876 - 5042)^2 + (4436 - 4785)^2 + (5910 - 6000)^2}{4 - 2}$$

$$\sigma_1^2 = 585019,5$$

Para a previsão realizada pelos responsáveis da empresa, a variância do erro está calculada abaixo:

$$\sigma_2^2 = \frac{(3351 - 2857)^2 + (4876 - 5000)^2 + (4436 - 5200)^2 + (5910 - 6000)^2}{4 - 2}$$

$$\sigma_2^2 = 835604$$

Com a variância dos erros calculada para os dois métodos que compõem o modelo integrado, pode-se calcular o valor de α , através da equação nº 59:

$$\alpha = \frac{\sigma_2^2}{\sigma_1^2 + \sigma_2^2} = \frac{835604}{(585019,5 + 835604)} = 0,59$$

Aplicando-se o valor de α para a equação nº 56 e com os dados do Quadro 5, em que encontram-se os valores obtidos através do método Box & Jenkins e da previsão dos responsáveis, encontra-se o modelo combinado:

- Jan 07= 0,59 x 4289 + (1 - 0,59) x 2857= 3701,9 Kg;
- Fev 07= 0,59 x 5078 + (1 - 0,59) x 5000= 5046,0 Kg;
- Mar 07= 0,59 x 4432 + (1 - 0,59) x 5200= 4746,9 Kg;
- Abr 07= 0,59 x 4887 + (1 - 0,59) x 5000= 4933,3 Kg.

Para o cálculo do modelo integrado, basta aplicar o índice final de ajuste, calculado no Quadro 12, no modelo combinado. Desta forma, encontra-se o modelo integrado:

- Jan 07= 3701,9 x 0,96= 3553,8 Kg;
- Fev 07= 5046 x 0,96= 4844,2 Kg;
- Mar 07= 4746,9 x 0,96= 4557,0 Kg;
- Abr 07= = 4933,3 x 0,96= 4736,0 Kg.

Os demais produtos foram calculados da mesma forma que o demonstrado para o produto C. Os Quadros 13 a 18 mostram os resultados obtidos, comparando as previsões pelo modelo de Box-Jenkins com intervenção, modelo combinado, modelo integrado, os valores previstos pelos responsáveis pela previsão de vendas da empresa, as vendas reais dos produtos, bem como os valores do MAPE para os modelos de previsão.

Quadro 13: Comparação dos Métodos de Previsão de Vendas do produto A através do MAPE.

Meses 2007	Modelo com Intervenção	Modelo Combinado	Modelo Integrado	Previsão da Empresa	<i>Venda Real do Produto</i>
Janeiro	6780	6610,60	6346,18	7420	7634
Fevereiro	5266	5134,10	4929,08	10000	5201
Março	4972	4847,60	4653,90	7000	4590
Abril	4120	4016,20	3856,10	5000	3024
<i>MAPE (%)</i>	<i>14,25</i>	<i>13,27</i>	<i>12,75</i>	<i>53,23</i>	<i>-----</i>

Fonte: Elaborado pelo autor com base nos dados.

Quadro 14: Comparação dos Métodos de Previsão de Vendas do produto C através do MAPE.

Meses 2007	Modelo com Intervenção	Modelo Combinado	Modelo Integrado	Previsão da Empresa	<i>Venda Real do Produto</i>
Janeiro	4289	3701,90	3553,80	2857	3351
Fevereiro	5078	5046,00	4844,20	5000	4876
Março	4432	4746,90	4557,00	5200	4436
Abril	4887	4933,30	4736,00	5000	5910
<i>MAPE (%)</i>	<i>12,38</i>	<i>9,37</i>	<i>7,32</i>	<i>12,60</i>	<i>-----</i>

Fonte: Elaborado pelo autor com base nos dados.

Quadro 15: Comparação dos Métodos de Previsão de Vendas do produto D através do MAPE.

Meses 2007	Modelo com Intervenção	Modelo Combinado	Modelo Integrado	Previsão da Empresa	<i>Venda Real do Produto</i>
Janeiro	8691	8604	8259,84	8740	9139
Fevereiro	9450	9356	8981,76	11000	13226
Março	8356	8272	7941,12	15000	10210
Abril	4386	4342	4168,32	11500	3820
<i>MAPE (%)</i>	<i>16,61</i>	<i>16,94</i>	<i>18,26</i>	<i>67,29</i>	<i>-----</i>

Fonte: Elaborado pelo autor com base nos dados.

Quadro 16: Comparação dos Métodos de Previsão de Vendas do produto E através do MAPE.

Meses 2007	Modelo com Intervenção	Modelo Combinado	Modelo Integrado	Previsão da Empresa	<i>Venda Real do Produto</i>
Janeiro	740	759,20	728,83	1700	304
Fevereiro	1120	1117,60	1072,00	1000	1092
Março	1089	1097,20	1053,30	1500	1036
Abril	2115	2124,70	2039,71	2600	2641
<i>MAPE (%)</i>	<i>42,75</i>	<i>44,38</i>	<i>41,50</i>	<i>128,49</i>	<i>-----</i>

Fonte: Elaborado pelo autor com base nos dados.

Quadro 17: Comparação dos Métodos de Previsão de Vendas do produto H através do MAPE.

Meses 2007	Modelo com Intervenção	Modelo Combinado	Modelo Integrado	Previsão da Empresa	<i>Venda Real do Produto</i>
Janeiro	3537	3378	3242,88	2400	3215
Fevereiro	4938	4919	4722,24	4800	6110
Março	4033	4476	4296,96	7200	3971
Abril	4977	5218	5009,28	6700	5845
<i>MAPE (%)</i>	<i>11,40</i>	<i>12,00</i>	<i>11,52</i>	<i>35,68</i>	<i>-----</i>

Fonte: Elaborado pelo autor com base nos dados.

Quadro 18: Comparação dos Métodos de Previsão de Vendas do produto M através do MAPE.

Meses 2007	Modelo com Intervenção	Modelo Combinado	Modelo Integrado	Previsão da Empresa	<i>Venda Real do Produto</i>
Janeiro	594	591	567,4	615	687
Fevereiro	438	419	402,2	500	316
Março	1198	1197	1139,1	1050	1216
Abril	1120	1119	1064,2	1050	1111
<i>MAPE (%)</i>	<i>13,61</i>	<i>12,24</i>	<i>13,81</i>	<i>21,96</i>	<i>-----</i>

Fonte: Elaborado pelo autor com base nos dados.

O Quadro 19 mostra o comparativo dos métodos de previsão de todos os produtos analisados através do MAPE (Erro Médio Percentual Absoluto):

Quadro 19: Comparação da Acurácia entre os Modelos de Previsão de Vendas para os produtos analisados.

MAPE (%)	Modelo Box & Jenkins com Intervenção	Modelo Combinado	Modelo Integrado	<i>Previsão da Empresa</i>
Produto A	14,25	13,27	12,75	53,23
Produto C	12,38	9,37	7,32	12,60
Produto D	16,61	16,94	18,26	67,29
Produto E	42,75	44,38	41,50	128,49
Produto H	11,40	12,00	11,52	35,68
<i>Produto M</i>	<i>13,61</i>	<i>12,24</i>	<i>13,81</i>	<i>21,96</i>

Fonte: Elaborado pelo autor.

A previsão dos responsáveis pelo planejamento de vendas da empresa, sem dúvida, foi o método com a pior acurácia de todos os métodos analisados. Em todos os produtos analisados, o modelo integrado de previsão apresentou melhores resultados que a previsão dos responsáveis pela empresa.

Dos seis produtos analisados, três produtos (A, C e E) apresentaram o valor do MAPE para o modelo integrado menor do que o modelo com intervenção de Box-Jenkins. O modelo combinado apresentou três produtos (A, C e M) com maior acurácia (menor valor do MAPE) quando comparado com o modelo de Box & Jenkins com intervenção. Como nos modelos combinados foram utilizadas as previsões realizadas pela empresa, e estas apresentam uma grande discrepância em relação aos valores reais, mesmo que com pesos menores, essa variabilidade influenciou nos valores previstos pelo método combinado, prejudicando a previsão obtida através da combinação dos modelos.

Em todos os produtos, o modelo de Box & Jenkins com intervenção apresentou melhores resultados que o modelo sem intervenção, que não foi apresentado nos quadros 13 a

19, por isso optou-se em trabalhar com os modelos com intervenção devido ao menor erro de previsão obtido. Esta situação está de acordo com a teoria sobre os modelos com intervenção, a qual estabelece que estes modelos são capazes de captar mudanças de nível, mudanças na variação, bem como incorporar componentes sazonais (BOX; JENKINS; REINSEL, 1994).

Constatou-se que o modelo que incorpora a melhor previsão individual em sua construção apresenta desempenho superior às piores previsões individuais (MARQUES, 2005).

Ratifica-se a importância de um monitoramento do modelo encontrado para cada produto, de forma a reestimar o modelo quando necessário, conforme descrito no item 2.4.6 deste trabalho.

5 CONSIDERAÇÕES FINAIS

Os resultados obtidos nesta pesquisa mostram uma boa oportunidade para os gestores aumentarem a competitividade da empresa, através da utilização da metodologia de previsão de vendas. A forma atual de previsão de vendas, baseada unicamente na experiência dos responsáveis e alguns dados fornecidos pelos vendedores, foi aquela que apresentou a pior precisão, ou seja, o maior erro (MAPE) em todos os produtos analisados. Desta forma, a aplicação do modelo integrado de previsão, baseado no método quantitativo e qualitativo, apresentou maior acurácia na previsão de vendas para todos os produtos, quando comparado com a previsão realizada pela empresa, para o período de janeiro a abril de 2007.

Dos seis produtos analisados, o modelo integrado de previsão de vendas apresentou melhores resultados em três produtos (A, C e E) quando comparado com a metodologia de Box & Jenkins. O modelo combinado apresentou três produtos (A, C e M) com maior acurácia quando comparado com o modelo de Box & Jenkins com intervenção. Como o modelo combinado foi obtido através da combinação do modelo de Box & Jenkins com a previsão de vendas realizada pela empresa, e esta última apresentou maior erro de previsão ou menor acurácia, a previsão do modelo combinado acabou ficando prejudicada, pois incorporou parte deste erro. Se compararmos os modelos combinados e integrados com a metodologia de Box & Jenkins, os primeiros apresentaram melhores resultados em quatro (A, C, E e M) dos seis produtos analisados.

No atual cenário mundial, a competitividade ocasiona grandes transformações, seja no campo tecnológico, seja na gestão de negócios, exigindo das empresas uma atuação cada vez mais rápida no sentido de aperfeiçoar os níveis de serviços oferecidos, a partir de estruturas operacionais mais flexíveis, necessidade esta atrelada à premência de garantir um fator de diferenciação, principalmente quando os produtos de vários concorrentes possuem um mesmo grau de qualidade. Dentre as várias metodologias a serem utilizadas para enfrentar esta realidade, destacam-se os modelos de previsão de vendas buscando reforçar o processo de decisão e planejamento.

Assim, a previsão de vendas influencia todas as áreas da empresa, como por exemplo, nos custos com estoques, no nível de atendimento ao cliente, nos custos com *set-ups* de máquinas, nas expectativas da equipe de vendas, nos custos com atividades promocionais e

na gestão de pessoas. Uma previsão de vendas equivocada pode gerar grandes prejuízos para a empresa, com efeitos graves, muitas vezes pouco considerados pelas próprias empresas, tais como a perda de clientes, baixa produtividade na operação devido ao excessivo número de *set-ups* e alto estoque de matérias-primas e produtos semi-elaborados, gerando um ativo imobilizado elevado e causando perda de rentabilidade da empresa, com impacto negativo na competitividade da empresa no mercado. Neste sentido, foi desenvolvida esta dissertação com o objetivo de desenvolver um estudo para melhorar a atividade de previsão de vendas.

Através deste estudo de caso, foi possível aplicar os métodos de previsão de vendas a uma empresa do setor têxtil. Foram utilizados os métodos quantitativos e qualitativos com o objetivo de obter os melhores resultados quando comparados com o método qualitativo atualmente utilizado na empresa, ou seja, obtendo maior acurácia na implementação dos métodos em função da quantidade de dados disponíveis na empresa onde foi desenvolvido o trabalho.

Neste estudo foram identificados os principais produtos em termos de vendas do setor de fabricação de tecidos de malha feitos em máquinas circulares da empresa. Foi utilizada a metodologia de Box & Jenkins para identificar o modelo mais representativo dos dados históricos de vendas destes produtos. Com base nas previsões qualitativas utilizadas pela empresa e nas informações sobre o comportamento futuro das vendas por parte dos responsáveis pela previsão da empresa, foi possível encontrar um modelo combinado e fazer ajustes nas previsões a curto prazo para as vendas dos produtos analisados, obtendo-se assim, o modelo integrado de previsão de vendas.

Considerando a abordagem ARIMA univariada, pelo seu carácter exclusivo e não causal apenas permitir a descrição e a previsão de uma série temporal com base no seu comportamento passado, esta não consegue captar os efeitos exercidos sobre a sucessão por fenômenos exógenos (intervenções e *outliers*), que em certos casos conduzem a observações anômalas e mudam o seu comportamento.

Assim, a aplicação da metodologia da análise de intervenção, combinando as características dos modelos univariados com os efeitos determinísticos das intervenções e *outliers*, proporcionou uma considerável melhoria da qualidade do ajustamento dos modelos estimados, o que pode ser constatado pela melhoria nos critérios R^2 , AIC e BIC utilizados na escolha dos modelos, desempenhando um papel importante na explicação das séries representativas dos principais produtos analisados no estudo de caso.

O objetivo de construir modelos integrados de previsões é de que a incorporação de informações permite aumentar a precisão ou reduzir a incerteza associada a um modelo de previsão individual. Por exemplo, a utilização dos dados históricos permite, através do modelo quantitativo, por exemplo Box & Jenkins, prever o comportamento da série analisada, sendo que o método qualitativo pode detectar alterações no mercado que sejam importantes na previsão, como, por exemplo, a taxa cambial, a moda da estação, promoções de vendas da empresa. Desta forma, a integração dos métodos permite uma visão geral para a aplicação da previsão. Para responder a questão sobre a possibilidade de aumentar a precisão da previsão por meio da combinação, pode-se recorrer às conclusões de Makridakis; Winkler (1983) e Hibon; Evgeniou (2005). Estes autores afirmam que adotar uma integração é geralmente menos arriscado do que usar uma previsão individual.

Kleinmuntz (1990) afirma que há uma tendência das pessoas a evitarem combinações devido à crença de que se deve buscar sempre o melhor modelo. Entretanto, parece ser mais razoável seguir Zarnowitz (1984), que defende um contraponto a este comportamento, afirmando que, num determinado momento, a sorte pode contar tanto quanto a técnica para selecionar a melhor previsão, entretanto, a longo prazo, a combinação de bons modelos, técnica e algum grau de subjetividade resultam em melhor performance.

Em suma, ainda que os ganhos da combinação sejam limitados, os riscos associados ao se incorporar previsões de diferentes fontes a um modelo parecem ser baixos frente aos ganhos em absorver informações complementares, desde que tratadas de forma adequada.

Assim, pode-se ressaltar que os resultados aqui encontrados estão de acordo com Bates e Granger (1969), que afirmam que não há razões para se esperar que a melhor previsão possível seja produzida por uma combinação de previsões. Entretanto, Hibon e Evgeniou (2005) concluíram que, quando não se sabe qual o melhor método de previsão individual, incorre-se em menor risco ao selecionar combinações, mesmo que estas não sejam, em média, superiores à melhor previsão individual.

A metodologia aprimorada neste trabalho, com base em trabalhos já desenvolvidos na área, traz uma contribuição no campo científico no que diz respeito à utilização da escala de Likert na definição da pontuação atribuída a cada fator pelos responsáveis pelas previsões qualitativas, bem como, na definição do percentual de ajuste, a utilização da variação percentual entre as previsões qualitativas. Esta metodologia é de simples implementação e poderá ser utilizada por qualquer empresa, servindo como uma ferramenta útil para as

empresas em suas tomadas de decisões, a fim de fixar os níveis de produção, controlar estoques, bem como torná-las cada vez mais competitiva.

5.1 FUTUROS TRABALHOS

Como sugestão para futuros trabalhos propõe-se:

- Analisar individualmente os produtos vendidos quanto aos fatores que influenciam as vendas, melhorando o modelo ajustado;
- A utilização de um modelo de função de transferência, utilizando como variáveis de entrada informações do mercado, como, por exemplo, a moda, análise da renda per capita, a atuação do concorrente e a taxa cambial que alteram a demanda de tecido;
- Usar as cartas de controle de Shewhart para monitorar a estabilidade das previsões, tanto para as mudanças de nível quanto para as mudanças de variabilidade.
- Fazer comparações com os níveis de produção e de estoques, utilizando estes dados como informações;
- Utilizar as técnicas de *bootstrap*, como forma de aumentar a amostra representativa das previsões.

REFERÊNCIAS

AKAIKE, H. **Maximum likelihood identification of Gaussian autoregressive moving average models.** *Biometrika*, v. 60, p. 255-265, 1973.

_____. **A new look at the statistical model identification.** *IEEE Transactions on Automatic Control*, AC-19, p.716-723, 1974.

_____. **On entropy maximization principle.** In: *Applications of Statistics*, Amsterdam. Ed. P.R. Krishnaiah. p. 27-41, 1977.

ARMSTRONG, J. Scott. **Research Needs in Forecasting.** *International Journal of Forecasting*. v. 4, n. 3, p. 449-465, 1988.

BALLOU, Ronald H. **Gerenciamento da Cadeia de Suprimentos: planejamento, organização e logística empresarial.** 4 ed. Porto Alegre: Bookman, 2001.

BATES, J.M.; GRANGER, C.W.J. **The Combining of Forecasts.** *Operational Research Quarterly*, v. 20, n. 4, p. 451-468, 1969.

BLATTBERG, Robert C.; HOCH, Stephen J. **Database Models and Managerial Intuition: 50% Model + 50% Manager.** *Management Science*, v. 36, n. 8, p. 887-899, 1990.

BOPP, Anthony E. **On Combining Forecasts: Some Extensions and Results.** *Management Science*. v. 31. n. 12, p. 1492-1498, 1985.

BOX, George Edward P. & JENKINS, Gwilym M. **Time Series Analysis: Forecasting and Control.** San Francisco, 1970.

_____. **Time Series Analysis: Forecasting and Control.** Revised edition. San Francisco: Holden-Day, 1976.

BOX, George Edward P.; JENKINS, Gwilym M & REINSEL, Gregory C. **Time series analysis - forecasting and control.** 3. ed. New Jersey: Prentice Hall, 1994.

BOX, G.E.P. & TIAO, G.C. **Intervention analysis with applications to economic and environmental problems.** *Journal of the American Statistical Association*, 70, 70-79, 1975.

CAVALHEIRO, Darlene. **Método de Previsão de Demanda aplicada ao Planejamento da Produção de Indústrias de Alimentos, 2003.** Dissertação de Mestrado - Curso de Pós-graduação em Engenharia de Produção, UFRGS, Porto Alegre.

CERVO, Amado L.; BERVIAN Pedro A. **Metodologia Científica.** São Paulo: Prentice Hall, 2002.

CHAMBERS; John C.; MULLICK; Satinder K.; SMITH, Donald D. **How to Choose the Right Forecasting Technique.** *Harvard Business Review*, jul/agosto, p. 45-74, 1971.

CHANG, I.; TIAO, G. C.; CHEN, C. Estimation of Time Series Parameters in the Presence of Outliers, **Technometrics**, v.30, n. 2, 193-204. 1988.

CHRISTOPHER, Martin. **Logística e Gerenciamento da Cadeia de Suprimentos: Estratégias para a Redução de Custos e Melhoria de Serviços**. 1. ed. São Paulo: Pioneira, 2002.

CLEMEN, Robert T. Combining Forecasts: A Review and Annotated Bibliography. **International Journal of Forecasting**. v. 5, n. 4, p. 559-583, 1989.

COLLOPY, Fred; ARMSTRONG, J. Scott. Ruled-based Forecasting: Development and Validation of an Expert System Approach to Combining Time Series Extrapolations. **Management Science**. v. 38, n. 10, p. 1394-1414, 1992.

COOPER, Donald.R.; SCHINDLER, Pamela S. **Métodos de Pesquisa em Administração**. 7. ed. Porto Alegre: Bookman, 2003.

CORRÊA, Henrique L.; GIANESI, Irineu G.N.; CAON, Mauro. **Planejamento, Programação e Controle da Produção**. 4. ed. São Paulo: Atlas, 2001.

DAVIS, Mark M.; AQUILANO, Nicholas J.; CHASE, Richard B. **Fundamentos da Administração da Produção**. 3. ed. Porto Alegre: Bookman, 2001.

DIETZ, Thomas. Methods for analyzing data from Delphi panels: Some evidence from a forecasting study. **Technological Forecasting and Social Change**. v. 31, n. 1, p. 79-85, 1987.

EUCLIDES FILHO, Kepler. Supply chain approach to sustainable beef production from a Brazilian perspective. In: **Livestock Production Science** 90, 53–61, 2004.

FARINA, E.M.M.Q. Competitividade e Coordenação de Sistemas Agroindustriais: um ensaio conceitual. In: **Revista Gestão & Produção**, vol.6, n.3, 1999.

FERRAZ, J.C.; KUPFER, D; HAGUENAUER, L. **Made in Brazil**. Rio de Janeiro: Campus, 1996.

FLEURY, Paulo F.; WANKE, Peter; FIGUEIREDO, Kleber F. **Logística Empresarial: A Perspectiva Brasileira**. Coleção Coppead de Administração. Centro de Estudos em Logística (CEL).1 ed. São Paulo: Atlas, 2000.

_____. **Logística e Gerenciamento da Cadeia de Suprimentos: Planejamento do Fluxo de Produtos e dos Recursos**. Coleção Coppead de Administração. Centro de Estudos em Logística (CEL).1 ed. São Paulo: Atlas, 2003.

FOX, A. J. Outliers in Time Series. **Journal of the Royal Statistical Society**, Ser. B, 34, 350-363. 1972.

GEORGOFF, David M.; MURDICK, Robert G. Manager's Guide to Forecasting. **Harvard Business Review**. v. 64, n. 1, p. 110-120, Jan. 1986.

GIL, Antônio C. **Métodos e Técnicas de Pesquisa Social**. São Paulo: Atlas, 1995.

GRANGER, C.W. J. **Forecasting in business and economics**. In: New York Academic Press, p. 131-147, 1980.

HAIR, Joseph F. Jr.; ANDERSON, Rolph E.; TATHAM, Ronald L.; BLACK, William C. **Análise Multivariada de Dados**. 5. ed. Porto Alegre: Bookmann, 2005.

HARVEY, Andrew C. A unified view of statistical forecasting procedures. **Journal of forecasting**. v.3, p. 245-283. 1984.

HIBON, M.; EVGENIOU, T. To combine or not combine selecting among forecasts and their combinations. **International Journal of Forecasting**. v. 21, 1: 15-24.2005.

HUTH, William L.; EPPRIGHT, David R.; TAUBE, Paul M. The indexes of consumer sentiment and confidence: Leading or misleading guides to future buyer behavior. **Journal of Business Research**, v. 29, n. 3, p. 199-206, 1994.

KENNEDY, P.; HARRISON, R., KALITZANDOKANES, N. Analysing Agribusiness Competitiveness: The case of U.S. Sugar Industry. In: **International Food and Agribusiness Management Review**. v.1, n.2, 1998.

KLEINMUNTZ, B. Why we still use our heads instead of formulas: Toward and integrative approach. **Psychological Bulletin**, 107, 296-310, 1990.

KOTLER, Philip. **Administração de Marketing: análise, planejamento, implementação e controle**. 5. ed. São Paulo: Atlas, 1998.

LAKATOS, Eva Maria; MARCONI, Marina de Andrade. **Fundamentos de Metodologia Científica**. 3. ed. rev. e ampl. São Paulo: Atlas, 1996.

LJUNG, G. M. (1993). On Outlier Detection in Time Series. **Journal of the Royal Statistical Society**, v. 55, p.559-567, 1993.

LEMOS, Fernando O. **Metodologia para seleção de Métodos de Previsão de Demanda**, 2006. Dissertação de Mestrado - Curso de Pós-graduação em Engenharia de Produção, UFRGS, Porto Alegre.

MAKRIDAKIS, Spyros. Forecasting: its role and value for planning and strategy. **International Journal of Forecasting**. v. 12, n. 4, p. 513-537, Dec. 1996.

MAKRIDAKIS, Spyros; WINKLER, Robert. Averages of Forecasts: Some Empirical Results. **Management Science**, v. 29, n. 9, p. 987-996, 1983.

MAKRIDAKIS, Spyros; WHEELWRIGHT, Steven; HYNDMAN, Rob. **Forecasting: Methods and Applications**. 3. ed. New York: John&Sons, 1998.

MALHOTRA, Naresch K. **Introdução à Pesquisa de Marketing**. 4. ed. Porto Alegre, Bookman, 2007.

MARQUES, Eduardo Barrozo. **Combinação de Previsões de Índices Preços, 2005**. Dissertação de Mestrado. Escola de Pós-graduação em Economia. FGV, Rio de Janeiro.

MARTINS, Petrônio G.; LAUGENI, Fernando P. **Administração da Produção**. 2. ed. São Paulo: Saraiva, 2006.

MENEZES, E.M. & SILVA, E.L. **Metodologia da Pesquisa e Elaboração de dissertação**, 2001. 3ª edição revisada. Florianópolis: Laboratório de Ensino a Distância da UFSC. Disponível em: < <http://www.ead.ufms.br/marcelo/orienta/Metodologia> >. Acesso em: 03 abril 2006, 20:30.

MONKS, Joseph G. **Administração da Produção**. São Paulo: McGraw-Hill, 1987.

MONTGOMERY, Douglas C.; JOHNSON, Lynwood A. **Forecasting and time series analysis**. New York: McGrawHill, 1976.

MOREIRA, Daniel A. **Administração da Produção e Operações**. São Paulo: Pioneira Thomson Learning, 2004.

MORETTIN, Pedro A.; TOLOI, Clélia M. **Séries Temporais**. 2. ed. São Paulo: Atual, 1987.

OLIVEIRA, Sílvio L. **Tratado de metodologia científica**. 2. ed. São Paulo: Pioneira, 1999.

OZAKI, T. On the order determination of ARIMA models. **Applied Statistics**. V. 26, p. 290-301, 1977.

PELLEGRINI, Fernando R. **Metodologia para Implementação de Sistemas de Previsão de Demanda**, 2000. Dissertação de Mestrado - Curso de Pós-graduação em Engenharia de Produção, UFRGS, Porto Alegre.

PREBLE, John. Public Sector Use of the Delphi Technique. **Technological Forecasting and Social Change**. v. 23, n. 1, p. 75-88, 1983.

RINGUEST, Jeffrey L.; TANG, Kwei. Simple Rules for Combining Forecasts: Some Empirical Results. **Socio-Economic Planning Science**. v. 21, n.14, p. 239-243, 1987.

SAATY, T. L. **Método de Análise Hierárquica**. São Paulo: McGraw-Hill, 1991.

SAMOHIL, R. W. Measuring the Efficiency of an Informal Forecasting Process, **Foresight, International Institute of Forecasters**, 2006.

SANDERS, Nada R.; RITZMAN, Larry P. Judgmental Adjustment of Statistical Forecasts. In: ARMSTRONG, J. Scott. **Principles of Forecasting: a Handbook for Researches and Practitioners**. Boston: Kluwer Academic Publishers, 2001.

SEVERINO, Antonio J. **Metodologia do trabalho científico**. São Paulo: Cortez, 2002.

SILVA, Christian Luiz. Competitividade: mais que um objetivo, uma necessidade. **Revista Faebusiness**, n.1, nov. 2001.

SKINNER, C. Wickham. Manufacturing - The Missing Link in Corporate Strategy. **Harvard Business Review**. v. 47, n. 3, p. 136-145, May 1969.

SLACK, Nigel; CHAMBERS, Stuart; JOHNSTON, Robert. **Administração da Produção**. 2. ed. São Paulo: Atlas, 2002.

SOUZA, Reinaldo C.; CAMARGO, Maria E. **Análise e Previsão de Séries Temporais - Os Modelos Arima**. 2. ed. Rio de Janeiro: Gráfica e Editora Regional, 2004.

- SPIEGEL, Murray R. **Estatística**. 3. ed. São Paulo: Makron Books, 1993.
- STALK, George Jr. Time - The Next Source of Competitive Advantage. **Harvard Business Review**. v. 66, n. 4, p.41-51, Jul. 1988.
- STONER, James A. S., FREMAN, R.Edward. **Administração**. 8 ed. Rio de Janeiro: Prentice-Hall, 1999.
- TRIPODI, Tony et al. **Análise da pesquisa social: diretrizes para o uso de pesquisa em serviço social e em ciências sociais**. Rio de Janeiro: Francisco Alves, 1975.
- TSAY, R. S. Time Series Model Specification in the Presence of Outliers. **Journal of the American Statistical Association**, v. 81, n. 393, 132-141, 1986.
- TSAY, R. S. Outliers, Level Shifts, and Variance Changes in Time Series. **Journal of Forecasting**, v. 7, 1-20. 1988.
- VERGARA, S. **Projetos e Relatórios de Pesquisa em Administração**. 7 ed. São Paulo: Atlas, 2006.
- VOLLMANN, Thomas E.; BERRY, William L.; WHYBARK, David C. **Manufacturing planning and control systems**. 4. ed. New York: McGraw-Hill, 1997.
- WACKER, John G.; CROMATIC, Jane S. Adapting forecasting methods to the small firm. **Journal of Small Business Management**, S.I. , p. 1-7, July, 1979.
- WEBBY, Richard; O'CONNOR, Marcus. Judgmental and Statistical Time Series Forecasting: A Review of the Literature. **International Journal of Forecasting**, v. 12, n. 1, p. 91-118, 1996.
- WERNER, Liane; RIBEIRO, José Luis Duarte. Previsão de Demanda: Uma aplicação dos Modelos Box & Jenkins na Área de Assistência Técnica de Computadores Pessoais. **Revista Gestão & Produção**, v.10, n.1, p.47-67, abr.2003.
- _____. Modelo composto para prever demanda através da integração de previsões. **Revista Produção**, v. 16, n. 3, p. 493-509, Set./Dez. 2006.
- WRIGHT, George; LAWRENCE, Michael; COLLOPY, Fred. The Role and Validity of Judgment in Forecasting. **International Journal of Forecasting**. v. 12, n. 1, p. 1-8, 1996.
- WRIGHT, James; GIOVINAZZO, Renata. Delphi - Uma ferramenta de apoio ao planejamento prospectivo. **Caderno de Pesquisa em Administração**. São Paulo, v. 1, n. 12, p. 54-65, 2000.
- YIN, Robert **Case Study Research: design and methods**. London: Sage Publications, 1994.
- ZARNOWITZ, V. The accuracy of individual and group forecast from business Outlook surveys. **Journal of Forecasting**, v.3, p. 11-26, 1984.

