

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL  
ESCOLA DE ENGENHARIA  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE PRODUÇÃO

**Um modelo composto para  
realizar previsão de demanda  
através da integração da  
combinação de previsões e do  
ajuste baseado na opinião**

**TESE DE DOUTORADO**

**Liane Werner**

Porto Alegre, 2004

**UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL  
ESCOLA DE ENGENHARIA  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE PRODUÇÃO**

**Um modelo composto para realizar previsão de  
demanda através da integração da combinação de  
previsões e do ajuste baseado na opinião**

**Liane Werner**

**Orientador: Prof. José Luis Duarte Ribeiro, Dr.**

**Prof. Dinara Westphalen Xavier Fernandez, Dr.**  
Departamento de Estatística / UFRGS

**Prof. Flávio Sanson Fogliatto, Ph.D.**  
Programa de Pós-Graduação em Engenharia de Produção / UFRGS

**Prof. Teniza da Silveira, Dr.**  
Mestrado em Administração / Unisinos

Porto Alegre, dezembro de 2004.

**Esta tese foi julgada adequada para a obtenção do título de doutor em  
ENGENHARIA de PRODUÇÃO e aprovada em sua forma final pelo orientador e  
pela banca designada pelo Programa de Pós-Graduação Engenharia de Produção da  
Universidade Federal do Rio Grande do Sul.**

**Prof. José Luis Duarte Ribeiro, Dr.**  
PPGEP/UFRGS  
Orientador

**Prof. José Luis Duarte Ribeiro, Dr.**  
Coordenador do PPGEP/UFRGS

Banca Examinadora:

**Prof. Dinara Westphalen Xavier Fernandez, Dr.**  
Departamento de Estatística  
UFRGS

**Prof. Flávio Sanson Fogliatto, Ph.D.**  
Programa de Pós-Graduação em Engenharia de Produção  
UFRGS

**Prof. Teniza da Silveira, Dr.**  
Mestrado em Administração  
Unisinos

## DEDICATÓRIA

Dedico essa tese, a meu amado esposo, amigo e companheiro **Adilson da Silva Braga** e a meu amado filho **Cristiano Werner Araújo**, que tiveram paciência nos meus momentos de ansiedade e sabedoria para me apoiar nesta caminhada.

## AGRADECIMENTOS

Agradeço a DEUS, por Ele conceder-me sabedoria, maturidade e saúde para concluir o doutorado, por ter me cercado de pessoas prestativas e atenciosas que proporcionaram a obtenção deste título.

Sou grata ao meu orientador Prof. Dr. José Luis Duarte Ribeiro, que com sua paciência e suas grandiosas contribuições impulsionaram a elaboração e conclusão desta tese.

Agradeço aos meus pais por que ao longo de minha vida sempre me incentivaram ao estudo. Agradeço também ao meu esposo Adilson e a meu filho Cristiano que souberam compreender e aceitar o tempo que deixei de dedicar a eles, para realizar essa tarefa.

Agradeço aos Professores do Programa de Pós-Graduação de Engenharia de Produção que participaram na minha formação como doutora.

Ao Departamento de Estatística agradeço pelo inventivo e pelas dispensas a fim de que esta tese fosse concluída.

Agradeço também a Paulo Ckless e Julie Brum pelo tempo dispensado para que o estudo de caso fosse realizado.

Aos professores integrantes da Banca, agradeço por suas contribuições e correções que tornam esse trabalho mais rico.

Por fim, agradeço ao colega e amigo Júlio van der Linden pelos momentos agradáveis e de trabalho árduo que dividimos, a agradeço também a amiga Márcia Echeveste pelo apoio e incentivo.

## RESUMO

Realizar previsões de demanda é uma atividade importante para as empresas assegurarem sua participação nos mercados em que atuam. Sendo assim, essa atividade torna-se fundamental. Por outro lado, observa-se que o uso de uma única técnica para obter as previsões pode não ser suficiente para incorporar todo o conhecimento associado ao ambiente de previsão. As formas de integração de previsões incorporam várias técnicas e têm mostrado potencial para reduzir o erro de previsão e obter melhores estimativas. Este trabalho apresenta uma modelagem que está estruturada utilizando duas formas de integração de previsões: a combinação de previsões e o ajuste baseado na opinião. A combinação de previsões leva em conta a informação de vários elementos que influenciam o comportamento do mercado. Os elementos incluídos na modelagem proposta são: dados históricos; dados econômicos, e opinião de especialistas. Após obter-se a previsão combinada, aplica-se um ajuste baseado em especialistas para obter a previsão final. O modelo proposto é descrito em detalhes e ilustrado através de uma aplicação prática. Entre as vantagens do modelo proposto, destacam-se: (i) correta ponderação das previsões individuais, na medida em que considera o erro inerente a cada previsão; (ii) possibilidade de fornecer previsões mais robustas, devido ao uso de diversas fontes de informação; e (iii) indicação de procedimentos originais e estruturados para orientar os especialistas na realização de ajustes da previsão combinada.

**Palavras-chave:** Previsão de Demanda; Séries Temporais; Modelos de Regressão; Combinação de Previsões; Ajuste baseado em especialistas.

## ABSTRACT

Demand forecasting is an important task so that companies can be aware of their market share. Such activity becomes, therefore, essential. On the other hand, it has been observed that the use of a single technique to produce forecasts might not be enough to gather all the knowledge associated with the forecast environment. The way to integrate forecasts incorporates various techniques and resented potential to reduce forecast error as well as to achieve enhanced estimations. This study presents a model that relies on the use of two means of integration: forecast combination and judgmental adjustment. The combination of forecasts takes into account the acknowledgement of several elements that influence the market performance. The elements covered by the presented model are: historic data, economic data, and the opinion of experts. After obtaining the combined forecast, an adjustment based on the experts' opinion is applied to attain the final forecast. The model proposed is described in details and illustrated through a practical application. Among the advantages of the proposed model, the following are highlighted: (i) correct balancing of individual forecasts, since the error inherent to the each forecasting is considered; (ii) possibility of providing more robust forecasts due to the use of various sources of information; and (iii) indication of a new procedure to lead experts when performing adjustments in the combined forecast.

**Keywords:** Demand Forecasting; Time Series; Regression Models; Combination of Forecasts, Judgmental Adjustment.

## LISTA DE FIGURAS

Figura 1 – Equilíbrio de mercado.....	28
Figura 2 – Modelo de sistema de previsão com oito etapas.....	30
Figura 3 – Construção de modelo.....	55
Figura 4 – Decomposição baseada na opinião.....	56
Figura 5 – Combinação de previsões.....	57
Figura 6 – Estrutura de combinação de previsões .....	58
Figura 7 – Ajuste baseado na opinião .....	83
Figura 8 – Comparação de fatores .....	90
Figura 9 – Matriz de comparações e pesos relativos .....	91
Figura 10 – Hierarquia para ajuste da previsão.....	92
Figura 11 – Matriz de comparação e pesos relativos do fator economia - Nível 2.....	92
Figura 12 – Pesos combinados de cada nível e do nível 3 para cada fator.....	93
Figura 13 – Pesos compostos de cada nível .....	94
Figura 14 – Fator de ajuste.....	94
Figura 15 – Estrutura básica do modelo composto de previsão.....	98
Figura 16 - Modelo composto completo de previsão.....	100
Figura 17 – Obtenção da previsão estatística.....	106
Figura 18 – Obtenção da previsão econométrica.....	107
Figura 19 – Obtenção da previsão usando opinião de especialistas.....	108
Figura 20 – Gráfico de controle com comportamento não estacionário: padrão de crescimento temporário .....	110
Figura 21 – Exemplo hipotético para as opiniões de um especialista.....	115
Figura 22 – Número de atendimentos para clientes do tipo avulsos e sua tendência.....	121



Figura 23 – (a) Função de auto-correlação e (b) Função de auto-correlação parcial para o número de atendimentos de clientes do tipo avulsos.....	122
Figura 24 – (a) Função de auto-correlação e (b) Função de auto-correlação parcial para o modelo ARIMA(1,1,0) .....	123
Figura 25–Papel de probabilidade normal para os resíduos da regressão linear múltipla..	127
Figura 26 – Análise de resíduos contra os resíduos padronizados para a regressão linear múltipla.....	127
Figura 27 - Número de atendimentos e o preço do serviço em escala comparável.....	129
Figura 28 – Papel de probabilidade normal para os resíduos da regressão múltipla polinomial.....	129
Figura 29 – Análise de resíduos contra os resíduos padronizados da regressão múltipla polinomial.....	130
Figura 30 – Papel de probabilidade normal para os resíduos da regressão do modelo polinomial usando método dos mínimos quadrados generalizados.....	131
Figura 31 – Análise de resíduos contra os resíduos padronizados da regressão do modelo polinomial usando método dos mínimos quadrados generalizados.....	132
Figura 32 – Gráfico de controle de médias móveis dos erros absolutos de previsão para a previsão estatística.....	135
Figura 33 – Gráfico de controle de médias móveis dos erros absolutos de previsão para a previsão econométrica .....	136

## LISTA DE TABELAS

Tabela 1 – Medidas de acurácia.....	32
Tabela 2 – Tabela ANOVA um fator para comparar opinião de especialistas.....	109
Tabela 3 – Critérios de comparação para verificação do melhor modelo.....	123
Tabela 4 – Previsão de demanda através do modelo econométrico.....	132
Tabela 5 – Previsões de demanda através da opinião de especialistas.....	133
Tabela 6 – Valor dos pesos para as três previsões individuais.....	137
Tabela 7 – Pesos e opiniões dos especialistas para os fatores que influenciam a demanda.....	139

# SUMÁRIO

<b>CAPÍTULO 1 – INTRODUÇÃO .....</b>	<b>13</b>
1.1. COMENTÁRIOS INICIAIS .....	13
1.2. RELEVÂNCIA DO TEMA .....	14
1.3. OBJETIVOS .....	16
1.3.1. <i>Objetivo principal</i> .....	16
1.3.2. <i>Objetivos secundários</i> .....	17
1.4. JUSTIFICATIVA DA PESQUISA .....	17
1.5. MÉTODO DO TRABALHO .....	20
1.6. LIMITAÇÕES DO TRABALHO .....	22
1.7. ESTRUTURA DA TESE .....	23
<b>CAPÍTULO 2 – DEMANDA E TÉCNICAS DE PREVISÃO .....</b>	<b>25</b>
2.1. DEMANDA .....	25
2.1.1. <i>Visão geral da demanda</i> .....	25
2.1.2. <i>Visão econômica da demanda</i> .....	26
2.2. O SISTEMA DE PREVISÃO E SUAS TÉCNICAS .....	29
2.2.1. <i>Metodologia de Box-Jenkins</i> .....	34
2.2.2. <i>Análise de regressão</i> .....	42
2.2.3. <i>Opinião de especialistas</i> .....	48
<b>CAPÍTULO 3 – FORMAS DE INTEGRAÇÃO DE PREVISÕES .....</b>	<b>53</b>
3.1. COMBINAÇÃO DE PREVISÕES .....	56
3.1.1. <i>Introdução</i> .....	56
3.1.2. <i>Estudos de métodos objetivos de combinação</i> .....	59
3.1.3. <i>Estudos de métodos subjetivos de combinação</i> .....	75
3.1.4. <i>Considerações finais sobre combinação de previsões</i> .....	79
3.2. AJUSTE BASEADO NA OPINIÃO .....	82
3.2.1. <i>Uso de conhecimento acumulado</i> .....	86
3.2.2. <i>Métodos de ajuste</i> .....	89
<b>CAPÍTULO 4 – MODELO COMPOSTO DE PREVISÃO .....</b>	<b>97</b>
4.1. ETAPAS DE ESTRUTURAÇÃO DO MODELO COMPOSTO DE PREVISÃO .....	99
4.1.1. <i>Etapa 1 - Verificação da existência de dados e de especialistas</i> .....	99
4.1.2. <i>Etapa 2 - Obtenção das previsões individuais</i> .....	101
4.1.3. <i>Etapa 3 - Estudo da variância dos erros das previsões</i> .....	102
4.1.4. <i>Etapa 4 - Obtenção da previsão combinada</i> .....	103
4.1.5. <i>Etapa 5 - Verificação da necessidade de fazer ajuste</i> .....	104
4.1.6. <i>Etapa 6 - Obtenção da previsão final</i> .....	104
4.2. PROPOSTA DE CONSTRUÇÃO DO MODELO COMPOSTO DE PREVISÃO .....	104
4.2.1. <i>Etapa 1 - Como verificar a existência de dados e de especialistas</i> .....	105
4.2.2. <i>Etapa 2 - Como obter as previsões individuais</i> .....	106
4.2.3. <i>Etapa 3 - Como obter as variâncias dos erros das previsões</i> .....	108
4.2.4. <i>Etapa 4 - Como obter a previsão combinada</i> .....	109
4.2.5. <i>Etapa 5 - Como verificar se existe conhecimento entre os especialistas para fazer ajustes</i> .....	112
4.2.6. <i>Etapa 6 - Como obter a previsão final</i> .....	113
<b>CAPÍTULO 5 – APLICAÇÃO DO MODELO COMPOSTO: UM ESTUDO NA ÁREA DE ASSISTÊNCIA TÉCNICA DE COMPUTADORES PESSOAIS .....</b>	<b>116</b>
5.1. ETAPA 1 - VERIFICAÇÃO DA EXISTÊNCIA DE DADOS E DE ESPECIALISTAS .....	117
5.1.1. <i>Obtenção dos dados para a metodologia Box-Jenkins</i> .....	117
5.1.2. <i>Obtenção dos dados para a modelagem econométrica</i> .....	118
5.1.3. <i>Disponibilidade de especialistas com domínio do conhecimento</i> .....	119
5.2. ETAPA 2 - OBTENÇÃO DAS PREVISÕES INDIVIDUAIS .....	120
5.2.1. <i>Obtenção da previsão de demanda através da metodologia Box-Jenkins</i> .....	120

5.2.2. <i>Obtenção da previsão de demanda através da modelagem econométrica</i> .....	124
5.2.3. <i>Obtenção da previsão de demanda através da opinião de especialistas</i> .....	132
5.3. ETAPA 3 – ESTUDO DAS VARIÂNCIAS DOS ERROS DAS PREVISÕES .....	133
5.4. ETAPA 4 – OBTENÇÃO DA PREVISÃO COMBINADA .....	134
5.4.1 <i>Avaliação da estacionariedade das variâncias</i> .....	134
5.4.2 <i>Cálculo dos pesos</i> .....	137
5.4.3 <i>Cálculo da previsão combinada</i> .....	137
5.5. ETAPA 5 – VERIFICAÇÃO DA NECESSIDADE DE FAZER AJUSTE .....	138
5.6. ETAPA 6 – OBTENÇÃO DA PREVISÃO FINAL.....	138
5.7. DISCUSSÃO DO MODELO COMPOSTO COMPLETO.....	141
5.7.1. <i>Princípios gerais do modelo proposto</i> .....	141
5.7.2. <i>Vantagens do modelo proposto</i> .....	142
5.7.3. <i>Dificuldades no uso do modelo proposto</i> .....	143
5.7.4. <i>Generalidade do modelo proposto</i> .....	144
<b>CAPÍTULO 6 – CONSIDERAÇÕES FINAIS</b> .....	<b>146</b>
6.1. CONCLUSÕES .....	146
6.2. PESQUISAS FUTURAS .....	149
<b>REFERÊNCIAS</b> .....	<b>150</b>
<b>APÊNDICES</b> .....	<b>159</b>
<b>ANEXOS</b> .....	<b>164</b>

# Capítulo 1 – Introdução

## 1.1. Comentários Iniciais

No final do século passado, a globalização passou a ser uma palavra usual no mercado mundial. Em função desse movimento, as empresas que desejam manter sua posição no mercado internacional, ou mesmo em seus mercados locais, precisam, antes de tudo, analisar a situação em que estão inseridas e estar atentas aos rumos definidos pela globalização.

Neste cenário, a competitividade tem feito com que as empresas, sejam produtoras de bens ou de serviços, busquem novas alternativas, visando à qualidade e à produtividade, para assegurar sua participação nos mercados em que atuam. As exigências dos clientes e a grande concorrência induzem a analisar todos os possíveis pontos de melhoria dentro da empresa, buscando continuamente o atendimento das necessidades dos consumidores.

Uma das dimensões da competitividade no cenário de globalização é o atendimento das quantidades demandadas pelo cliente. Não é suficiente uma empresa ter boa imagem, ser reconhecida pela sua qualidade e apresentar custos competitivos, também é fundamental que uma empresa esteja estruturada para dimensionar a quantidade de bens ou serviços que irá produzir, de forma que possa atender à demanda proveniente do mercado consumidor.

Segundo Makridakis *et al.* (1998), realizar previsões de demanda é uma atividade importante, que auxilia na determinação dos recursos necessários para a empresa. Em tempos de abertura de mercados, essa atividade torna-se fundamental. Os mercados que podem ser atingidos pela empresa, bem como a concorrência que disputa esses espaços, mudam continuamente, exigindo novas previsões de demanda em períodos mais curtos. Além disso, a previsão da demanda está intimamente ligada à produção. O super

dimensionamento da produção agrega custos, além de gerar estoques que, por sua vez, geram outros custos. Uma previsão de demanda inferior às necessidades do mercado poderá abalar a imagem da empresa devido à falta do produto, reduzir lucros associados às vendas perdidas e, inclusive, gerar custos devido a multas contratuais.

Muitos são os métodos de previsão de demanda (MAKIDRAKIS *et al.*, 1998), contudo a grande maioria desses métodos analisa as informações utilizando uma única técnica de previsão, seja analisando as condições econômicas, através de modelos econométricos, seja analisando o que a empresa já realizou, através de séries temporais. Em tempos de globalização, uma única técnica pode não ser suficiente. Previsões confiáveis podem exigir a utilização de vários métodos, permitindo abranger a maior quantidade de informações disponíveis.

A base das informações para aplicar técnicas de previsão de demanda está dividida em dois grupos: as informações utilizadas nas técnicas qualitativas, que podem ser obtidas de especialistas que atuam ou conhecem o comportamento dos negócios da empresa, e as informações utilizadas nas técnicas quantitativas, técnicas que podem, ainda, ser subdivididas em modelos causais (econométricos) e em modelos que analisam o comportamento de séries temporais.

Estruturar uma metodologia que acomode as informações provenientes de dados históricos, dados econômicos e informações de especialistas podem auxiliar na construção de previsões mais confiáveis. Essas previsões, por sua vez, irão contribuir para que haja o atendimento às necessidades do mercado. Para tanto, é necessário desenvolver procedimentos que permitam agregar e ajustar diversas técnicas de previsão.

## **1.2. Relevância do Tema**

O tema desta tese de doutorado é a previsão de demanda de bens ou de serviços, considerando tanto abordagens qualitativas como quantitativas, através da utilização de formas de integração de previsões.

A produção e a oferta de bens e de serviços destinados a atender às necessidades do mercado relacionam-se nitidamente ao comportamento da demanda (PINDYCK &

RUBINFELD, 2002 e TROSTER & MOCHÓN, 1999). Portanto, para o setor produtivo, torna-se evidente a importância do estudo da demanda. Somente após a comprovação da existência da demanda haverá o interesse econômico pela produção de certo produto ou pela prestação de dado serviço.

A identificação de oportunidades de mercado necessita que sejam mensurados e previstos o tamanho, o crescimento e o potencial do lucro de cada oportunidade. Para atender e gerenciar estas necessidades, é preciso realizar previsões de demanda. Conforme Pellegrini & Fogliatto (2000), previsões de demanda desempenham um papel-chave em diversas áreas da gestão das organizações. Assim, o departamento financeiro levanta os recursos necessários aos investimentos e operações para que o departamento de manufatura defina os níveis de produção; para que o departamento de compras adquira o volume correto de suprimentos e o departamento de recursos humanos planeje adequadamente o número de operadores necessários.

Como o funcionamento da organização está intimamente ligado à previsão da demanda, esse depende, conseqüentemente, da maneira como ela será obtida. As formas de integração de previsões têm mostrado potencial para reduzir o erro de previsão e obter suas melhores estimativas. Porém a questão fundamental é como as técnicas quantitativas (estatísticas) e qualitativas (julgamento humano) podem contribuir para que o processo de previsão possa ser melhor integrado (GOODWIN, 2002).

Para Makridakis & Winkler (1983), previsões geradas por uma certa técnica podem fornecer informações que outras técnicas de previsão não geram. Assim, parece razoável considerar informações provenientes de várias técnicas, combinando essas previsões segundo algum procedimento específico. Em um vasto levantamento, realizado por Clemen (1989), sobre a forma de integração de previsões conhecida por combinação, é possível observar que a combinação de previsões (previsões quantitativas aliadas a previsões qualitativas) pode gerar resultados superiores quando do uso de técnicas individuais. Outra forma de integração bastante comum, na prática, é o ajuste baseado na opinião; nesse caso, parte-se simplesmente de uma previsão para, então, realizar-se um ajuste, baseado em informações do próprio ambiente. Cabe ressaltar que, na combinação de previsões pode-se utilizar uma previsão qualitativa, que consiste de uma previsão obtida usando informações de especialistas. Porém esta é diferente da forma de integração de

previsão ajuste baseado na opinião, onde a opinião de especialistas é utilizada para fazer o ajuste da previsão (individual ou combinada).

Em termos de uso, o ajuste baseado na opinião parece ser a principal alternativa para competir com a combinação de previsões, visando integrar previsões objetivas e subjetivas. Contudo existe uma lacuna de estudos comparativos entre estas duas abordagens (WEBBY & O'CONNOR, 1996). A existência dessa lacuna, além de outras dificuldades como, por exemplo, de que maneira compor estas duas formas de integração para melhorar as previsões, confirmam a relevância deste trabalho.

### **1.3. Objetivos**

#### **1.3.1. Objetivo principal**

Esta tese tem como objetivo principal estruturar um método para modelar e prever a demanda a curto prazo, considerando a informação de vários elementos que influenciam o comportamento do mercado. Os elementos a serem incluídos na modelagem são: dados históricos, que indicam o comportamento da demanda em tempos passados; dados econômicos, que podem estar associados ao comportamento da demanda e dados de especialistas da área do negócio, que prestam informações que irão compor a previsão da demanda, além de realizarem ajustes na previsão combinada, a fim de obterem a previsão final.

Para estruturar esta modelagem, serão utilizadas duas formas de integração de previsões: a combinação de previsões e o ajuste baseado na opinião. Para compor a combinação de previsões será utilizada, em cada um dos segmentos, uma das várias técnicas disponíveis. Para a análise de dados históricos, será utilizada a metodologia *Box-Jenkins*; para a análise de dados econômicos, serão utilizados modelos obtidos pela análise de regressão e, para a opinião dos especialistas, serão realizadas entrevistas individuais, as quais serão analisadas de acordo com técnicas pertinentes a este tipo de dado.



### 1.3.2. Objetivos secundários

Entre os objetivos secundários desta tese, pretende-se proceder com uma revisão atualizada sobre técnicas de previsão, métodos objetivos e subjetivos de combinação e ajuste de previsões, permitindo concluir a respeito dos métodos que proporcionam melhor desempenho na acurácia das previsões.

Além disso, outro objetivo secundário é apresentar um estudo de caso onde será aplicada a modelagem proposta. O estudo de caso refere-se à previsão da demanda de uma empresa de assistência técnica de computadores pessoais. Através do estudo de caso, será possível avaliar a viabilidade da utilização da modelagem proposta.

## 1.4. Justificativa da Pesquisa

Face ao mundo em constante evolução, em que é necessário encontrar melhores alternativas para administrar as mais diversas situações, a tomada de decisão precisa ser planejada. Para um planejamento efetivo, é importante avaliar quais eventos irão ocorrer e quando. Como a previsão de demanda é um destes eventos, é fundamental, para tomar as decisões adequadas, conhecer e utilizar metodologias que auxiliem o processo de previsão.

Conforme Wright *et al.* (1996), entre os pesquisadores que estudam o processo de previsão há um crescente interesse pela interação entre os modelos estatísticos e a opinião dos especialistas. Aparentemente, muitas são as razões para tal crescimento. A mais importante é o desejo de incorporar mais conhecimento, referente ao ambiente de previsão, na própria previsão. Uma vez que freqüentemente os especialistas têm conhecimento sobre eventos recentes que não foram observados nos dados, estas informações podem ser incorporadas à previsão; porém os especialistas podem introduzir algum tipo de viés, devido a sua subjetividade. Os modelos estatísticos são menos propensos ao viés e podem extrair muitas informações dos dados coletados no passado, mas se limitam a essas informações. Desta forma, incorporar estes dois tipos de informação pode melhorar a previsão. A incorporação desse conhecimento pode ocorrer através da utilização de combinação de previsões e/ou ajuste baseado na opinião.

Para Armstrong (2001a), a combinação de previsões é mais efetiva quando as previsões combinadas trazem diferentes tipos de informação para o processo de previsão e não estão correlacionadas. Assim, parece interessante combinar previsões provenientes de várias técnicas de previsão. Na prática, previsões baseadas na opinião são rotineiramente combinadas com outras previsões. Esta combinação pode ser completamente informal, como, por exemplo, quando um executivo julga e modifica a previsão antes de aprová-la, previsão esta, que pode ser de uma fonte quantitativa ou de opinião. Alternativamente, a combinação pode ser formal, quando um grupo de executivos é solicitado a preparar uma previsão, a qual é combinada em uma reunião ou através do cálculo da média aritmética das previsões (LAWRENCE *et al.*, 1986). Independente do modo como a combinação de previsões será obtida, seu resultado traz um aumento da acurácia sobre as previsões individuais (CLEMEN, 1989).

Em um levantamento realizado por Armstrong (1984), onde o autor realizou uma busca sobre estudos publicados que comparavam modelos de previsão. Neste levantamento foram encontrados e analisados 39 estudos, dos quais 13 envolviam modelos *Box-Jenkins*. Desses 13, em 4 os modelos *Box-Jenkins* foram mais acurados que técnicas simples; em 8 estudos, os modelos *Box-Jenkins* não apresentaram diferenças significativas na comparação da acurácia com relação a técnicas simples, e em apenas 1 estudo técnicas simples foram mais acuradas que modelos *Box-Jenkins*. Conclui-se, assim, que os modelos *Box-Jenkins* trazem informações úteis para aumentar a acurácia da combinação.

Para Makridakis (1989), os modelos *Box-Jenkins* analisam séries temporais univariadas, não permitindo a inclusão de outras informações no modelo de previsão. Muitas vezes, porém, existem outros dados que podem auxiliar a previsão de séries de interesse, tais como informações sobre feriados, greves, mudanças da legislação ou alguma outra variável que pode auxiliar no aumento da acurácia da previsão. Uma solução para este problema é combinar modelos de regressão com modelos *Box-Jenkins*.

Ainda segundo Makridakis (1989), modelos econométricos são ferramentas valiosas para aumentar o entendimento da forma como um sistema econômico trabalha e para testar e avaliar políticas alternativas. Contudo Nelson (1972) mostrou que certas previsões econométricas são ineficientes e que o procedimento de combinar previsões

econométricas com modelos *Box-Jenkins* pode reduzir significativamente os erros de previsão.

De acordo com Sanders & Ritzman (1990), os especialistas têm profundo conhecimento do ambiente de previsão e introduzem novas informações não-disponíveis através das técnicas quantitativas. Para Makridakis (1989), a acurácia de previsões por opinião é, em média, inferior à das previsões estatísticas. Edmunson *et al.* (1988) e Fildes (1991), entretanto, mostraram que previsões subjetivas, as quais utilizam informações do ambiente de previsão, são significativamente mais acuradas que previsões objetivas. Tal contradição revela que o cenário, em que as previsões subjetivas apresentam um desempenho superior, precisa ser melhor delineado, tal assunto será abordado no Capítulo 3.

O julgamento humano apresenta numerosos vieses, tal como inconsistência ou correlações ilusórias. Além disso, as pessoas têm uma capacidade de processamento limitada. Padrões consistentes, componentes estruturados da previsão, parecem ser capturados melhor pelas técnicas quantitativas formais. Ao mesmo tempo, mudanças ambientais e informações internas da empresa são componentes não-estruturados da previsão, que requerem interpretação e julgamento (SANDERS & RITZMAN, 1990).

Segundo Winkler (1989), os modelos estatísticos certamente são importantes, mas existem também muitas situações nas quais informações subjetivas podem ser igualmente importantes, e agregar essas informações é o melhor caminho. Contudo, por causa da habilidade do julgamento humano para incorporar informações adicionais e detectar mudanças, os especialistas deveriam ajustar previsões (WILLEMAIN, 1989).

Desta forma, a composição entre as formas de integração - combinação de previsões e ajuste baseado na opinião - indica uma maneira de utilizar toda a informação disponível, seja utilizando como estrutura básica os modelos estatísticos e/ou econométricos, seja através da opinião de especialistas, a fim de compor uma previsão mais refinada.

## 1.5. Método do Trabalho

Para elaborar esta tese, foi utilizado o método de pesquisa científica classificado por Cervo & Bervian (2002) como Pesquisa Aplicada. Na concepção dos autores, o investigador que faz uso da pesquisa aplicada é movido pela necessidade de contribuir para fins práticos, buscando soluções para problemas concretos. Em qualquer tipo de pesquisa, ainda segundo esses autores, é necessário realizar uma revisão bibliográfica prévia, a fim de fundamentar teoricamente o trabalho e de justificar os limites e contribuições da própria pesquisa. Isto posto, a pesquisa documental realizada, aliada à experiência obtida junto ao estudo de caso, trouxe subsídios para a construção de um modelo composto de previsão de demanda.

A primeira etapa consistiu no levantamento do referencial teórico sobre o tema da tese, que envolve (i) demanda e (ii) técnicas de previsão. Após, foi estruturado o modelo proposto, que considera várias bases de informações, constituídas por dados históricos, dados econômicos e dados de especialistas. Como tais bases de informações influenciam o comportamento do mercado, elas constituem a previsão-base do modelo proposto. Para subsidiar a construção do modelo, foi realizada uma revisão bibliográfica sobre as técnicas de previsão que podem sustentar cada uma dessas bases de informações. A metodologia *Box-Jenkins* foi utilizada para prever o comportamento da demanda com base nos dados históricos. Empregou-se a análise de regressão para modelar e prever a demanda no contexto de dados econômicos, e a opinião de especialistas foi obtida através de entrevistas, para prever a demanda a partir da percepção subjetiva daqueles que estão envolvidos no ambiente do negócio.

A próxima etapa consiste em obter as previsões individuais, para cada uma das bases de informação. Após, é necessário que essas informações sejam combinadas, compondo, assim, uma previsão intermediária, a qual é objeto de um ajuste baseado na opinião, gerando a previsão final. Para atingir tal etapa, foi preciso realizar um levantamento do referencial teórico sobre as formas de integração (i) combinação de técnicas de previsão e (ii) ajuste baseado na opinião.

A literatura referente às técnicas de previsão é vasta, e algumas delas estão fortemente consolidadas. Por outro lado, pesquisas associadas às formas de integração de

previsões estão em patamares diferenciados. A combinação de previsões possui ampla literatura, contudo, conforme esta, não há consenso sobre a melhor combinação a ser usada em qualquer situação de previsão. As pesquisas com ajuste baseado na opinião, por sua vez, ainda são incipientes. Por fim, reunir estas duas formas de integração para obter uma previsão mais acurada consiste apenas em uma sugestão de pesquisadores da área. Tais colocações subsidiam e reforçam a necessidade de buscar novas formas de previsão, justificando a proposição dessa modelagem.

Portanto, o modelo proposto consiste em obter a previsão individual para cada uma das três bases de informação: (i) através da metodologia de *Box-Jenkins*; (ii) através da análise de regressão, para obter um modelo econométrico e (iii) através de entrevistas, para captar a opinião de especialistas. Após, gera-se uma nova previsão, resultado da combinação destas previsões individuais. Com a previsão combinada, utiliza-se a forma de ajuste baseado na opinião (dos especialistas) para obter a previsão final. A utilização da opinião de especialistas em dois momentos distintos – na realização da previsão subjetiva e no ajuste baseado na opinião – se deve ao fato de que cada grupo contribui com um enfoque diferente, enquanto os especialistas que realizam a previsão subjetiva visam focar o comportamento global da área em estudo, os especialistas que realizam o ajuste baseado na opinião se ocupam em contemplar as informações específicas provenientes do mercado, como por exemplo, que o estoque de determinado cliente está acabando.

Para avaliar o método proposto foi realizado um estudo de caso, sendo que seus resultados foram analisados e discutidos. A aplicação do modelo foi feita na área de assistência técnica de computadores pessoais. Este área foi escolhida porque apresenta um comportamento complexo, sujeito a inúmeras variações de demanda, em função de inovações tecnológicas e de oscilações na taxa de câmbio.

Com estas etapas concluídas, foi possível tecer comentários finais, sumarizando os pontos importantes vivenciados durante a execução desta tese e propondo idéias para pesquisas futuras.

## 1.6. Limitações do Trabalho

Essa tese limita-se a propor um método de previsão de demanda através da integração de previsões, tendo como base a combinação de modelos *Box-Jenkins*, modelos econométricos e opinião de especialistas, além do ajuste baseado na opinião. Verificar qual a melhor técnica a ser utilizada nas previsões objetivas (modelos *Box-Jenkins* e modelo econométrico) não é o escopo desta tese, mas é preciso ressaltar que, dentro de cada classe, por exemplo, dos modelos *Box-Jenkins*, é utilizado o modelo que apresenta o melhor desempenho. Já para a previsão subjetiva, baseada na opinião de especialistas, foram utilizadas as informações disponíveis no estudo de caso, uma vez que as alternativas para o tratamento de dados qualitativos são mais abrangentes e flexíveis.

É importante ressaltar que esta tese se limita a utilizar técnicas de previsões clássicas, isto é, não considera previsores bayesianos.

Outro ponto que cabe ressaltar é que esta tese visa a integrar previsões, ou seja, serão operacionalizadas as estimativas das previsões. O foco não é integrar modelos.

Outra limitação é não considerar o fator custo na análise. Apesar do custo ser ponto fundamental na tomada de decisão referente à escolha da técnica de previsão mais adequada, essa tese se limitará a cuidar das observações sobre custos levantadas por Mahmoud (1989): enquanto a combinação de previsões quantitativas, em geral, adiciona pouco custo sobre os custos da produção de previsões individuais, este não é o caso da previsão por opinião, onde os custos podem ser substanciais.

Já no início dos anos 90, Sanders & Ritzman (1990) declararam que numerosos procedimentos de previsão estavam implementados em computadores e disponíveis para os previsores. Para realizar a combinação de previsões, foram desenvolvidos alguns algoritmos como, por exemplo, o AFTER, proposto por Zou & Yang (2004). Apesar da escassez de algoritmos, essa tese não tem por objetivo utilizar, analisar ou comparar qualquer tipo de procedimento computacional que realiza a tarefa de integrar previsões.

Zotteri & Verganti (2001) citam que recentes estudos têm mostrado demandas regulares transformando-se em demandas irregulares e complexas. A análise desse tipo de

demanda requer uma abordagem adequada. No entendimento dos autores, é possível administrar tal incerteza através da obtenção de informações diretamente com os consumidores. O estudo previsão de demanda com foco no consumidor não é o alvo dessa tese.

Outro ponto relevante para realizar previsão de demanda, segundo Tagliacarne (1978), diz respeito a um novo produto que se pretenda fabricar, pois é preciso conhecer e prever a demanda com vistas aos investimentos que devem ser feitos, por exemplo, em aquisição de máquinas e de matéria-prima. Estudar o comportamento de previsões e integração de previsões em novos produtos também não faz parte do escopo dessa tese.

## 1.7. Estrutura da Tese

A tese será subdividida em seis capítulos, discriminados a seguir.

O **capítulo 1** é introdutório, apresentando as considerações iniciais, a relevância do tema, os objetivos da pesquisa, a justificativa da pesquisa, o método de trabalho, a estrutura da pesquisa, bem como o escopo e as limitações da tese.

O **capítulo 2** é constituído por uma revisão bibliográfica sobre demanda. Além dessa revisão, também são apresentadas as técnicas de previsão, sendo as principais classes de técnicas de previsão explicitadas. Ainda nesse capítulo, é apresentada uma revisão das técnicas que darão suporte à forma de integração combinação de previsões: a metodologia de *Box-Jenkins*; a análise de regressão, que será utilizada para estimar o comportamento de modelos econométricos e a opinião de especialistas, obtida através de entrevistas.

O **capítulo 3** apresenta a integração de previsões. É realizado um levantamento a respeito das formas de realizar as integrações, sendo abordados mais profundamente os métodos de combinação de previsões, objetivo ou subjetivo, bem como quais os métodos que proporcionam maior acurácia na previsão. Ainda nesse capítulo, são abordados a forma de integração do ajuste baseado na opinião e os tipos de viés que podem ser introduzidos com sua aplicação.

O **capítulo 4** apresenta os passos de desenvolvimento da modelagem de previsão de demanda proposta nesta tese. Em um primeiro momento, são apresentados os passos para combinar metodologia *Box-Jenkins*, modelos econométricos e opinião de especialistas, bem como a verificação da necessidade de realizar ajuste baseado na opinião. Em um segundo momento, é mostrado como os passos devem ser executados para compor as duas formas de integração de previsões.

O **capítulo 5** apresenta um estudo de caso. Seguindo a modelagem proposta, primeiramente é obtida a previsão da demanda através da metodologia *Box-Jenkins*; após, através de modelos econométricos e, finalmente, através da opinião de especialistas. Em seguida, é verificado o comportamento das variâncias das previsões, a fim de estabelecer a forma como será obtida a previsão combinada, a qual poderá ser ajustada pela opinião dos especialistas, conduzindo à previsão final. Este capítulo também apresenta uma discussão sobre o desempenho da modelagem proposta.

O **capítulo 6** refere-se às considerações finais, contendo as principais conclusões obtidas ao longo do trabalho e algumas sugestões para futuras pesquisas.



## Capítulo 2 – Demanda e Técnicas de Previsão

### 2.1. Demanda

#### 2.1.1. Visão geral da demanda

É possível conceituar procura ou demanda como sendo a quantidade de determinado bem ou serviço que um consumidor eventual está disposto a adquirir por determinado preço, em determinado período de tempo em certa área geográfica. Quando se considera o comportamento da coletividade, tem-se o conceito de demanda de mercado. Nesta visão, Sandhusen (1998) definem demanda de mercado como “o volume total comprado em uma área geográfica específica por um grupo de clientes específicos em uma época específica sob um programa de *marketing* específico”.

Para Kotler & Armstrong (1998), demandas são desejos por produtos específicos, respaldados pela habilidade e pela disposição para comprá-los. Desejos tornam-se demandas quando apoiados por poder de compra. Por conseguinte, as empresas devem mensurar não apenas quantas pessoas desejam seu produto, mas, o mais importante, quantas realmente estão habilitadas e dispostas a comprá-lo.

A fim de captar o mercado consumidor potencial, uma empresa necessita averiguar qual é o objetivo da previsão de demanda. A demanda que uma empresa pode mensurar varia em nível de produto (item do produto, linha do produto), em nível de espaço (consumidor, região de consumo, país) e em nível de tempo (curto, médio e longo prazo). Para as vendas de uma empresa em curto prazo, prever a demanda de consumidores é um exemplo de objetivo de previsão de demanda (KOTLER, 1998).

Escolhido o objetivo de previsão de demanda, é necessário que os profissionais encarregados de realizar este estudo façam distinção entre um estudo de demanda de mercado e um estudo da demanda da própria empresa, sendo que este último consiste na previsão de sua participação no mercado, em função do esforço de *marketing* empregado.

Comumente, conforme Sandhusen (1998), as empresas utilizam um procedimento de três estágios para preparar a previsão: previsão macroeconômica, previsão do setor industrial e previsão da empresa. Para Kuyven & Cunha (2001), quando se analisa a demanda por um produto em uma empresa, é necessário atentar para duas variáveis de demanda: Demanda Total da Indústria (DTI) e Demanda Relativa da Empresa (DR). A DTI representa a demanda global por um tipo de produto em uma localização geográfica delimitada e pré-definida, considerando todos os seus fornecedores. Já a DR é o *market share* que uma empresa tem deste produto, naquela localização determinada.

Segundo Kotler (1998), poucos produtos são de fácil previsão, como os serviços de utilidade pública ou os oligopólios puros. Na maioria dos mercados, a demanda da empresa não é estável, e uma boa previsão da demanda torna-se fator-chave para o sucesso. Quanto mais instável for a demanda, maior a importância da precisão da previsão e, conseqüentemente, mais elaborados serão os procedimentos para tanto.

### 2.1.2. Visão econômica da demanda

A economia estuda a forma pela qual os indivíduos e a sociedade fazem suas escolhas e decisões, visando a utilizar os recursos disponíveis para satisfazer as necessidades individuais e coletivas. Como qualquer ciência, a economia preocupa-se com a explicação e a previsão de fenômenos observados.

Teorias são desenvolvidas para explicar fenômenos observados em termos de um conjunto de premissas e regras básicas. Para Johnston (1986), a teoria econômica consiste no estudo de vários conjuntos de relações que, supostamente, descrevem o funcionamento de uma parte ou do todo de um sistema econômico, os quais podem ser testados por meio de observações. Estes testes fazem uso das técnicas econométricas para construir modelos, a partir dos quais previsões podem ser feitas. O desenvolvimento das teorias econômicas

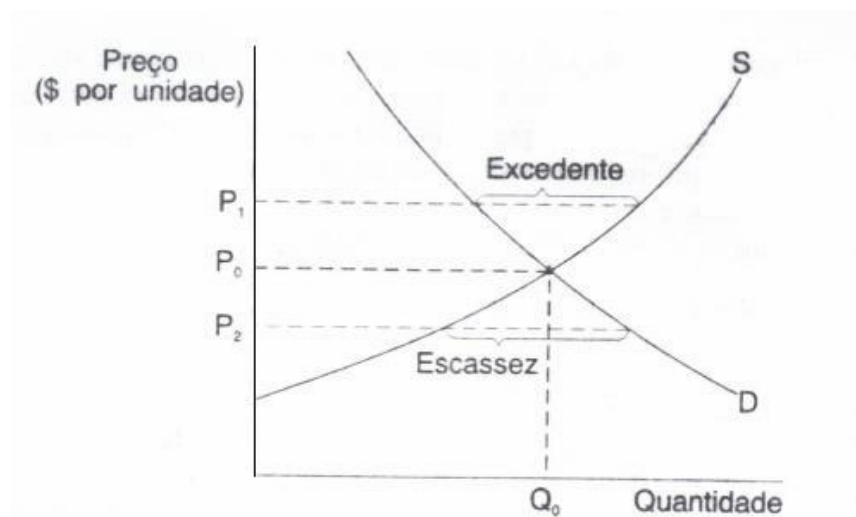
pode ocorrer em seus dois ramos: a macroeconomia, que estuda o funcionamento da economia de um país ou de uma aliança de países, e a microeconomia.

A microeconomia é a parte da economia que se ocupa da análise do comportamento das unidades econômicas, como famílias, consumidores ou empresas. Segundo Troster & Mochón (1999), a perspectiva microeconômica considera a atuação das diferentes unidades econômicas como se fossem unidades individuais.

A microeconomia explica como e por que estas unidades tomam decisões econômicas. Por exemplo, ela esclarece como consumidores tomam decisões de compra e de que forma suas escolhas são influenciadas pela variação de preços e de rendas; ela explica, também, de que maneira as empresas determinam o número de trabalhadores que contratarão. A microeconomia estuda, ainda, os mercados onde operam os demandantes e os ofertantes de bens e de serviços.

Em conjunto, demandantes e ofertantes interagem, originando os mercados. O funcionamento do mercado está baseado em um conjunto de regras, mediante as quais se compram e vendem bens e serviços livremente. Quando um mercado possui muitos demandantes e ofertantes, de tal modo que nenhum deles exerça, individualmente, impacto significativo sobre os preços, caracteriza-se um mercado competitivo ou de concorrência perfeita. Neste tipo de mercado, geralmente um único preço prevalece, o preço de mercado.

Quando consumidores e produtores são colocados em contato com seus respectivos planos de consumo e de produção, isto é, com suas respectivas curvas de demanda e de oferta, pode-se analisar a interação entre esses agentes. A interação que ocorre entre os demandantes (consumidores) e ofertantes (produtores) descrevem o mecanismo de mercado. Se o mercado é livre, isto é, se não há intervenção governamental (como, por exemplo, por meio da imposição do controle de preços ou de qualquer outra política regulamentadora), a oferta e a demanda entrarão em equilíbrio, conforme a Figura 1, determinando o preço de mercado de um bem ou serviço, bem como a quantidade a ser produzida (PINDYCH & RUBINFELD, 2002).



**Figura 1 – Equilíbrio de mercado**

[Fonte: Pindyck & Rubinfeld, 2002]

Através da curva de demanda D, na Figura 1, pode ser observado que, quanto maior o preço de um bem ou de um serviço, menor será a quantidade que os indivíduos estarão dispostos a demandar. Alternativamente, quanto menor o preço, maior será o número de unidades demandadas. A curva de demanda individual é a relação existente entre o preço e a sua quantidade demandada, durante um período de tempo determinado, por parte de um indivíduo. Assim, somando para cada preço as respectivas quantidades, obtém-se a curva de demanda D do mercado (PINDYCH & RUBINFELD, 2002).

A curva da oferta S, na Figura 1, informa as quantidades que os ofertantes estão dispostos a vender para cada preço que possam estabelecer no mercado. Esta curva é de inclinação ascendente, uma vez que, quanto mais alto for o preço de um bem ou de um serviço, maior será o número de empresas aptas e desejosas a produzi-lo e vendê-lo. A curva de oferta individual é a relação existente entre o seu preço e a sua quantidade ofertada, durante um período de tempo determinado, por parte de um indivíduo. Somando para cada preço as respectivas quantidades que os ofertantes estão dispostos a disponibilizar individualmente, obtém-se a curva de oferta S do mercado (PINDYCH & RUBINFELD, 2002).

Segundo Pindyck & Rubinfeld (2002), as duas curvas se interceptam no ponto de preço e na quantidade de equilíbrio. No preço  $P_0$ , a quantidade ofertada e a quantidade demandada são exatamente iguais ( $Q_0$ ). Denomina-se mecanismo de mercado a tendência, em mercados livres, de que o preço se modifique até que a quantidade ofertada e a quantidade

demandada tornem-se iguais. Neste ponto, não há escassez nem excedente de oferta, de tal forma que não existe pressão para que o preço continue se modificando.

A curva de demanda de um bem ou de um serviço é traçada mantendo constantes todos os fatores que incidem sobre a demanda, exceto o preço do bem ou do serviço em questão. Na realidade, os demais fatores se alteram com frequência, o que motivará deslocamentos da curva de demanda (PINDYCH & RUBINFELD, 2002). Desta forma ficará claro que a demanda não é apenas dependente do preço, mas também de outros fatores.

Segundo Troster & Mochón (1999), dentre os vários fatores que podem influenciar a demanda, os mais importantes são a renda dos consumidores, o preço dos bens relacionados e as preferências dos consumidores. Gujarati (2000) ressalta que, através da microeconomia, sabe-se que a demanda geralmente depende do preço do bem ou do serviço, do preço de outros bens ou serviços concorrentes ou complementares e da renda do consumidor. Hill *et al.* (2000) exemplificam que a demanda de, por exemplo, automóveis Gol, da Volkswagen, é uma função do preço dos modelos Gol; do preço dos modelos substitutos, como Palio e Fiesta; do preço de itens complementares, como a gasolina, e do nível da renda dos compradores de modelos Gol.


## **2.2. O Sistema de Previsão e suas Técnicas**

De acordo com Abraham & Ledolter (1983), estamos sempre fazendo previsões, embora nós não as reconheçamos como tal. Makridakis (1988) afirma que previsão é uma atividade indispensável no planejamento, na definição da estratégia e na tomada de decisões orientadas para o futuro, tanto em nível individual como em nível organizacional.

Para Abraham & Ledolter (1983), uma vez que previsões envolvem eventos futuros e estes, por sua vez, envolvem a incerteza, tem-se que as previsões, em geral, não são perfeitas. O objetivo, ao realizar uma previsão, é reduzir o erro da mesma. Para produzir uma previsão que apresente um erro pequeno, é necessário utilizar a técnica de previsão adequada. Conforme Makridakis *et al.* (1998), os previsores têm uma ampla variedade de técnicas disponíveis, as quais variam em acurácia (exatidão), objetivo, horizonte de tempo e custos.

Conforme Armstrong (2001c), a previsão é realizada somente se existe incerteza sobre o futuro. Além disso, devido à incerteza, é necessário saber se as previsões são acuradas; para tanto, é essencial usar critérios de acurácia para as previsões. Para Chambers *et al.* (1971), o custo total da previsão decorre de um balanceamento entre o custo de previsão e o custo da falta de acurácia. Por fim, as previsões são realizadas com base em um horizonte de tempo. Para Johnson & King (1988), se a previsão é solicitada para dois ou três períodos de tempo no futuro, o seu horizonte é considerado de curto prazo. Contudo, se o horizonte é maior que vinte períodos no futuro, a previsão será de longo prazo. Se for algum período intermediário entre os anteriores, a previsão é de médio prazo.

Para obter uma previsão que atenda ao objetivo, que seja acurada, dentro do horizonte de tempo desejado e com o menor custo, é necessário cumprir certas etapas do sistema. A estruturação de um sistema de previsão exige a realização de várias etapas. Na Figura 2, é apresentado um sistema de previsão composto por oito etapas. Para o modelo apresentado, as etapas são: (i) Definição do problema; (ii) Dimensionamento do processo; (iii) Obtenção de informações; (iv) Análise preliminar dos dados; (v) Seleção da técnica de previsão; (vi) Implementação da técnica de previsão; (vii) Avaliação da técnica de previsão e (viii) Uso da previsão.



**Figura 2 – Modelo de sistema de previsão com oito etapas**

[Adaptado de ARMSTRONG, 2001c; MAKRIDAKIS *et al.*, 1998; MURDICK & GEORGOFF, 1993]

A primeira etapa consiste em definir qual é o problema de previsão. Segundo Makridakis *et al.* (1998), definir o problema é, algumas vezes, o mais difícil aspecto da tarefa de previsão, pois envolve o entendimento de como a previsão deverá ser usada, de quem requer a previsão e de como essa função se ajusta à empresa.

O próximo passo, para Murdick & Georgoff (1993), é fazer o dimensionamento do processo. Essa etapa consiste em especificar os tipos de dados de entrada que estão

disponíveis, os resultados desejados e as suposições sobre o comportamento das variáveis que irão ser utilizadas na previsão.

Conhecidas as variáveis necessárias para o estudo, a próxima etapa é a obtenção de informações. Segundo Pellegrini & Fogliatto (2000), ao menos dois tipos de informações devem estar disponíveis na elaboração de um sistema de previsão: dados estatísticos e julgamento de especialistas. Os dados estatísticos serão utilizados na modelagem da previsão, e a opinião de especialistas será essencial para a validação prática das previsões geradas pelo sistema.

Segundo Makridakis *et al.* (1998), quando há utilização de dados estatísticos, deve-se iniciar traçando gráficos visando uma inspeção visual. Através dessa inspeção será possível verificar padrões, tendência e sazonalidade, caso os dados em estudo apresentem-se na forma de dados históricos. A análise gráfica preliminar e exploratória fornece subsídios que auxiliam a escolha dos modelos quantitativos.

Para Abraham & Ledolter (1983), a escolha ou a seleção da técnica de previsão depende, entre muitos outros critérios, do grau de acurácia desejada, do horizonte de previsão, de como os altos custos de previsão podem ser tolerados, do grau de complexidade requerida e de quais os dados disponíveis. Vale lembrar que o critério mais importante para escolher uma técnica de previsão é a acurácia.

De acordo com Madridakis *et al.* (1998), em muitas situações a palavra acurácia refere-se à qualidade do ajuste, isto é, ao quão hábil é a técnica ou o modelo para reproduzir os dados que já são conhecidos. As medidas de acurácia mais conhecidas são apresentadas na tabela 1. Segundo Johnson & King (1988), é proveitoso calcular mais que um critério de comparação, visto que, ocasionalmente, diferentes critérios fornecem indicações diferentes. Já Armstrong & Collopy (1992) sugerem, com base em um estudo empírico realizado com 191 séries temporais, a utilização do MdRAE para selecionar a técnica mais acurada.

Tabela 1 – Medidas de acurácia

Sigla	Descrição	Tradução
ME	<i>Mean Error</i>	erro médio
MAE	<i>Mean Absolute Error</i>	erro absoluto médio
MSE	<i>Mean Square Error</i>	erro quadrático médio
MPE	<i>Mean Percentual Error</i>	erro percentual médio
APE	<i>Absolute Percentual Error</i>	erro percentual absoluto
MAPE	<i>Mean Absolute Percentual Error</i>	média dos erros percentuais absolutos
MdAPE	<i>Median Absolute Percentual Error</i>	mediana dos erros percentuais absolutos
RAE	<i>Relative Absolute Error</i>	erro absoluto relativo
GMRAE	<i>Geometric Mean Relative Absolute Error</i>	média geométrica dos erros absolutos relativos
MdRAE	<i>Median Relative Absolute Error</i>	Mediana dos erros absolutos relativos
RMSE	<i>Root Mean Square Error</i>	raiz do erro quadrático médio

A etapa de implementação da técnica de previsão, no caso das técnicas quantitativas, consiste em construir modelos pertinentes aos dados e à teoria disponível. Em muitas situações, a teoria, por exemplo, a teoria econômica, pode sugerir modelos específicos; em outros casos, não existindo ainda teoria ou estando ela ainda incompleta, os dados devem ser utilizados para estabelecer o modelo e para estimar seus parâmetros. O desempenho do modelo somente pode ser avaliado apropriadamente após os dados do período de previsão serem disponibilizados, através das medidas de erros de previsão. Caso os erros de previsão sejam aceitáveis, o modelo pode ser utilizado e, como consequência, a previsão gerada por ele (MAKRIDAKIS *et al.*, 1998).

Em geral, as técnicas de previsão podem ser divididas em duas grandes categorias: qualitativa ou quantitativa (CHAMBERS *et al.*, 1971; ABRAHAM & LEDOLTER, 1983; JOHNSON & KING, 1988 e MAKRIDAKIS *et al.*, 1998). Contudo é possível realizar a integração entre várias técnicas, pertencentes ou não à mesma categoria. Tal assunto será abordado no capítulo 3 deste trabalho.

As técnicas quantitativas de previsão são aquelas baseadas em princípios e/ou em modelos estatísticos (ABRAHAM & LEDOLTER, 1983; MAKRIDAKIS *et al.*, 1998 e ARMSTRONG, 2001d). Para poder aplicá-las, é necessário atender a duas condições: (i)



que as informações sobre o passado estejam disponíveis na forma de dados numéricos e (ii) que se possa assumir a continuidade, no futuro, de alguns aspectos/padrões do passado (JOHNSON & KING, 1988 e MAKRIDAKIS *et al.*, 1998).

Segundo Johnson & King (1988), as técnicas quantitativas podem ser subdivididas em técnicas que estudam o comportamento de dados temporais e em modelos causais. A distinção entre estas duas abordagens reside em que, para a primeira, os modelos são baseados puramente nos valores do passado da variável envolvida, sendo o objetivo descobrir qualquer padrão que ocorreu no passado e extrapolá-lo para o futuro. Já os modelos causais procuram desenvolver uma relação de causa e efeito entre as variáveis que compõem a previsão e outros fatores relevantes.

Para realizar previsões com dados temporais, muitas técnicas foram desenvolvidas e estão consolidadas na literatura. Dentre elas encontram-se a decomposição de séries temporais, o alisamento exponencial e a metodologia de *Box-Jenkins* (MAKRIDAKIS *et al.*, 1998, ARMSTRONG, 2001b). Mais recentemente, as redes neurais passaram a ser utilizadas. Nesta tese será utilizada a metodologia de *Box-Jenkins* para contribuir na previsão da demanda.

De acordo com Chambers *et al.* (1971), quando dados históricos estão disponíveis e é possível explicar detalhadamente a relação entre a variável a ser prevista e outras variáveis, tal como variáveis econômicas, o previsor pode construir um modelo causal. Assim, os modelos econométricos podem ser considerados um caso particular dos modelos causais. Segundo Johnson & King (1988), a principal técnica usada na modelagem de relações causais é a análise de regressão, que também será utilizada para contribuir na previsão da demanda, seguindo a modelagem proposta nesta tese.

As técnicas qualitativas de previsão são usadas, de acordo com Chambers *et al.* (1971), quando os dados são escassos, como ocorre, por exemplo, no lançamento de um produto. Nesses casos, o julgamento humano é usado para converter informações qualitativas em estimativas quantitativas. Para Pellegrini & Fogliatto (2000), técnicas qualitativas baseiam-se em opiniões de especialistas. Como diferentes indivíduos apresentam preferências distintas, essas técnicas são vulneráveis a tendências que podem comprometer a confiabilidade dos resultados.

As técnicas qualitativas têm suas vantagens e desvantagens, e tais pontos serão abordados no item referente a esse tópico. Nesta tese, será utilizada a opinião de especialistas para realizar a previsão qualitativa. Uma vez que esta tese será sustentada por três técnicas de previsão, a saber: metodologia de *Box-Jenkins*, modelos causais advindos da análise de regressão e opinião de especialistas, cada uma delas será apresentada a seguir.

### 2.2.1. Metodologia de *Box-Jenkins*

Conforme Morettin & Tolo (1987), uma série temporal é qualquer conjunto de observações ordenadas no tempo. Séries temporais são compostas por quatro elementos:

- Tendência, que verifica o sentido de deslocamento da série;
- Ciclo, que descreve um movimento ondulatório o qual, ao longo de vários anos, tende a ser periódico;
- Sazonalidade, com duração de curto prazo, inferior a um ano, e está associada, em geral, a mudanças climáticas;
- Ruído Aleatório ou erro, que compreende a variabilidade intrínseca aos dados e que não pode ser modelado.

Como uma série temporal tem os dados coletados seqüencialmente, é esperado que ela apresente correlação seriada no tempo. Os modelos de *Box-Jenkins*, genericamente conhecidos por ARIMA, *AutoRegressive Integrated Moving Average*, e, em português, como Modelos Auto-Regressivos Integrados de Médias Móveis, são modelos matemáticos que visam a captar o comportamento da correlação seriada ou a auto-correlação existente entre os valores da série temporal e, com base neste comportamento, realizar previsões futuras. Se esta estrutura de correlação for bem modelada, ele fornecerá boas previsões.

Segundo Fava (2000), os modelos *Box-Jenkins* resultam da combinação de três componentes, denominados ‘filtros’: o componente Autoregressivo (AR), o filtro de Integração (I) e o componente de Médias Móveis (MA). Uma série pode ser modelada pelo três filtros ou apenas por um subconjunto deles, resultando em vários modelos, abordados a seguir.

### 2.2.1.1. Modelos estacionários

Modelos estacionários são aqueles que assumem o ‘equilíbrio’ do processo. Um processo é considerado fracamente estacionário se sua média e sua variância se mantêm constantes ao longo do tempo. Um processo é fortemente estacionário se todos os momentos estatísticos são constantes ao longo do tempo.

#### 2.2.1.1.1. Modelo Auto-Regressivo (AR)

Em um modelo auto-regressivo, a série de dados históricos  $Z_t$  é descrita por seus valores passados regredidos e pelo ruído aleatório  $\varepsilon_t$ . Assim, um modelo AR( $p$ ) é dado pela equação (2.1):

$$\tilde{Z}_t = \phi_1 \tilde{Z}_{t-1} + \phi_2 \tilde{Z}_{t-2} + \dots + \phi_p \tilde{Z}_{t-p} + \varepsilon_t \quad (2.1)$$

onde:  $\tilde{Z}_t = Z_t - \mu$ ;  $\phi_i$  é o parâmetro que descreve como  $\tilde{Z}_t$  se relaciona com o valor  $\tilde{Z}_{t-i}$  para  $i = 1, 2, \dots, p$ ;  $E(\varepsilon_t) = 0$ ;  $E(\varepsilon_t^2) = \sigma_\varepsilon^2$ ;  $E(\varepsilon_t \varepsilon_s) = 0$  para  $t \neq s$ .

O modelo auto-regressivo de ordem 1, ou AR(1), é a versão mais simples desta classe de modelos. Sua representação algébrica é dada pela equação (2.2):

$$\tilde{Z}_t = \phi_1 \tilde{Z}_{t-1} + \varepsilon_t \quad (2.2)$$

Uma vez que o modelo fracamente estacionário apresenta média e variância constantes ao longo do tempo, tem-se:

$$E(Z_t) = \frac{\mu}{1 - \phi_1} \quad (2.3)$$

$$V(Z_t) = \gamma_0 = \frac{\sigma_\varepsilon^2}{1 - \phi_1^2} \quad (2.4)$$

Para que a variância de  $Z_t$  seja não-negativa e finita, é necessário que  $|\phi_1| < 1$ . Esta condição é conhecida como condição de estacionariedade. Além disto, para o modelo ser estacionário, mesmo que fracamente, as auto-covariâncias ( $\gamma_k$ ) devem ser independentes do tempo  $t$ . No caso do modelo AR(1), as auto-covariâncias são dados por:

$$\gamma_k = \phi_1^k \gamma_0 \quad (2.5)$$

Desta forma, as auto-correlações não dependem do tempo, mas apenas da defasagem  $k$ . Como  $|\phi_1| < 1$ , quanto maior for a defasagem  $k$ , isto é, a distância entre os valores da série, menor será a auto-correlação. As auto-correlações  $\rho_k$  são dadas pela equação (2.6):

$$\rho_k = \frac{\gamma_k}{\gamma_0} = \phi_1^k, \quad k = 0, 1, 2, \dots \quad (2.6)$$

A função de auto-correlação decai exponencialmente quando  $\phi_1$  é positivo; quando  $\phi_1$  é negativo, a função também decai exponencialmente, mas apresenta alternância entre sinais positivos e negativos.

O modelo  $AR(p)$ , dado pela equação (2.1), pode ser reescrito, conforme a equação (2.7), utilizando o operador de defasagem  $L$ .

$$(1 - \phi_1 L - \phi_2 L^2 - \dots - \phi_p L^p) \tilde{Z}_t = \phi(L) \tilde{Z}_t = \varepsilon_t \quad (2.7)$$

Segundo Box & Jenkins (1976), para que a série seja estacionária é necessário que as raízes da equação  $\phi(L) = (1 - \phi_1 L - \phi_2 L^2 - \dots - \phi_p L^p) = 0$  sejam maiores que um, ou seja, todas as raízes devem estar fora do círculo unitário.

A função de auto-correlação de um modelo  $AR(p)$  é dada pelas equações de Yule-Walker:

$$\begin{aligned} k=1 : \quad \rho_1 &= \phi_1 + \rho_1 \phi_2 + \dots + \rho_{p-1} \phi_p \\ k=2 : \quad \rho_2 &= \rho_1 \phi_1 + \phi_2 + \dots + \rho_{p-2} \phi_p \\ &\vdots \\ k=p : \quad \rho_p &= \rho_{p-1} \phi_1 + \rho_{p-2} \phi_2 + \dots + \phi_p \end{aligned} \quad (2.8)$$

#### 2.2.1.1.2. Modelos de Médias Móveis (MA)

Em um modelo de médias móveis (do inglês *Moving Average*), a série  $Z_t$  resulta da combinação dos ruídos brancos  $\varepsilon$  do período atual com os ocorridos em períodos anteriores. Assim, um modelo de médias móveis de ordem  $q$  ou  $MA(q)$  é dado por:

$$\tilde{Z}_t = \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q} \quad (2.9)$$

onde:  $\tilde{Z}_t = Z_t - \mu$ ;  $\theta_i$  é o parâmetro que descreve como  $Z_t$  se relaciona com o valor  $\varepsilon_{t-i}$  para  $i = 1, 2, \dots, q$ ;  $E(\varepsilon_t) = 0$ ;  $E(\varepsilon_t^2) = \sigma_\varepsilon^2$ ;  $E(\varepsilon_t \varepsilon_s) = 0$  para  $t \neq s$ .

O modelo MA(1) é a versão mais simples desta classe de modelos. Sua representação algébrica é dada pela equação (2.10):

$$\tilde{Z}_t = \varepsilon_t + \theta_1 \varepsilon_{t-1} \quad (2.10)$$

Para este modelo, a média e a variância de  $Z_t$  são constantes ao longo do tempo:

$$E(Z_t) = \mu$$

$$V(Z_t) = \gamma_0 = (1 + \theta_1^2) \sigma_\varepsilon^2 \quad (2.11)$$

As auto-correlações  $\rho_k$ , que nada mais são que as auto-covariâncias divididas pela variância, são dadas pela equação (2.12):

$$\rho_k = \frac{\gamma_k}{\gamma_0} \quad k = 0, 1, 2, \dots \quad (2.12)$$

$$\text{Assim, } \rho_1 = \frac{\gamma_1}{\gamma_0} = \frac{-\theta_1 \sigma_\varepsilon^2}{(1 + \theta_1^2) \sigma_\varepsilon^2} = \frac{-\theta_1}{(1 + \theta_1^2)} \quad \text{onde } \rho_k = 0 \text{ e } k > 1 \quad (2.13)$$

A função de auto-correlação do modelo MA(1) apresenta apenas a primeira auto-correlação não nula, e as demais, iguais a zero. A primeira auto-correlação será positiva se  $\theta_1$  for menor que zero, e será negativa se  $\theta_1$  for maior que zero.

Segundo Nelson (1973), uma propriedade importante do MA(1), que provém da função de auto-correlação, é que sua ‘memória’ é de somente um período de tempo. Uma dada observação, por exemplo,  $Z_{53}$ , está correlacionada apenas com seu antecessor  $Z_{52}$  e com seu sucessor  $Z_{54}$ , mas não com qualquer outro membro da série.

Analisando as expressões da variância e das auto-correlações do modelo MA(1), observa-se que não é necessário impor nenhuma restrição sobre  $\theta_1$  para obter a

estacionariedade (fraca) da série. Contudo, para transformar um modelo MA(1) em um modelo AR( $\infty$ ), é preciso impor a restrição  $|\theta| < 1$ , que é a condição de invertibilidade.

O modelo MA( $q$ ), dado pela equação (2.9), pode ser reescrito, como em (2.14), utilizando o operador de defasagem L.

$$(1 - \theta_1 L - \theta_2 L^2 - \dots - \theta_q L^q) \varepsilon_t = \theta(L) \varepsilon_t = \tilde{Z}_t \quad (2.14)$$

Segundo Nelson (1973), qualquer processo de média móvel é estacionário, pois, conforme (2.9),  $\tilde{Z}_t$  é a soma de um número finito de termos. Contudo, segundo Abraham & Ledolter (1983), para que o processo se torne inversível, é necessário que as raízes da equação  $\theta(L) = (1 - \theta_1 L - \theta_2 L^2 - \dots - \theta_q L^q) = 0$  sejam maiores que um, ou seja, todas as raízes devem estar fora do círculo unitário.

As auto-correlações de um modelo MA( $q$ ) são não-nulas até a defasagem  $q$ , e são dadas por:

$$\rho_k = \frac{-\theta_k + \theta_1 \theta_{k+1} + \dots + \theta_{q-k} \theta_k}{1 + \theta_1^2 + \dots + \theta_q^2} \quad k = 1, 2, \dots, q \quad \text{e} \quad \rho_k = 0 \quad k > q \quad (2.15)$$

### 2.2.1.1.3. Modelos Auto-Regressivos de Médias Móveis (ARMA)

Em alguns casos, pode ser necessário estimar um grande número de parâmetros em modelos que são puramente AR ou puramente MA. Nesses casos, é vantajoso misturar os componentes de um modelo AR com os componentes de um modelo MA, gerando, assim, um modelo ARMA. O modelo ARMA( $p, q$ ) certamente irá utilizar um número menor de termos e pode ser expresso conforme a equação (2.16):

$$\tilde{Z}_t = \phi_1 \tilde{Z}_{t-1} + \dots + \phi_p \tilde{Z}_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \dots - \theta_q \varepsilon_{t-q} \quad (2.16)$$

onde:  $\tilde{Z}_t = Z_t - \mu$ ;  $\phi_i$  é o parâmetro que descreve como  $\tilde{Z}_t$  se relaciona com o valor  $\tilde{Z}_{t-i}$  para  $i = 1, 2, \dots, p$ ;  $\theta_i$  é o parâmetro que descreve como  $Z_t$  se relaciona com o valor  $\varepsilon_{t-i}$  para  $i = 1, 2, \dots, q$ ;  $E(\varepsilon_t) = 0$ ;  $E(\varepsilon_t^2) = \sigma_\varepsilon^2$ ;  $E(\varepsilon_t \varepsilon_s) = 0$  para  $t \neq s$ .

O modelo ARMA mais simples é o modelo ARMA(1,1), dado pela equação (2.17):

$$\tilde{Z}_t = \phi_1 \tilde{Z}_{t-1} + \varepsilon_t - \theta_1 \varepsilon_{t-1}. \quad (2.17)$$

Reescrevendo o modelo em termos do operador de defasagem, tem-se:

$$(1 - \phi_1 L) \tilde{Z}_t = (1 - \theta_1 L) \varepsilon_t. \quad (2.18)$$

A função de auto-correlação do modelo ARMA(1,1) é dada por:

$$\rho_1 = \frac{(1 - \phi_1 \theta_1)(\phi_1 - \theta_1)}{1 + \theta_1^2 + 2\phi_1 \theta_1}, \quad \rho_k = \phi_1 \rho_{k-1} \text{ para } k > 1. \quad (2.19)$$

A função de auto-correlação é similar à de um modelo AR(1), sendo caracterizada por um decaimento exponencial, oscilatório ou não, dependendo do sinal de  $\phi_1$ . Contudo esse decaimento inicia a partir de  $\rho_1$ , e não, a partir de  $\rho_0$ , como acontece no modelo AR(1). A condição de estacionariedade é a mesma de um modelo AR(1), isto é,  $|\phi_1| < 1$ , e a condição de inversibilidade é a mesma de um modelo MA(1), isto é,  $|\theta_1| < 1$ .

O modelo ARMA( $p,q$ ), na equação (2.16), pode ser reescrito como em (2.20), utilizando o operador de defasagem L.

$$(1 - \phi_1 L - \dots - \phi_p L^p) \tilde{Z}_t = (1 - \theta_1 L - \dots - \theta_q L^q) \varepsilon_t \quad (2.20)$$

A função de auto-correlação do modelo ARMA( $p,q$ ) apresenta características da função MA( $q$ ) para as defasagens  $k > q$ , devido ao fato de que a ‘memória’ do componente de médias móveis dura apenas  $q$  períodos. Já as condições de estacionariedade e de invertibilidade de um modelo ARMA( $p,q$ ) requerem, respectivamente, que todas as  $p$  raízes de  $\phi(L)=0$  e todas as raízes de  $\theta(L)=0$  estejam fora do círculo unitário.

### 2.2.1.2. Modelos não-estacionários

Uma série temporal com média e variância dependentes do tempo é chamada de não-estacionária. A não-estacionariedade de uma série implica que: (i) existe tendência nos dados e eles não oscilam aleatoriamente ao redor de uma linha horizontal ao longo do tempo e/ou (ii) a variação dos dados não permanece essencialmente constante sobre o tempo, isto é, as flutuações vão aumentando ou diminuindo com o passar do tempo, o que indica que a variância está se alterando.

A não-estacionariedade de uma série pode ser detectada graficamente, buscando-se os padrões (i) e (ii) ou, então, aplicando-se os testes estatísticos de raiz unitária. O teste de raiz unitária mais usado é o teste de Dickey-Fuller. Maiores detalhes sobre esse teste podem ser vistos em Makidrakis *et al.* (1998), Enders (1995) e Hamilton (1994).

#### 2.2.1.2.1. Modelos Auto-Regressivos Integrados de Médias Móveis (ARIMA)

Como a maioria dos procedimentos de análise estatística de séries temporais supõe que estas sejam estacionárias, será necessário transformá-las, caso ainda não o sejam. Segundo Morettin & Toloí (1987), a transformação mais comum consiste em tomar diferenças sucessivas da série original até obter uma série estacionária.

A primeira diferença de  $Z_t$  é definida pela equação (2.21):

$$\Delta Z_t = Z_t - Z_{t-1} \quad (2.21)$$

a segunda diferença é dada pela equação (2.22):

$$\Delta^2 Z_t = \Delta[\Delta Z_t] = \Delta[Z_t - Z_{t-1}] = Z_t - 2Z_{t-1} - Z_{t-2} \quad (2.22)$$

Em situações normais, ainda segundo os autores mencionados, será suficiente tomar uma ou duas diferenças para que a série se torne estacionária. O número  $d$  de diferenças necessárias para tornar a série estacionária é denominado de ordem de integração. A inclusão do termo de ordem de integração permite que sejam utilizados os modelos ARIMA( $p, d, q$ ) dados pela equação (2.23):

$$w_t = \phi_1 w_{t-1} + \dots + \phi_p w_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \dots - \theta_q \varepsilon_{t-q} \quad (2.23)$$

onde:  $w_t = \Delta^d Z_t$

O modelo ARIMA( $p, d, q$ ) dado pela equação (2.23) pode ser reescrito como em (2.24), utilizando o operador de defasagem  $L$ .

$$(1 - \phi_1 L - \dots - \phi_p L^p) w_t = (1 - \theta_1 L - \dots - \theta_q L^q) \varepsilon_t \quad \text{sendo: } w_t = (1 - l)^d Z_t \quad \text{ou}$$

$$\phi(L)(1 - L)^d Z_t = \theta(L) \varepsilon_t \quad (2.24)$$



No caso do modelo apresentar uma constante, a equação (2.24) é representada como na equação (2.25). Conforme Montgomery e Peck (1982), esta constante é conhecida como parâmetro de tendência.

$$\phi(L)(1-L)^d Z_t = \mu + \theta(L)\varepsilon_t \quad (2.25)$$

### 2.2.1.3. Modelos sazonais

Os modelos *Box-Jenkins* exploram a auto-correlação entre os valores da série em instantes sucessivos. Entretanto, quando os dados são observados em períodos inferiores a um ano, a série também pode apresentar auto-correlação para uma estação de sazonalidade  $s$ . Os modelos que contemplam as séries de auto-correlação sazonal são conhecidos como modelos SARIMA.

Os modelos SARIMA contêm uma parte não-sazonal, com parâmetros  $(p,d,q)$ , e uma parte sazonal, com parâmetros  $(P,D,Q)_s$ . O modelo mais geral é dado pela equação (2.26):

$$(1-\phi_1L-\dots-\phi_pL^p)(1-\Phi_1L^s-\dots-\Phi_PL^{Ps})(1-L)^d(1-L^s)^D Z_t = (1-\theta_1L-\dots-\theta_qL^q)(1-\Theta_1L^s-\dots-\Theta_QL^{Qs})\varepsilon_t \quad (2.26)$$

onde:  $(1-\phi_1L-\dots-\phi_pL^p)$  é a parte autoregressiva não sazonal de ordem  $p$ ;

$(1-\Phi_1L^s-\dots-\Phi_PL^{Ps})$  é a parte autoregressiva sazonal de ordem  $P$  e estação sazonal  $s$ ;

$(1-L)^d$  é parte de integração não sazonal de ordem  $d$ ;

$(1-L^s)^D$  é parte de integração sazonal de ordem  $D$  e estação sazonal  $s$ ;

$(1-\theta_1L-\dots-\theta_qL^q)$  é a parte não sazonal de médias móveis de ordem  $q$ ;

$(1-\Theta_1L^s-\dots-\Theta_QL^{Qs})$  é a parte sazonal de médias móveis de ordem  $Q$  e estação sazonal  $s$ .

A parte sazonal pode ser detectada nas defasagens sazonais das funções de auto-correlação e auto-correlação parcial. Uma sazonalidade de 12 meses será detectada na defasagem  $k=12, 24, 36, \dots$

#### 2.2.1.4. Etapas da metodologia Box-Jenkins

A construção dos modelos *Box-Jenkins*, segundo Morettin & Toloí (1987), é baseada em um ciclo iterativo. Segundo Box & Jenkins (1976), são três as etapas para construção do modelo:

- (i) identificação: consiste em descobrir qual, dentre os vários modelos *Box-Jenkins*, sejam eles sazonais ou não, descreve o comportamento da série;
- (ii) estimação: consiste em estimar os parâmetros  $\phi$  e/ou  $\Phi$  do componente autorregressivo e os parâmetros  $\theta$  e/ou  $\Theta$  do componente de médias móveis, além da variância de  $\varepsilon_t$  e
- (iii) verificação: consiste em avaliar se o modelo estimado é adequado para descrever o comportamento dos dados.

Caso o modelo não seja adequado, o procedimento é repetido, voltando-se à fase de identificação.

Um procedimento utilizado com frequência consiste em identificar não só um único modelo, mas alguns modelos que serão, então, estimados e verificados. Quando se obtém um modelo satisfatório, passa-se para a última etapa da metodologia de *Box-Jenkins*, que constitui o seu objetivo principal: realizar previsões. O detalhamento dessas etapas se dará com a sua devida aplicação no estudo de caso.

#### 2.2.2. Análise de regressão

Para Montgomery & Peck (1982), a análise de regressão é a técnica estatística utilizada para investigar e modelar o relacionamento entre variáveis. Conforme Draper & Smith (1981), ela consiste em examinar dados e em obter conclusões significativas sobre relações de dependência que podem existir entre as variáveis estudadas.

Os modelos de relacionamento entre variáveis podem ser lineares ou não-lineares. A linearidade, de acordo com Gujarati (2000), está relacionada aos parâmetros da regressão. Nos modelos lineares, os parâmetros são elevados somente à primeira potência, e as variáveis explicativas podem ser elevadas a qualquer potência.

### 2.2.2.1. Modelo de regressão linear simples

A relação mais simples entre duas variáveis, segundo Johnson (1986), é a linear. O modelo de regressão linear simples é dado pela expressão (2.27):

$$Y_i = \alpha + \beta X_i + \varepsilon_i \quad (2.27)$$

onde:  $Y_i$  é a variável dependente para a observação  $i$ ;  $\alpha$ ,  $\beta$  são os coeficientes de regressão, o intercepto e a inclinação da reta, respectivamente;  $X_i$  é a variável independente (ou explicativa) para a observação  $i$ ;  $\varepsilon_i$  é o erro aleatório (ou ruído aleatório) para a observação  $i$ , supondo que  $E(\varepsilon_i) = 0$ ,  $\text{Var}(\varepsilon_i) = \sigma^2$  e  $\text{Cov}(\varepsilon_i, \varepsilon_j) = 0$  para  $i \neq j$ .

A inclinação  $\beta$  indica a mudança na média da distribuição de  $Y$ , produzida por uma mudança unitária de  $X$ . Se a amplitude da variável  $X$  inclui o valor zero, então o intercepto  $\alpha$  é a média da distribuição da resposta de  $Y$  quando  $X$  se iguala a zero. Se a amplitude de  $X$  não inclui o valor zero, então  $\alpha$  não tem interpretação prática (MONTGOMERY & PECK, 1982).

Como os parâmetros  $\alpha$ ,  $\beta$  e  $\sigma^2$  são desconhecidos, é necessário estimá-los. Primeiramente toma-se uma amostra de  $n$  pares de dados  $(y_1, x_1)$ ,  $(y_2, x_2)$ , ...  $(y_n, x_n)$ . Segundo Montgomery & Peck (1982), esses dados podem ser resultado de um experimento controlado ou do registro de dados históricos. Após a obtenção dos dados, faz-se uso de um método de estimação. Conforme Gujarati (2000), o método utilizado com mais frequência é o dos mínimos quadrados ordinários, pois apresenta algumas propriedades estatísticas atraentes que o tornaram um dos mais poderosos e populares.

#### 2.2.2.1.1. Estimadores de Mínimos Quadrados Ordinários (MQO)

Uma vez que a equação (2.27) representa o modelo de regressão populacional, sendo difícil a população ser observada diretamente, pode-se reescrever esta mesma equação de forma que, ao se aplicar a amostra selecionada, obtenha-se o modelo de regressão amostral, dado pela equação (2.28).

$$Y_i = \hat{\alpha} + \hat{\beta}X_i + \hat{\varepsilon}_i = \hat{Y}_i + \hat{\varepsilon}_i \quad \text{para } i = 1, 2, \dots, n \quad (2.28)$$

O princípio do método dos mínimos quadrados ordinários é que os estimadores de  $\alpha$  e  $\beta$  conduzam à menor soma dos quadrados das diferenças entre os valores observados e as estimativas. Essas diferenças são chamadas de resíduos. Matematicamente, o princípio do método dos mínimos quadrados ordinários objetiva minimizar o somatório expresso na equação (2.29).

$$\sum_{i=1}^n \hat{\varepsilon}_i^2 = \sum_{i=1}^n (Y_i - \hat{\alpha} - \hat{\beta}X_i)^2 \quad (2.29)$$

Para encontrar os estimadores  $\hat{\alpha}$  e  $\hat{\beta}$  pelo método de mínimos quadrados ordinários, é necessário obter as derivadas parciais da equação (2.29) em relação a estes estimadores e igualá-las a zero, chegando a:

$$\hat{\alpha} = \bar{y} - \hat{\beta}\bar{x} \quad (2.30)$$

$$\hat{\beta} = \frac{n \sum_{i=1}^n X_i Y_i - \sum_{i=1}^n Y_i \sum_{i=1}^n X_i}{n \sum_{i=1}^n X_i^2 - \left( \sum_{i=1}^n X_i \right)^2}. \quad (2.31)$$

Assim, as equações (2.30) e (2.31) são os estimadores de mínimos quadrados ordinários do intercepto e da inclinação, respectivamente, sendo que o modelo de regressão linear simples estimado é dado pela equação (2.32).

$$Y = \hat{\alpha} + \hat{\beta} X \quad (2.32)$$

Além da estimação pontual de  $\alpha$  e  $\beta$ , é necessário estimar a variância dos resíduos ( $\sigma^2$ ), requisito básico para realizar testes de hipóteses e construção de intervalos de confiança pertinentes ao modelo de regressão. O estimador para  $\sigma^2$  pode ser obtido elevando-se a soma dos erros ao quadrado. Como os resíduos dependem de dois estimadores para serem obtidos, perde-se dois graus de liberdade. Desta forma, um estimador não-viciado é dado pela equação (2.33).

$$\hat{\sigma}^2 = \frac{\sum_{i=1}^n (Y_i - \hat{y}_i)^2}{n-2} \quad (2.33)$$

A quantidade obtida na equação (2.33) é chamada de erro quadrático médio (EQM), e sua raiz quadrada é conhecida por erro padrão da regressão, o qual apresenta a mesma unidade de medida da variável Y. Pelo fato do estimador apresentado em (2.33) depender da soma dos quadrados dos resíduos, qualquer violação das suposições dos erros do modelo ou qualquer falha na especificação do modelo pode prejudicar sua utilização como um bom estimador de  $\sigma^2$ .

Além do método de mínimos quadrados ordinários, os coeficientes de regressão podem ser estimados por outros métodos: máxima verossimilhança; mínimos quadrados ponderados; mínimos quadrados parciais e por equações aparentemente não-relacionadas (SURE), vide Montgomery & Peck (1982), Abraham & Ledolter (1983), Geladi & Kowalski (1986) e Zellner (1971), respectivamente. Além do método de mínimos quadrados generalizados que será abordado ainda nesta seção.

#### 2.2.2.1.2. Adequação do modelo

Cinco suposições foram estabelecidas para a realização da análise de regressão: que o relacionamento entre as variáveis X e Y seja linear; que o termo de erro tenha média zero; que haja variância constante  $\sigma^2$ ; que os erros não sejam correlacionados e que sejam normalmente distribuídos. Violações severas destas condições podem levar a um modelo que não represente o comportamento real da variável independente, por isto se faz necessário verificar a adequação do modelo.

Usualmente não se pode detectar desvios das suposições pelo exame das estatísticas padrão, tal como a estatística t ou a estatística F e o coeficiente de determinação  $r^2$ . Estas são propriedades 'globais' do modelo e, como tal, não asseguram sua adequação (MONTGOMERY & PECK, 1982). Assim, para investigar a adequação do ajuste do modelo de regressão e detectar desvios nas suposições iniciais, que geram problemas como auto-correlação, heterocedasticidade e não-normalidade dos erros, utiliza-se a análise de resíduos e testes apropriados. Para um maior aprofundamento, Draper & Smith (1981), Montgomery & Peck (1982), Abraham & Ledolter (1983) e Gujarati (2000) podem ser consultados.

### 2.2.2.2. Modelo de regressão linear múltipla

Em muitas situações como, por exemplo, na teoria econômica, raramente uma variável dependente  $Y$  relaciona-se a apenas uma variável explicativa. Gujarati (2000) exemplifica que a demanda por uma mercadoria provavelmente não depende apenas de seu preço, mas também dos preços de seus concorrentes, da renda do consumidor, de seu *status* social, etc. Por isso se faz necessário ampliar o modelo para abranger as demais variáveis.

Para situações como esta, a relação pode ser explicada através de uma regressão linear múltipla, cuja equação que expressa a resposta (variável dependente  $Y$ ), segundo Weisberg (1985), passa a ser uma função linear de  $k$  variáveis explicativas. O modelo é dado pela expressão (2.34):

$$Y_i = \beta_0 + \beta_1 X_{1i} + \dots + \beta_k X_{ki} + \varepsilon_i, \quad \text{para } i=1, \dots, n \quad (2.34)$$

onde:  $Y_i$  é a variável dependente para a observação  $i$ ;  $\beta_0$  é o intercepto,  $\beta_1, \dots, \beta_k$  são os coeficientes parciais da regressão;  $X_{1i}, \dots, X_{ki}$  são as variáveis explicativas para a observação  $i$ ;  $\varepsilon_i$  é o erro aleatório para a observação  $i$ , supondo que  $E(\varepsilon_i) = 0$ ,  $\text{Var}(\varepsilon_i) = \sigma^2$ ,  $\text{Cov}(\varepsilon_i, \varepsilon_j) = 0$  para  $i \neq j$ .

A relação dada na equação (2.34) pode ser expressa através de notação matricial, conforme a expressão (2.35):

$$Y = X\beta + \varepsilon \quad (2.35)$$

onde:  $Y$  é o vetor de ordem  $(n \times 1)$  de observações da variável dependente;  $\beta$  é o vetor de ordem  $(k+1 \times 1)$  dos coeficientes de regressão, incluindo o intercepto  $\beta_0$ ;  $X$  é a matriz de ordem  $(n \times k+1)$  dada pelo valores das variáveis explicativas, sendo que a primeira coluna é de valores unitários, visando obter o valor do intercepto e, por fim,  $\varepsilon$  é o vetor de ordem  $(n \times 1)$  dos erros aleatórios.

Na regressão linear múltipla, uma das suposições básicas do modelo é que a matriz  $X$  dos dados deve apresentar posto  $k$ , onde  $k$  é o número de variáveis explicativas. Isto implica que não é permitida a existência de relação linear entre as variáveis explicativas, ou seja, elas devem ser linearmente independentes. Segundo Montgomery & Peck (1982),

quando existe uma certa dependência linear entre os regressores, surge o problema de multicolinearidade. Muitas são as fontes e as formas de evitar a multicolinearidade. Maiores detalhes podem ser encontrados em Draper & Smith (1981), Montgomery & Peck (1982), Abraham & Ledolter (1983) e Gujarati (2000).

### 2.2.2.3. Estimação por Mínimos Quadrados Generalizados (MQG)

Duas suposições usualmente feitas para o modelo de regressão linear múltipla são de que  $E(\varepsilon)=0$  e de que  $\text{Var}(\varepsilon)=\sigma^2I$ . Segundo Draper & Smith (1981), muitas vezes estas suposições não são verificadas, e o estimador de mínimos quadrados ordinários, mesmo sendo não-viciado, poderá não ser o estimador de variância mínima. Quando isto ocorre, Montgomery & Peck (1982) consideram que é necessário realizar modificações no procedimento de mínimos quadrados ordinários, isto é, quando  $\text{Var}(\varepsilon)=\sigma^2V$ , onde  $V$  é uma matriz  $n \times n$ , não-singular e positiva definida.

Para realizar tais modificações é necessário um método que considere as informações da variabilidade. O método de mínimos quadrados generalizados (MQG) considera as alterações da variabilidade. Quando se trabalha com pesos específicos para a variabilidade dos valores de  $Y$ , utiliza-se o método de mínimos quadrados ponderados, o qual, para alguns autores, como Gujarati (2000), é um caso particular do MQG.

Para entender o método de mínimos quadrados generalizados, tomamos um modelo de regressão linear simples, dado na equação (2.27) e que, reescrito, resulta em:

$$Y_i = \alpha_i X_{0i} + \beta X_{1i} + \varepsilon_i \quad (2.36)$$

onde:  $X_{0i} = 1$  para qualquer  $i$ .

Supondo que as variâncias heterocedásticas  $\sigma_i^2$  sejam conhecidas e dividindo a equação (2.36) pelas variâncias, tem-se as seguintes equações:

$$\frac{Y_i}{\sigma_i} = \alpha \left( \frac{X_{0i}}{\sigma_i} \right) + \beta_1 \left( \frac{X_{1i}}{\sigma_i} \right) + \left( \frac{\varepsilon_i}{\sigma_i} \right) \quad \text{ou} \quad (2.37)$$

$$Y_i^* = \alpha X_{0i}^* + \beta_1 X_{1i}^* + \varepsilon_i^* \quad (2.38)$$

Com esta transformação, os erros atendem às suposições desejadas, de que  $E(\varepsilon^*)=0$  e de que  $\text{Var}(\varepsilon^*) = \sigma^2 I$ .

Para Gujarati (2000), o método de transformar as variáveis originais, de modo que as variáveis transformadas satisfaçam as hipóteses do modelo clássico para, em seguida, aplicar o método de mínimos quadrados ordinários, é conhecido como método de mínimos quadrados generalizados. Para uma maior aprofundamento Weisberg (1985) e Gujarati (2000) podem ser consultados.

### 2.2.3. Opinião de especialistas

Todos os métodos de previsão, segundo Wright *et al.* (1996) e Goodwin (2002), envolvem opiniões. Ainda que a previsão provenha do método estatístico mais sofisticado, a opinião humana está envolvida na escolha do método de previsão.

Para Rowe & Wright (2001), a opinião de especialistas é freqüentemente necessária na tarefa de previsão, porque faltam informações apropriadas para a utilização de procedimentos estatísticos. Mesmo quando métodos estatísticos são utilizados, os resultados são, muitas vezes, ajustados de acordo com a opinião de especialistas (BUNN & WRIGHT, 1991).

Segundo Armstrong (2001), em muitas situações de previsões, o primeiro passo é perguntar aos especialistas. Algumas vezes isto é suficiente, pois eles podem produzir excelentes previsões. Conforme Remus *et al.* (1995), os métodos baseados na opinião de especialistas podem ser particularmente úteis quando as condições de previsão não são estáveis, sendo caracterizadas por mudanças.

Independente das condições de previsão, a opinião de especialistas é muito utilizada. Nos Estados Unidos da América, Dalrymple (1987) realizou uma pesquisa sobre como as empresas de negócios preparavam suas previsões de vendas e descobriu que a opinião da força de vendas era o mais importante método de previsão.

Morris (1977) define especialista como “qualquer pessoa que tenha conhecimentos especiais sobre certo evento”. A técnica de opinião de especialistas consiste em obter e em



agregar, de alguma forma, a opinião desses especialistas. Segundo Kotler (1998), na técnica de opinião de especialistas, um conjunto de pessoas notáveis é selecionado, e essas pessoas são solicitadas a atribuir importância e graus de probabilidade em relação a possíveis desenvolvimentos futuros.

Armstrong (1986) afirma que a opinião de muitos especialistas é melhor que a opinião de um único especialista. Por isso, sugere que o número ótimo de especialistas seja entre cinco e vinte. Os especialistas sempre têm alguma habilidade para prever, ainda que sejam diferentes uns dos outros; contudo mais especialistas devem ser usados quando o custo de errar for alto.

Em um meta-estudo de previsão, Winklhofer *et al.* (1996) registraram que a principal razão dos administradores preferirem a previsão por opinião era a acurácia e a facilidade do uso. Para Harvey (2001), a previsão baseada em opinião pode ser melhorada com o propósito de minimizar inconsistência e viés. A inconsistência se refere à dispersão das previsões em torno da média. Já o viés se refere à distância entre o valor da previsão e o valor verdadeiro.

Para Rowe & Wright (2001), quando o julgamento humano é requisitado em situações de previsão, a questão-chave é como obter e usar o melhor da opinião dos especialistas. Essa questão depende muito dos objetivos do previsor; entretanto algumas técnicas de obtenção de dados qualitativos já foram desenvolvidas e são amplamente usadas, tais como entrevistas, o método Delphi e o grupo focado.

Visto que nesta tese serão utilizadas entrevistas para a obtenção de dados, o referido tópico será abordado a seguir.

### **2.2.3.1. Entrevistas**

Segundo Patton (1987), realizar entrevistas é um procedimento que consiste em obter informações das pessoas sobre suas experiências, opiniões, sentimentos e conhecimentos. O princípio fundamental da entrevista qualitativa é prover uma estrutura em que cada respondente possa expressar seu entendimento com suas próprias palavras. Além disso, a qualidade da informação obtida durante uma entrevista é largamente

dependente do entrevistador. Para isto, o entrevistador terá de fazer com que a pessoa entrevistada permita que ele conheça seu mundo.

Denzin & Lincoln (2000) indicam que a entrevista não é uma ferramenta neutra, pois pelo menos duas pessoas estão envolvidas no seu desenrolar. Além disso, esta forma de obter os dados é influenciada pelas características do entrevistador. Para os autores, a entrevista é uma conversação, envolvendo a arte de perguntar e de ouvir.

Conforme Fontana & Frey (2000), a entrevista é uma das maneiras mais comuns e poderosas para tentar entender o ser humano. Para esses autores, entrevistas incluem uma variedade de formas e uma multiplicidade de usos. A forma mais comum de entrevista é a individual, contemplando intercâmbio verbal face a face, mas entrevistas também podem ser em grupo, através de troca de mensagens, de questionário auto-preenchido e de pesquisa por telefone.

Para coletar os dados em uma entrevista, é necessário, primeiramente, escolher entre três estratégias. Para Patton (1987), as três estratégias envolvem diferentes tipos de preparação, conceituação e instrumentalização. Cada estratégia tem suas vantagens e desvantagens, servindo a diferentes propósitos. As três estratégias são: (1) entrevista realizada como conversa informal; (2) entrevista guiada por roteiro e (3) entrevista com questões padronizadas. Essas mesmas estratégias são designadas por Fontana & Frey (2000), respectivamente, como não-estruturada, semi-estruturada e estruturada.

De acordo com Ribeiro (2004), quando a entrevista é não-estruturada, o tópico de pesquisa é explicado e, a seguir, tanto o respondente quanto o entrevistador têm total liberdade na condução do diálogo. Para o sucesso dessa técnica, é importante que: (i) o entrevistador estabeleça uma relação simpática e descontraída, estimulando o respondente a falar, independentemente do posicionamento de questões e (ii) o entrevistador tenha firme conhecimento dos objetivos da pesquisa, identificando rapidamente os caminhos promissores que possam ajudar a elucidar as questões básicas da pesquisa em curso.

Quando a entrevista é semi-estruturada, conforme Ribeiro (2004), existe um roteiro básico e um conjunto de questões que, eventualmente, ao longo da entrevista, serão colocadas. Apesar da existência deste roteiro, as estas entrevistas nunca seguem uma

estrutura rígida, e o entrevistador deve estar sempre propenso a complementar o roteiro, fazendo perguntas que são diretamente motivadas pelas respostas articuladas pelo respondente.

Para Fontana & Frey (2000), na entrevista com questões padronizadas o entrevistador, utilizando essencialmente as mesmas palavras, pergunta a todos os respondentes a mesma série preestabelecida de questões, as quais apresentam um conjunto limitado de categoria de respostas. Segundo Patton (1987), a finalidade básica da entrevista com questões padronizadas é minimizar o efeito do entrevistador, já que ele aborda a mesma questão com cada entrevistado. Este tipo de entrevista é particularmente apropriado quando muitas pessoas são entrevistadas (grupos) e quando os pesquisadores desejam reduzir a variação nas respostas.

#### 2.2.3.1.1. Entrevistas individuais

As entrevistas individuais são aquelas onde o entrevistador fica frente a frente com o respondente, tendo a oportunidade de explorar em profundidade um determinado tema (objeto de pesquisa). A abordagem é essencialmente qualitativa, o número de entrevistados é pequeno e o envolvimento do entrevistador é muito grande, interagindo diretamente com o respondente que detém as informações (RIBEIRO, 2004).

Uma das vantagens das entrevistas individuais é que elas não requerem um grande planejamento prévio, permitindo que o pesquisador vá a campo tão logo tenha definido os objetivos da pesquisa. No entanto, apesar de não exigirem muito planejamento, há aspectos que precisam ser verificados, dentre os quais Ribeiro (2004) destaca: escolha dos entrevistados; agenda e horário; local; roteiro das questões; forma de registro dos dados e alternativas para a transformação dos dados. Para um maior aprofundamento dessas questões, sugere-se consultar a referência citada.

Muitas são as formas de obtenção de dados qualitativos e de análise desses, devido a sua natureza. Segundo Clemen (1989), nos anos 50 um considerável esforço de pesquisa foi direcionado para o desenvolvimento de modelos que capturassem a opinião de especialistas, conhecidos por *bootstrapping* subjetivo.

De acordo com Armstrong (2001d), o *bootstrapping* subjetivo é um tipo de sistema especialista que infere um modelo através do exame das previsões realizadas pelo especialista (ou grupo de especialistas).

Para Goodwin (2002), *bootstrapping* subjetivo (que é diferente do termo *bootstrapping* usado na estatística, que descreve um procedimento de re-amostragem) normalmente envolve o uso de regressão linear múltipla para construir um modelo de previsão por opinião. A forma usual do modelo é dada pela equação (2.39).

$$F = a + b_1X_1 + b_2X_2 + \dots + b_nX_n \quad (2.39)$$

onde:  $F$  é a previsão;  $a$  é uma constante;  $b_i$  é o peso que o previsor implicitamente associa a opinião  $i$ ;  $X_i$  é a opinião disponibilizada pelo previsor  $i$  e que serve como variável explicativa.

Para obter mais detalhes sobre o tópico, Armstrong (2001d) e Goodwin(2002) podem ser consultados.

## Capítulo 3 – Formas de Integração de Previsões

Na busca pelo melhor modo de obter as previsões, seja através de uma técnica qualitativa, realizando entrevistas com especialistas, ou, então, através de uma técnica quantitativa, obtendo um modelo estatístico que apresente as melhores métricas de desempenho, o objetivo dos previsores é sempre o mesmo: encontrar as previsões que contenham o menor erro possível.

Visando a atingir esse objetivo, Webby & O'Connor (1996) propuseram quatro formas de integrar previsões. Essas formas de integração buscam capturar informações de maneiras distintas, sejam elas provenientes de previsões objetivas, obtidas de técnicas quantitativas, ou de previsões subjetivas, obtidas de técnicas qualitativas. Tais formas de integração serão abordadas na seqüência.

Seguindo essa linha de pensamento, Sanders & Ritzman (2001) afirmam que tanto as técnicas de previsões estatísticas (objetivas) como as de opinião (subjetivas) têm seus prós e contras, oferecendo informações diferentes para o processo de previsão. Blattberg & Hoch (1990) também consideram que o julgamento humano e que os modelos estatísticos trazem contribuições valiosas e complementares que podem ser resumidas através da integração de previsões. Por exemplo: modelos são não-viciados; já o julgamento humano apresenta viés na percepção e na avaliação. Por outro lado, modelos são consistentes, mas como consequência não apresentam flexibilidade para acomodar novos fatos; por sua vez, o julgamento humano é inconsistente, mas flexível para se adaptar quando as condições de previsão mudam.

Webby *et al.* (2001) consideram que o julgamento humano apresenta uma vantagem sobre as previsões estatísticas: a de incorporar uma grande quantidade de conhecimento no processo de previsão. Apesar disso, para Makridakis *et al.* (1998), a

acurácia das previsões por opinião é, em média, inferior à das previsões estatísticas. Isto ocorre porque o julgamento é frequentemente caracterizado pelas limitações humanas, sendo possível a introdução de vários tipos de viés.

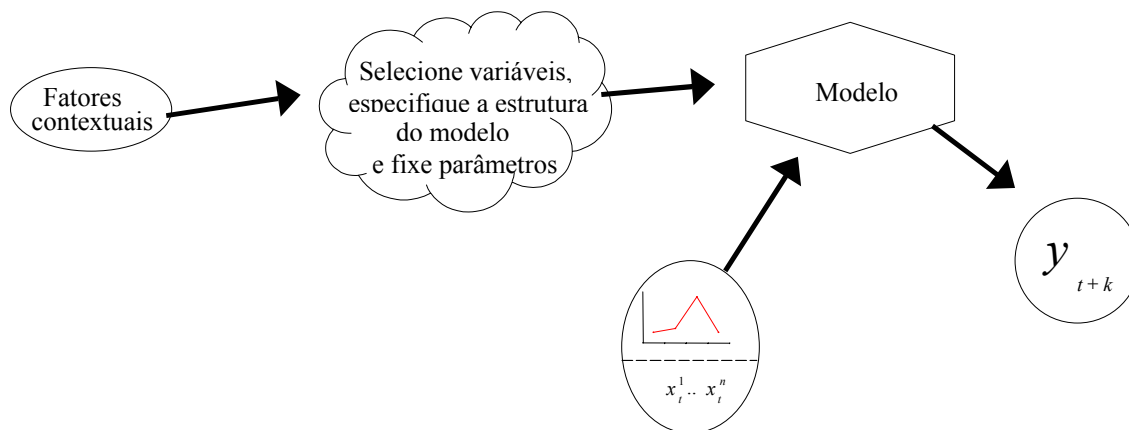
Contudo, de acordo com Remus *et al.* (1995), a literatura sobre técnicas de previsão tem enfatizado que o uso de modelos estatísticos no processo de previsão apresenta melhor desempenho quando as condições são estáveis. Assim, técnicas que incorporam opinião podem ser particularmente úteis em um ambiente caracterizado por mudanças, pois o julgamento humano pode ser superior aos modelos de previsão no reconhecimento de mudanças nos padrões dos dados, ou pode ser hábil para melhor integrar informações externas sobre as mudanças no processo de previsão. Tal consideração é corroborada por Wright *et al.* (1996), ao observarem que a acurácia de dados artificiais é favorecida pelo uso de técnicas quantitativas. Por outro lado, quando dados reais são utilizados, a instabilidade e a não-estacionariedade dos dados favorecem a subjetividade e penalizam as técnicas quantitativas, que dependem da estacionariedade e da suposição de constância.

Por fim, de acordo com Sanders & Ritzman (1990), previsões objetivas e subjetivas são usualmente vistas na literatura como mutuamente exclusivas. No entanto mesclá-las em uma única previsão composta pode ser vantajoso. De acordo com Goodwin (2000), através de vários estudos realizados nos mais diversos contextos, o julgamento humano e as técnicas estatísticas têm fornecido contribuições complementares e valiosas ao processo de previsão.

Webby & O'Connor (1996) sugerem que técnicas de previsão objetivas e subjetivas devem ser sintetizadas para que haja aproveitamento do benefício proporcionado pelas duas abordagens: a precisão mecânica das técnicas objetivas e as habilidades interpretativas e subjetivas do ser humano. Dessa forma, os autores classificam as principais abordagens de integração de previsões objetivas e subjetivas em quatro tipos:

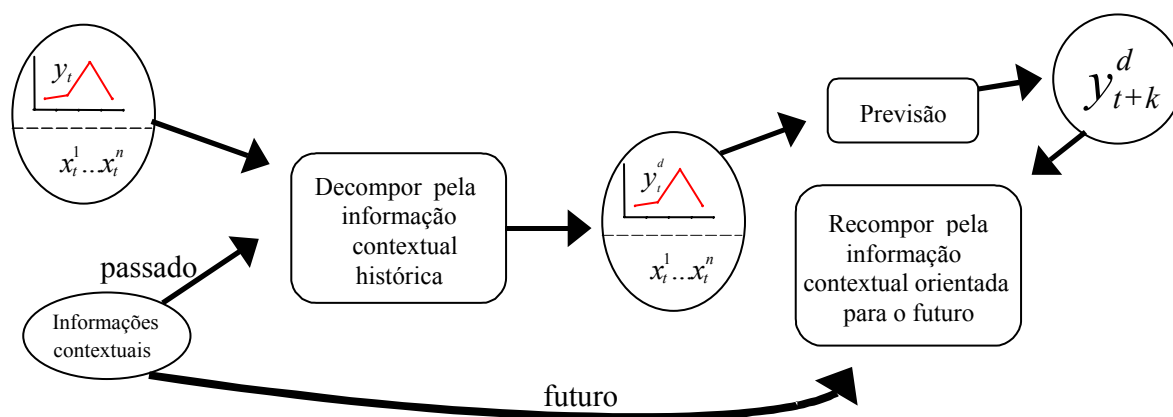
- (i) Construção de Modelos;
- (ii) Decomposição Baseada na Opinião;
- (iii) Combinação de Previsões e
- (iv) Ajuste Baseado na Opinião.

A construção de modelos é uma forma em que o julgamento humano é utilizado para selecionar variáveis, especificar a estrutura do modelo e fixar os parâmetros, baseando-se em informações contextuais. Informações contextuais são definidas como as que auxiliam a explanação, a interpretação e a antecipação do comportamento da série temporal. São informações específicas, disponíveis no ambiente de previsão, tais como um aumento dos preços ou uma greve eminente. Após, incorpora-se os dados da série temporal, de onde se obtém uma gama de modelos. Nesse ponto, novamente se utiliza a opinião para escolher o que aparenta ser o melhor, para então gerar uma previsão. Esta descrição pode ser elucidada através da figura 3 (BUNN & WRIGHT, 1991 e WEBBY & O'CONNOR, 1996).



**Figura 3 – Construção de modelo**  
[fonte: Webby & O'Connor, 1996]

Já a forma de integração que envolve decomposição baseada na opinião é um processo realizado em três etapas, e em cada uma pode-se utilizar um procedimento objetivo ou subjetivo. A primeira etapa consiste em decompor a série temporal com base em informações contextuais históricas (do passado). Após, a série temporal decomposta é prevista. Por fim, é feita uma recomposição da série já prevista, utilizando informações contextuais orientadas para o futuro. A figura 4 ilustra esta descrição (WEBBY & O'CONNOR, 1996).



**Figura 4 – Decomposição baseada na opinião**

[fonte: Webby & O'Connor, 1996]

Para Webby & O'Connor (1996), a decomposição é especialmente útil quando o previsor conhece pouco sobre o assunto em questão. Além disso, conforme MacGregor (2001), o previsor escolhe a forma de decomposição, aditiva ou multiplicativa, de acordo com a natureza da previsão e com os fatores causais conhecidos e associados ao problema, sugerindo que a decomposição multiplicativa seja usada somente quando a incerteza é alta, e evitada quando a incerteza é baixa.

Makridakis *et al.* (1998), por sua vez, preferem utilizar a decomposição como uma ferramenta de entendimento da série temporal, ao invés de técnica de previsão em si, pois, embora pareça ser uma abordagem razoável, na prática raramente apresenta bom desempenho.

Pelo fato de ser alvo dessa tese, as formas de integração que envolvem combinação de previsões – que utiliza algum mecanismo, objetivo ou subjetivo, para compor as previsões e obter a previsão final (combinada) – e ajuste baseado na opinião – que toma a previsão objetiva e faz um ajuste com base em informações contextuais para, então, produzir a previsão final – serão abordadas a seguir, separadamente.

### 3.1. Combinação de Previsões

#### 3.1.1. Introdução

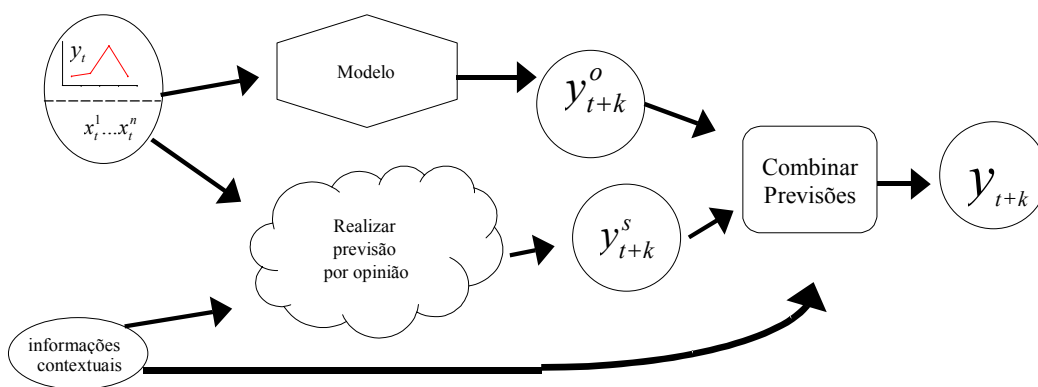
De acordo com Goodwin (2002), das formas disponíveis de integração de previsões por opinião com técnicas estatísticas, a mais discutida é a combinação. Segundo Clemen



(1989), a combinação é uma abordagem atraente para realizar previsões, visto que, ao invés de tentar escolher a melhor técnica, formula-se o problema perguntando que técnicas poderiam ajudar na melhoria da acurácia. Como as previsões podem ser afetadas por diversos fatores, cada técnica pode contribuir capturando algum tipo de informação que influencia esses fatores; logo, um número maior de fatores poderá ser analisado através da combinação.

Da mesma forma, Rausser & Oliveira (1976) comentam que, dadas duas ou três previsões do mesmo evento, a prática usual é determinar a melhor delas através de alguma medida de acurácia. A melhor previsão é, então, aproveitada, e as outras, descartadas. Através do descarte de previsões classificadas como inferiores, muitas vezes, alguma informação útil é perdida. Logo, ao invés de escolher uma única técnica de previsão, parece razoável considerar informações provenientes de várias técnicas e combiná-las.

A combinação de técnicas objetivas e subjetivas pode ser descrita como mostra a Figura 5. Primeiramente, gera-se, com base em dados históricos, um modelo; após, uma previsão objetiva. Paralelamente, realiza-se uma análise subjetiva dos dados históricos, agregando informações contextuais, de onde se obtém uma previsão subjetiva. Estas previsões são, então, combinadas, gerando a previsão final, com base em informações contextuais (WEBBY & O'CONNOR,1996).



**Figura 5 – Combinação de previsões**

[fonte: Webby & O'Connor, 1996]

Há muitos estudos sobre combinação de previsões propostos na literatura. Segundo Mackay & Metcalfe (2002), o foco prioritário desses estudos, até 1989, foi o estabelecimento de métodos de combinação que de fato melhorassem a acurácia e

reduzissem erros de previsão; desde 1989, a ênfase de pesquisa tem sido determinar (i) quais previsões combinar e (ii) quais métodos utilizar para combiná-las. Independente do foco, ainda há muito espaço para pesquisas, pois alguns métodos de combinação de previsões foram testados teoricamente, e uma grande parte dos métodos foi analisada em estudos empíricos. De qualquer forma, o previsor precisa estabelecer qual o método a ser empregado para combinar suas previsões.

Na realidade, para fazer uso da combinação e poder capturar os fatores que afetam as previsões, é preciso saber quais técnicas utilizar e como combiná-las. Flores & White (1988) propõem uma estrutura que visa a atender a esses fins, estabelecendo, respectivamente, duas dimensões: (i) seleção das técnicas de previsão-base e (ii) seleção do método de combinação. Tal estrutura pode ser visualizada na Figura 6.

Previsão Base	Método de Combinação	
	Objetivo	Subjetivo
Objetiva	A	B
Subjetiva	C	D
Ambas	E	F

**Figura 6 – Estrutura de combinação de previsões**

[fonte: Flores e White, 1988]

A primeira dimensão, ‘seleção das técnicas de previsão-base’, se preocupa com **quais** previsões incluir na combinação e está ligada à tarefa de selecionar as técnicas que irão participar da combinação. De acordo com Zou & Yang (2004), a tarefa de escolher a mais apropriada das previsões pode ser muito difícil, pois a seleção da técnica, como abordado anteriormente, depende de cinco fatores: acurácia, horizonte de previsão, custos de previsão, complexidade e dados disponíveis, sendo que o mais estudado e o mais relevante é o grau de acurácia.

Conforme a Figura 6, as três categorias de previsões-base são objetivas, subjetivas ou ambas. A categoria objetiva engloba alisamento, regressão, modelos *Box-Jenkins* e outros procedimentos com base matemática. A categoria subjetiva inclui todas as

abordagens que envolvem o julgamento humano, tal como grupo focado ou opinião de especialistas. Algumas técnicas de previsão, tanto subjetivas quanto objetivas, já foram abordadas no capítulo anterior.

A segunda dimensão se preocupa com **como** as técnicas devem ser combinadas. Tal preocupação é alvo de estudo há muito tempo. De acordo com Clemen (1989), alguns métodos têm sido desenvolvidos para encontrar a melhor combinação, e o resultado tem sido unânime: combinar previsões conduz ao aumento de acurácia da previsão (combinada) em relação a qualquer previsão individual.

Ainda conforme a Figura 6, a dimensão dos métodos de combinação envolve uma abordagem objetiva ou subjetiva. A abordagem objetiva reflete os métodos que fazem uso da matemática, de forma que os resultados possam ser repetidos. A abordagem subjetiva inclui esforços intuitivos para combinar previsões-base, empregando conhecimento e opinião individual ou de grupo.

O cruzamento dessas duas dimensões gera as seis células da Figura 6. Na célula ‘A’ encontra-se o estudo de Bates & Granger (1969), considerado seminal em combinação de previsões, além de outros métodos de combinação objetiva das previsões.

Clemen (1989) catalogou, até o referido ano, 209 estudos, os quais apresentaram uma taxa de crescimento positiva ao longo dos anos. Face ao grande número de estudos esperado para a atualidade, serão apresentados apenas alguns dos que compõem cada uma das seis células. Porém é importante ressaltar que muitos estudos apresentam sobreposições entre as várias células da Figura 6. Visando a facilitar a explanação dos métodos, primeiramente serão apresentados os estudos que abordaram métodos objetivos de combinação e, em seguida, os estudos sobre métodos subjetivos de combinação.

### 3.1.2. Estudos de métodos objetivos de combinação

O histórico dos métodos de combinação indica que os primeiros estudos sobre o assunto pertencem à célula ‘A’ da Figura 6, onde previsões-base objetivas são combinadas de forma objetiva. Os precursores desse assunto foram Bates & Granger (1969); como já citado anteriormente, eles propuseram que o método de combinar as previsões deveria

constar de uma combinação linear de duas previsões objetivas não-viciadas (ou devidamente corrigidas), dando peso  $w$  para a primeira e peso  $(1-w)$  para a segunda. A equação (3.1) fornece a combinação  $F_c$ .

$$F_c = wF_1 + (1-w)F_2 \quad (3.1)$$

onde:  $w$  é o peso da previsão 1 e  $F_1$  e  $F_2$  são as previsões a serem combinadas.

Os pesos a serem atribuídos a cada previsão poderiam ser iguais; contudo, para esses autores, é desejável dar um peso maior para a previsão que possui os menores erros. Assim, visando a encontrar o valor do peso  $w$ , propuseram a minimização da variância dos erros da previsão combinada. A variância da previsão combinada é dada pela equação (3.2).

$$\sigma_c^2 = w^2\sigma_1^2 + (1-w)^2\sigma_2^2 + 2\rho.w\sigma_1(1-w)\sigma_2 \quad (3.2)$$

onde:  $\sigma_1^2$  e  $\sigma_2^2$  são as variâncias dos erros das previsão a serem combinadas;  $\rho$  é o coeficiente de correlação entre os erros das previsões;  $w$  é o peso dado a previsão 1.

Para minimizar a variância  $\sigma_c^2$ , procede-se a diferenciação da equação (3.2) com relação a  $w$  e iguala-se o resultado a zero. Assim, o mínimo de  $\sigma_c^2$  ocorre quando  $w$  assume o valor dado pela equação (3.3). Por minimizar a variância, esse método ficou conhecido como método da variância mínima.

$$w = \frac{\sigma_2^2 - \rho\sigma_1\sigma_2}{\sigma_1^2 + \sigma_2^2 - 2\rho\sigma_1\sigma_2} \quad (3.3)$$

Para o caso em que os erros não estão correlacionados ( $\rho = 0$ ),  $w$  fica reduzido ao valor dado pela equação (3.4).

$$w = \frac{\sigma_2^2}{\sigma_1^2 + \sigma_2^2} \quad (3.4)$$

Como as variâncias  $\sigma_i^2$  dos erros de previsão não são conhecidas, para calcular o peso  $w$  Bates & Granger (1969) propuseram cinco procedimentos de estimação, tendo

como base os erros de previsão. Newbold & Granger (1974) ampliaram o número de técnicas combinadas, mantendo todas as suposições de Bates & Granger (1969), passando de duas para  $p$  técnicas combinadas. Os mesmos cinco procedimentos de estimação de pesos, propostos pelos precursores, foram utilizados e estendidos à nova situação de combinar mais de duas previsões. Tais procedimentos encontram-se no anexo A.

Através da combinação de três previsões, obtidas de modelos *Box-Jenkins*, de modelos *Holt-Winters* e de auto-regressão *Stepwise*, Newbold & Granger (1974) concluíram que a combinação ponderada, como este método é conhecido, trouxe melhorias na acurácia da previsão combinada. Também concluíram que essas melhorias são freqüentemente obtidas considerando a combinação das três técnicas de previsão, uma vez que os modelos de previsão são hábeis em capturar os diferentes aspectos das informações disponíveis para predição. Além disso, as correlações poderiam ser ignoradas na estimação dos pesos, pois na prática elas têm pouca influência na sua definição.

Winkler & Makridakis (1983) sugerem que os pesos destinados às diferentes previsões também deveriam ser relacionados com a matriz de covariância dos erros de previsão, como fizeram Newbold & Granger (1974); contudo os erros de previsão são erros percentuais, como dado na equação (3.5).

$$e_i = \frac{Y - F_i}{Y}, \quad (3.5)$$

onde:  $Y$  é o valor observado e  $F_i$  é a previsão  $i$ , para  $i = 1, 2, \dots, p$ .

Se a matriz de covariância  $\Sigma$  é conhecida, os pesos ótimos podem ser determinados pela equação (3.6):

$$w_i = \frac{\sum_{j=1}^p \alpha_{ij}}{\sum_{h=1}^p \sum_{j=1}^p \alpha_{hj}}, \quad (3.6)$$

onde:  $w_i$  é o peso da previsão  $i$ , para  $i = 1, 2, \dots, p$  e  $\alpha_{ij}$  é o elemento da matriz  $\Sigma^{-1}$ .

A equação (3.7) apresenta a previsão combinada:

$$F_c = w_1 F_1 + w_2 F_2 + \dots + w_p F_p \quad (3.7)$$

onde:  $w_i$  é o peso da previsão  $i$ , para  $i = 1, 2, \dots, p$  e  $F_i$  é a previsão  $i$ , para  $i = 1, 2, \dots, p$ .

Como na prática a matriz de covariância não é conhecida, os autores utilizaram os procedimentos de estimação de pesos apresentados por Newbold & Granger (1974). O método de combinação dado na equação (3.7), que utiliza os pesos estimados conforme a equação (3.6), ficou conhecido como média ponderada ótima.

Winkler & Makridakis (1983) também analisaram combinações ponderadas entre dez técnicas de previsão, e os resultados obtidos confirmaram as conclusões de Newbold & Granger (1974). Tais resultados consistem na comparação do MAPE (*Mean Average Percentual Error*) médio de 1001 séries temporais, o que lhes permitiu concluir ser melhor ignorar os efeitos da correlação no cálculo de combinações ponderadas.

Granger & Ramanathan (1984) chamaram a atenção para o fato de que os métodos convencionais de combinação de previsões poderiam ser vistos como uma forma estruturada de regressão. Eles argumentam que os métodos são equivalentes ao Método de Mínimo Quadrados Ordinários (MQO), tendo a previsão combinada como variável resposta e as previsões individuais como variáveis explicativas. Assim, propuseram três métodos para combinar previsões de forma linear.

O primeiro refere-se a uma combinação linear sem restrição nos pesos e sem constantes, chamado de método A, igual aos modelos propostos por Newbold & Granger (1974) e Winkler & Makridakis (1983), sendo representado pela equação (3.7); porém seus parâmetros (os pesos) são estimados por MQO.

O segundo, chamado de método B, é uma combinação linear sem constante e com restrição nos pesos, que somam um. Este método está representado pela equação (3.8). Para Taylor & Bunn (1999), tal método é equivalente ao método de variância mínima proposto por Bates & Granger (1969), porém combina mais que duas previsões.

$$F_c = w_1 F_1 + w_2 F_2 + \dots + w_p F_p, \text{ sendo que: } \sum_{i=1}^p w_i = 1 \quad (3.8)$$

O terceiro método de combinação, chamado de método C, é uma combinação linear sem restrições nos pesos, porém com a adição de uma constante, e é representado pela equação (3.9).

$$F_c = w_1F_1 + w_2F_2 + \dots + w_pF_p + K \quad (3.9)$$

onde: K é uma constante e  $K \neq 0$ .

Os autores demonstram matematicamente que é melhor empregar o método de combinação linear não-restrito aos pesos e incluir um termo constante (método C), porque produz um menor erro quadrático médio e uma previsão combinada não-viciada, mesmo quando as previsões individuais são viciadas.

Holmen (1987) simulou dados de três modelos *Box-Jenkins*. Ao combinar as previsões resultantes desses três modelos, utilizando os métodos A, B e C, chegou às mesmas conclusões que Granger & Ramanathan (1984): as combinações de previsões produzem, individualmente, o menor erro quadrático médio que qualquer previsão original e o método C produz o menor erro quadrático médio, para a combinação das três técnicas e para qualquer combinação duas a duas.

Lobo (1991) propôs outro método de combinação ponderada, dado pela equação (3.10). Em sua análise empírica, comparou este método aos três métodos propostos por Granger & Ramanathan (1984) e à média aritmética das previsões. Sua conclusão foi de que a previsão combinada através do uso de combinação linear sem termo constante e sem restrição nos pesos das previsões (método A) é superior aos outros métodos de combinação.

$$F_c = w_1F_1 + w_2F_2 + \dots + w_pF_p + K, \text{ sendo que: } \sum_{i=1}^p w_i = 1 \text{ e } K \neq 0. \quad (3.10)$$

Asku & Gunter (1992) compararam empiricamente onze métodos de combinação de previsões, através dos resultados de três métricas de acurácia: RMSE, MAE e MAPE. Entre os métodos de combinação estudados encontram-se os descritos por Granger & Ramanathan (1984) e por Lobo (1991). Além desses quatro, a média aritmética das previsões e outros seis métodos de regressão estimados por mínimos quadrados com diferentes restrições. As equações (3.11) a (3.16) representam esses métodos com suas restrições.

$$F_c = w_1F_1 + w_2F_2 + \dots + w_pF_p + K, \text{ sendo que: } w_i \geq 0, \forall i \text{ e } K \neq 0 \quad (3.11)$$

$$F_c = w_1F_1 + w_2F_2 + \dots + w_pF_p + K, \text{ sendo que: } w_i \geq 0, \forall i \text{ e } K > 0 \quad (3.12)$$

$$F_c = w_1F_1 + w_2F_2 + \dots + w_pF_p + K, \text{ sendo que: } \sum_{i=1}^p w_i = 1, w_i \geq 0, \forall i \text{ e } K \neq 0 \quad (3.13)$$

$$F_c = w_1F_1 + w_2F_2 + \dots + w_pF_p + K, \text{ sendo que: } \sum_{i=1}^p w_i = 1, w_i \geq 0, \forall i \text{ e } K > 0 \quad (3.14)$$

$$F_c = w_1F_1 + w_2F_2 + \dots + w_pF_p, \text{ sendo que: } w_i \geq 0, \forall i \quad (3.15)$$

$$F_c = w_1F_1 + w_2F_2 + \dots + w_pF_p, \text{ sendo que: } \sum_{i=1}^p w_i = 1, w_i \geq 0, \forall i \quad (3.16)$$

Entre as muitas conclusões obtidas pelos autores, a principal delas é que os métodos cujos pesos são não-negativos e a média aritmética, quase sempre apresentam métricas superiores à dos demais. Concluíram, também, que os métodos com pesos não-negativos são tão acurados e robustos quanto a média aritmética.

Para Gupta & Wilton (1987), devido às dificuldades de estimação dos pesos, métodos mais sofisticados, tais como os propostos por Newbold & Granger (1974) e Granger & Ramanathan (1984), nem sempre têm apresentado um bom desempenho em estudos empíricos, como, por exemplo, o estudo de Clemen & Winkler (1986). Além disso, em alguns casos os pesos obtidos não são intuitivos e dificultam a interpretação. Face a muitas controvérsias sobre qual o melhor método e às dificuldades na estimação dos pesos, os autores propõem o uso de um procedimento simples para combinar previsões, a média aritmética das previsões. Conforme Armstrong & Collopy (1998), este método serve como um ponto de referência útil e, em algumas aplicações, demonstrou ser relativamente robusto e mais acurado que métodos mais elaborados (CLEMEN & WINKLER, 1986, GUPTA & WILTON, 1987 e ASKU & GUNTER, 1992).

Para Makridakis & Winkler (1983), utilizar a média das previsões é indubitavelmente melhor que usar um “mau” modelo ou uma técnica de previsão pobre, uma vez que os resultados registrados pelos autores sugerem que o uso de média das previsões traz consideráveis benefícios práticos em termos de melhoria da acurácia de previsão e de diminuição da sua variabilidade. Quando não há informações sobre a dependência entre as previsões, ou quando não há informações disponíveis sobre a precisão de cada técnica de previsão, parece ser razoável utilizar a média das previsões (CLEMEN & WINKLER, 1986, e BESSLER & BRANDT, 1981).



Além disso, de acordo com Taylor & Bunn (1999), a média, além de ser um método importante, é o método de combinação mais empregado. Para Menezes *et al.* (2000), uma possível resposta para o sucesso da média aritmética pode estar associada à instabilidade dos pesos que, freqüentemente, resultam de mudanças não-sistemáticas que ocorrem ao longo do tempo na matriz de covariância dos erros das previsões individuais. Devido a estas circunstâncias, a média, embora não tenha pesos ótimos, pode dar origem a resultados melhores que os de métodos mais sofisticados.

Por fim, Makridakis & Winkler (1983) salientam que médias de previsões não estão restritas a combinações que utilizam somente técnicas de séries temporais (técnicas objetivas), como foi o caso estudado pelo autores, devendo ser considerada toda e qualquer informação disponível. Isto significa que as previsões vindas de diferentes tipos de fontes devem ser consideradas. Os autores acreditam que possam ser combinadas previsões advindas de técnicas de séries temporais, previsões advindas de modelos econométricos e previsões subjetivas, advindas de especialistas, ou seja, acreditam na possibilidade de combinar objetivamente previsões-base do tipo subjetiva e objetiva. Tal sugestão será abordada quando os métodos pertencentes à célula ‘E’ da Figura 6 forem explanados.

Mesmo sendo a média aritmética das previsões uma boa opção para combiná-las, muitos autores continuaram na busca pelo melhor método de combinação. Para Deutsch *et al.* (1994), como a vasta maioria das combinações lineares considera pesos fixos, a combinação de pesos que variam no tempo é uma área a ser investigada. Com o intuito de realizar tal investigação, os autores propõem, com base no uso dos modelos de *switching regression*, dois métodos de combinação de previsões, chamados de ‘*switching regime models*’ e ‘*smooth transition models*’.

O método ‘*switching regime models*’ considera um regime ou estado em que a combinação de previsões está sendo realizada. A equação que modela o método para combinar duas previsões é dada pela equação (3.17).

$$F_{t,C} = I(t \in I_1)(w_1F_{t,1} + w_2F_{t,2}) + (1 - I(t \in I_1))(w_3F_{t,1} + w_4F_{t,2}) \quad (3.17)$$

onde:  $F_{t,C}$  é a previsão combinada no tempo  $t$ ,  $I$  é o regime;  $I(t \in I_1) = 1$  quando  $t \in I_1 = 0$  e  $F_{t,i}$  é a previsão  $i$  no tempo  $t$ .

Em alguns casos, quando é mais apropriado assumir uma mudança gradual nos pesos da combinação para duas previsões, os autores sugerem o método ‘*smooth transition models*’, representado na sua forma genérica pela equação (3.18):

$$F_{t,C} = (1 + e^{\gamma V_{t-1}})^{-1} (w_1 F_{t,1} + w_2 F_{t,2}) + (1 - (1 + e^{\gamma V_{t-1}})^{-1}) (w_3 F_{t,1} + w_4 F_{t,2}) \quad (3.18)$$

onde:  $V_{t-1}$  é uma função do erro de previsão defasado e  $\gamma$  é um valor que minimiza a soma do quadrado dos erros.

Para o primeiro método os autores examinaram seis opções para  $I_1$ , entre elas citam-se duas: (i)  $I_1$  é  $Z_{t-1,1} \geq 0$ , sendo  $Z_{t,1} = Y_{t+1} - F_{t,1}$  e (ii)  $I_2$  é  $Z_{t-1,2} \geq 0$ , sendo  $Z_{t,2} = Y_{t+1} - F_{t,2}$ . Já para o segundo método foram analisados quatro modelos, um deles foi  $V_{t-1} = Z_{t-1,1}$ .

Visando a analisar os dez modelos propostos, os autores utilizaram dois exemplos: o índice de inflação dos Estados Unidos e o índice de inflação do Reino Unido, concluindo que os métodos de combinação de pesos que variam no tempo podem trazer reduções substanciais à soma dos quadrados dos erros e que os exemplos empíricos constataam que as combinações propostas podem gerar previsões superiores às dos modelos de previsão que utilizam pesos fixos.

Ridley (1995), discorrendo sobre as suposições ideais de independência, linearidade e normalidade da população, afirma que um modelo linear gera o menor erro quadrático médio de previsões. Na prática, a maioria das séries históricas são modeladas por variáveis independentes e defasadas no tempo, o que gera auto-correlação. Para resolver esta situação, o autor propôs o método antitético de combinação: em sua definição, duas previsões são antitéticas se seus erros são perfeita e negativamente correlacionados. Tal definição baseia-se na idéia de que se as previsões têm erros iguais, mas com sinais opostos, eles se cancelam.

Para estabelecer a previsão antitética são necessárias duas previsões, uma proveniente da série original dos dados, e outra, da série antitética. A série antitética é obtida através de uma regressão linear simples, sendo a série original uma variável

independente, de forma que os erros sejam assintótica e negativamente correlacionados. Uma vez estabelecidas as séries e suas respectivas previsões obtidas, a previsão combinada é dada pelo método expresso na equação (3.19):

$$F_{t,C} = w_1 F_t + w_2 F_t' \quad \text{para } t=1,2,3,\dots \quad (3.19)$$

onde:  $F_{t,C}$  é a previsão combinada no tempo  $t$ ;  $\sum_{i=1}^2 w_i = 1$ ;  $F_t$  é a previsão da série original  $Y$  no tempo  $t$  e  $F_t'$  é a previsão da série antitética  $Y^A$  no tempo  $t$ , que é obtida conforme a equação (3.20).

$$F_t' = \bar{y} + \text{cov}(y, y^A)(s_y / s_{y^A})(\hat{y}_t - \bar{y}^A) \quad (3.20)$$

Ainda segundo Ridley (1995), o método descrito é independente do modelo (da técnica objetiva) de previsão, podendo ser legitimamente classificado como uma combinação de previsão. Dessa forma, ele pode ser usado como um retro-ajuste em qualquer modelo de previsão existente. Outro benefício deste método de combinação é que o ganho na acurácia aumenta junto ao horizonte de previsão.

Um estudo que traz uma interessante contribuição empírica é o de Chan *et al.* (1999). Nele, os autores utilizam as previsões de demanda por formulários de um grande banco de Hong Kong, comparando quatro métodos de combinação de previsões. Os métodos analisados foram: (i) média aritmética; (ii) pesos fixos; (iii) pesos com janela móvel de 12 meses e (iv) pesos mais altos. Este último não é uma combinação, mas, sim, a técnica que apresenta-se como a mais acurada no período estimado. As técnicas utilizadas para obter as previsões-base foram modelos de alisamento exponencial, modelos *Box-Jenkins* e modelos de regressão.

Ao comparar o comportamento da demanda em dez séries de diferentes formulários através do RMSE (*Root Mean Square Error*), os autores confirmaram que combinar previsões aumenta significativamente o desempenho das mesmas. Além disso, concluíram que atualizar os pesos todos os meses era notoriamente inferior (em termos de acurácia) do que utilizar pesos fixos, obtidos uma vez por ano.

Os resultados obtidos por Chan *et al.* (1999) são razoáveis caso o processo seja estável e os pesos, ótimos. Em tal circunstância, não há necessidade de mudanças de pesos. Contudo, se existe uma mudança no processo, os pesos deveriam ser alterados (CHAN *et al.*, 2004).

Com o intuito de resolver o problema de quando os pesos devem ser alterados, em vista da ocorrência de alguma mudança, seja pequena ou grande, Chan *et al.* (2004) propõem o método de combinação de previsão intitulado por eles de método de controle de pesos. Esse método consiste em utilizar a técnica de CUSUM (gráfico de controle de soma cumulativa) para atualizar os pesos somente se as previsões ultrapassarem os limites de controle (obtidos, nesse estudo, pela forma tabelar<sup>1</sup>).

Os autores utilizaram as mesmas dez séries de demanda por formulários de um banco de Hong Kong para comparar o comportamento de pesos ajustados em 6 meses, em 12 meses e o método proposto. Os resultados mostraram, através da comparação do desempenho da soma do RMSE das dez séries, que o método proposto apresenta o melhor desempenho devido à habilidade de indicar o momento apropriado para a atualização.

Cabe ressaltar que outras alternativas foram desenvolvidas, mas são abordagens bayesianas, não sendo, porém, o foco desta tese. O método *Outperformance*, através do qual os pesos para as previsões individuais são interpretados como a probabilidade que cada previsão irá desempenhar melhor na próxima ocasião, estima as probabilidades considerando a proporção de vezes em que a respectiva previsão teve melhor desempenho no passado. Este método foi desenvolvido por Bunn (1975), que pode ser consultado para um maior detalhamento. O método *Odds-Matrix* é especialmente útil quando existem poucos dados disponíveis ou problemas de estacionariedade dos erros, baseado no método *Outperformance* e desenvolvido por Gupta & Wilton (1987), que pode ser consultado para um aprofundamento. LeSage & Magura (1992) propuseram um método que estende o C de Granger & Ramanathan (1984), sendo os pesos usados na combinação passíveis de mudança ao longo do tempo. Para Zou & Yang (2004), o modelo selecionado é, muitas vezes, instável, e pode causar uma alta variabilidade na previsão final. Por isso, eles propuseram o uso de um algoritmo para combinar modelos, sendo que, para cada

---

<sup>1</sup> Para detalhes consultar: Montgomery, D.C. **Introduction to Statistical Quality Control**, John Wiley & Sons, New York, 1991.

observação adicional incluída na análise, ocorre uma atualização nos pesos da combinação. Os autores exemplificaram seus estudos ajustando quatro conjuntos de dados a modelos ARIMA e verificaram, assim, o desempenho do algoritmo.

Combinar objetivamente previsões-base objetivas continua sendo alvo de pesquisa, não apenas visando a encontrar novos métodos, mas também a que os métodos já existentes sejam aplicados adequadamente, através do estudo dos pressupostos e das métricas de eficiência.

De acordo com Flores & White (1988), os primeiros esforços foram feitos para combinar objetivamente previsões com base objetiva, tais como as propostas apresentadas anteriormente. Ainda segundo os autores, a combinação objetiva utilizando previsões com base subjetiva, referentes aos métodos pertencentes à célula 'C', da Figura 6, foi explanada por Ashton & Asthon (1985) e por alguns estudos cujo enfoque é bayesiano.

Apesar de não ter sido catalogado por Flores & White (1988), um importante estudo sobre combinação objetiva de previsões com base subjetiva é o de Figlewski & Ulrich (1983). Os autores apresentam um procedimento linear para agregar previsões subjetivas à combinação, a fim de capturar tanta informação quanto possível. A equação (3.21) é a expressão final da demonstração do método proposto, um método linear não-viesado de variância mínima.

$$F_t^c = (\underline{1}'\Sigma^{-1}\underline{1})^{-1}\underline{1}'\Sigma^{-1}(F_t + \underline{b}) \quad (3.21)$$

onde:  $\underline{1}$  é o vetor identidade;  $\Sigma$  é a matriz de covariância dos erros;  $F_t$  é o vetor de previsões para  $n$  previsores no tempo  $t$  e  $\underline{b}$  é o vetor de média dos erros.

Quando se assumem erros com média zero, independentes e identicamente distribuídos, tem-se a média aritmética. Para o método proposto, foram estudados quatro modelos estruturados com base no relaxamento progressivo das restrições sobre a matriz de covariância e sobre os erros. O modelo média assume que a matriz de covariâncias é uma matriz identidade. O modelo diagonal assume que os erros de previsão são independentes, mas que algumas previsões são mais acuradas que outras. O modelo chamado de sem restrição é aquele cuja matriz de covariâncias não possui nenhum tipo de restrições e, por fim, o modelo índice-simples é aquele onde se assume que cada erro do

previsor é constituído por uma parte independente dos demais erros de previsão acrescida da parte proporcional a um erro comum.

Ao analisar seus modelos em uma aplicação na área financeira, os autores concluíram que o modelo média e que o modelo diagonal possuem a mesma acurácia, através da análise do RMSE. Já o modelo de índice-simples não é tão acurado; o menos acurado deles é o modelo sem restrição.

Ashton & Asthon (1985) analisaram a acurácia de previsão de cinco métodos de combinação ponderada. O estudo foi baseado em 42 observações reais relativas à quantidade anual de propaganda na revista *Time* e realizado por treze funcionários voluntários da empresa. Os métodos de combinação utilizados foram: (i) média aritmética das previsões; (ii) pesos ponderados pelo erro absoluto médio, sendo o peso obtido pela razão entre o erro absoluto médio das 42 previsões de cada previsor e a soma dessa medida para os 13 previsores; (iii) pesos ponderados pelas correlações entre as observações e as previsões de cada previsor, sendo o peso obtido da razão entre a correlação de cada previsor e a soma dessa medida para os 13 previsores; (iv) o método que consiste na divisão entre o *rank* obtido pelo previsor, conforme sua posição hierárquica na empresa, e o somatório dos *rankings* das posições hierárquicas e (v) similar ao método anterior, sendo que o *rank* atribuído aos previsores é dado por um executivo experiente.

Para cada um dos cinco métodos, foram obtidas todas as combinações possíveis de previsões agregadas compostas de  $k$  indivíduos<sup>2</sup> ( $k = 1,2,\dots,13$ ). Após, foi calculado o MAPE para cada  $k$ , sendo tal resultado utilizado para comparação dos métodos e obtenção de conclusões.

Os autores concluíram que a agregação de previsões subjetivas foi mais acurada do que as previsões individuais que formaram a agregação. Além disso, na medida em que aumenta o número  $k$  de indivíduos combinados, o aumento da acurácia, para os métodos ponderados, em relação à média, foi pequeno. Assim, a abordagem simples de pesos iguais

---

<sup>2</sup> Por exemplo, a previsão agregada baseada em combinação de  $k=3$  indivíduos. Para combinar 13 previsões em grupos de 3 obtém-se 286 combinações.

para todas as previsões dos indivíduos (média) parece ser a solução promissora para o problema da escolha do método de combinação.

Ainda conforme Ashton & Asthon (1985), independente do método de combinação utilizado, pequenas agregações ( $k$  pequeno) contribuíram muito para o ganho total da acurácia. Esse é um importante resultado no contexto da previsão subjetiva, porque o custo associado à inclusão de novos previsores pode ser substancial. Embora a acurácia possa ser aumentada pela contínua inclusão de previsores na combinação, o balanço entre o aumento da acurácia e os custos associados à inclusão de indivíduos deve ser considerado.

Mesmo muitos anos depois da publicação desses estudos, nenhuma outra referência não-bayesiana foi encontrada sobre esse tipo de combinação. Tal situação deve-se, possivelmente, aos resultados obtidos com os estudos em que as previsões objetivas promovem ganhos na acurácia e, também, aos estudos realizados com a combinação de previsões objetivas e subjetivas.

A terceira forma de combinar previsões objetivamente é através da utilização de previsões-base subjetivas e objetivas na mesma combinação, como proposto por Makridakis & Winkler (1983). Tal forma de combinação de previsões se refere à célula 'E' da Figura 6.

Bressler & Brandt (1981) aplicaram métodos de combinação de previsões para prever o preço de gado, porco e aves. Nesse estudo, os autores utilizaram três métodos de combinação. O primeiro foi o método da variância mínima, estimando os pesos através do procedimento 1 do anexo A. O segundo método, chamado de adaptativo, consiste em multiplicar os pesos obtidos no método anterior por  $\frac{1}{p-1}$ , sendo que  $p$  é o número de previsões que compõe a combinação, a fim de que a combinação de previsões viesadas resultasse em uma combinação não-viesada. O terceiro método utilizado foi a média aritmética.

Nesse estudo, as técnicas de previsão-base utilizadas para combinar previsões foram: um modelo *Box-Jenkins*, um modelo econométrico e a opinião de especialistas. A média das previsões obtidas com as três técnicas teve melhor desempenho para o preço da

carne de porco. Para o preço das carnes de gado e de aves, o método que apresentou menor erro quadrático médio foi o adaptativo, para combinação dos modelos *Box-Jenkins* e econométrico.

Granger & Ramanatan (1984) também utilizaram dados dos preços da carne de porco, cedidos e atualizados por Bressler & Brandt, para comparar os três métodos de combinação de previsão propostos por eles. O estudo realizado é uma aplicação da combinação de um modelo econométrico, um modelo *Box-Jenkins* e da opinião de especialistas, em dados trimestrais do preço da carne de porco. Os autores encontraram que o erro quadrático médio da combinação das três técnicas ou de qualquer combinação duas a duas dos três métodos é menor que o erro quadrático médio de qualquer previsão individual. Além disso, o método C apresentou os menores erros quadráticos médios quando comparado aos métodos A e B, para a combinação das três técnicas e para qualquer combinação duas a duas.

Pereira *et al.* (1989) combinaram previsões de operadores do mercado financeiro e uma previsão objetiva obtida do método conhecido como Filtro Adaptativo<sup>3</sup>, para a operação financeira conhecida como *overnight*. A previsão final foi obtida pela combinação dada na equação (3.22).

$$F_c = w_1 F_1 + w_2 F_2 + \dots + w_p F_p + (1 - w_1 - \dots - w_p) F_{FA}, \quad (3.22)$$

onde:  $F_i$  é a previsão subjetiva do previsor  $i$ , para  $i = 1, 2, \dots, p$ ;  $F_{FA}$  é a previsão obtida pelo método do filtro adaptativo e  $w_i$  é o peso da previsão  $i$  estimado.

Nesse estudo, os pesos foram obtidos de forma recursiva, pela estimação por mínimos quadrados do modelo de regressão dado na equação (3.23).

$$Y_t = F_t w_t + \varepsilon \quad (3.23)$$

onde:  $Y_t$  é o vetor de observações no tempo  $t$ ;  $F_t$  é a matriz das previsões no tempo  $t$ , com  $t=1, 2, \dots, n$ ;  $\varepsilon$  é o vetor de erros no tempo  $t$  e  $w_t$  é o vetor transposto de pesos a serem estimados no tempo  $t$ .

---

<sup>3</sup> Para maiores detalhes os autores do estudo indicam Makridakis, S. & Wheelwright, S.C. **Forecasting: Methods and Applications**, New York, Wiley, 1978.



Entre as conclusões obtidas pelos autores, uma é de que essa maneira de previsão, utilizada diariamente durante quatro anos, apresentou os melhores resultados, em termos da média dos erros absolutos, ao ser comparado à previsão obtida pelo operador mais experiente, pelo método do filtro adaptativo, pelo melhor operador e filtro adaptativo ou pela combinações de dois a  $p$  operadores.

Blatteberg & Hogh (1990) analisaram dados de cinco companhias para indicar que a melhor opção de combinação é utilizar pesos iguais para previsões objetivas e subjetivas (média), quando comparada a métodos de combinação linear que utilizam qualquer outra proporção de pesos. Primeiramente, os autores obtiveram as previsões objetivas e subjetivas, através de modelos de regressão e de modelos *bootstrapping* subjetivo, respectivamente. Após, para todas as proporções de pesos - iniciando com a configuração peso 1 para previsão objetiva e zero para subjetiva, passando, por exemplo, pela configuração 0,8 para a previsão objetiva e 0,2 para subjetiva até a configuração puramente subjetiva - foi calculado o valor do coeficiente de determinação  $r^2$  da combinação de previsões.

Ao compararem os valores de  $r^2$  da média com o valor  $r^2$  do ponto ótimo (proporção de pesos que fornece maior  $r^2$ ), encontraram desvios próximos de 1% para as cinco companhias estudadas. Aliados aos resultados numéricos obtidos, os autores argumentaram a favor da média em função de três vantagens: (i) simplicidade, pois é fácil de entender; (ii) possibilidade de controle sobre o processo de tomada de decisão e (iii) acurácia, sendo a média mais acurada que as previsões individuais.

Sanders & Ritzman (1990) estudaram a demanda dos consumidores de um armazém público com base em dados diários. Foram analisados dados de 22 séries diferentes, estratificadas em quatro grupos: baixa, baixa-média, alta-média e alta variabilidade, classificação operada com base no valor do coeficiente de variação. O objetivo desse estudo era verificar a melhora da acurácia, medida através do MAPE, ao agregar a previsão subjetiva à combinação. O método de combinação usado foi a média aritmética, sendo formada por três técnicas de previsão com base objetiva: dois modelos de alisamento e um modelo de regressão linear.

Após comparar o MAPE da combinação puramente quantitativa com a agregação da previsão subjetiva, os autores concluíram que o nível de melhoria obtido com a agregação de previsões subjetivas supera as combinações puramente quantitativas nos quatro grupos citados. Além disso, para séries com alta volatilidade, onde todas as opções apresentaram desempenho fraco, a previsão subjetiva forneceu os melhores resultados.

Utilizando os mesmos dados, Sanders e Ritzman (1995) combinaram, através do método de combinação de pesos iguais (média), três técnicas para compor a previsão objetiva: alisamento exponencial simples, modelos de alisamento de *Holt* com dois parâmetros e procedimento de estimação adaptativo, e, visando verificar seus objetivos, utilizaram duas previsões subjetivas, uma com especialistas e outra com estudantes.

O objetivo específico era avaliar a contribuição das previsões subjetivas, com ou sem conhecimento acumulado<sup>4</sup>, ao combiná-las com previsões objetivas. Para tanto, testaram três níveis de pesos, nomeados de baixo, médio e alto, de acordo com o peso atribuído à previsão subjetiva, respectivamente apresentados nas equações de (3.24) a (3.26). Cabe ressaltar que a soma dos pesos, nessas equações, é igual a um.

$$F_c = 0,75 * F_o + 0,25 * F_s \quad (3.24)$$

$$F_c = 0,5 * F_o + 0,5 * F_s \quad (3.25)$$

$$F_c = 0,25 * F_o + 0,75 * F_s \quad (3.26)$$

onde:  $F_c$  é a previsão combinada;  $F_o$  é a previsão objetiva, dada pela combinação de três técnicas estatísticas e  $F_s$  é a previsão subjetiva.

Além disso, os autores verificaram a influência da agregação da opinião nas previsões objetivas, para os quatro grupos de séries com variabilidade diferenciadas, classificadas no estudo anteriormente realizado pelos mesmos.

Utilizando o MAPE para tecer suas comparações, os autores mostram que o MAPE médio da combinação da previsão objetiva com a previsão dos especialistas aumentou significativamente a acurácia das previsões sobre as outras combinações. Para comprovar tal melhoria, foi empregado o teste de *Wilcoxon* para duas amostras pareadas. Por outro

---

<sup>4</sup> Conhecimento que os previsores adquirem com a experiência de utilizar informações contextuais.

lado, previsões subjetivas de estudantes, baseadas em conhecimento técnico<sup>5</sup>, não apresentam o mesmo grau de contribuição que as previsões combinadas.

Concluíram, também, que a necessidade de inclusão da opinião é função da variabilidade da série temporal. Para séries estáveis, a inclusão de opinião não melhora significativamente a acurácia, sendo, portanto, a previsão objetiva a melhor escolha. Para séries que apresentam variabilidade moderada ou alta, a inclusão da opinião fornece uma melhora significativa na acurácia. Por fim, para séries com alta variabilidade, a utilização individual de previsões subjetivas, provenientes de especialistas, pode ser a melhor alternativa.

É inegável que a agregação de previsões subjetivas às previsões objetivas trouxeram um ganho à acurácia. Contudo o método objetivo de combinação a ser utilizado continua sendo um ponto de estudo, face à grande quantidade de métodos propostos e suas múltiplas formas de serem comparados. Uma alternativa que apresenta diversas vantagens, devendo ser considerada no momento da escolha, é a média aritmética.

### 3.1.3. Estudos de métodos subjetivos de combinação

Uma vez que, para combinar subjetivamente previsões, utiliza-se a intuição e o conhecimento adquirido, dificilmente o procedimento que forma a combinação pode ser repetido. Por isso, combinar subjetivamente previsões-base objetivas ou subjetivas é uma alternativa relativamente inexplorada.

Na célula 'B' da Figura 6, Flores & White (1988) citam a o trabalho de Chunglo (1985), o qual descreve a situação de uma empresa onde funcionários, incluindo representantes de produção e de *marketing*, reúnem-se para combinar previsões obtidas através da aplicação de diferentes métodos estatísticos. Nessa célula pode ser incluído o uso de qualquer forma intuitiva de combinar previsões objetivas como, por exemplo, especialistas analisando previsões provenientes de modelos econométricos e/ou modelos de alisamento exponencial utilizados em um grupo focado para obter uma previsão subjetivamente combinada.

---

<sup>5</sup> Conhecimento técnico se refere a informações obtidas pelo conhecimento de análise de dados e técnicas de previsão.

Estudos da célula 'D' da Figura 6, pertinentes à combinação subjetiva de previsões-base subjetivas, aparecem em menor número que métodos objetivos. Larreché & Moinpour (1983) utilizaram, na realização de seu estudo, cinco métodos de combinação: (i) média das previsões dos indivíduos envolvidos no estudo (método objetivo); (ii) obtenção de consenso do grupo; (iii) método *Delphi*; (iv) seleção do melhor especialista identificado com uma medida própria de conhecimento e (v) seleção do melhor especialista identificado com uma medida externa de conhecimento.

Empregando o MAPE para obter seus resultados, os autores concluíram que a média fornece estimativas comparáveis, em qualidade, àquelas obtidas pelo consenso de grupo. Além disso, concluíram que as estimativas do método *Delphi* são melhores que a média e o consenso de grupo. Cabe salientar que, nesse estudo, os autores propõem e utilizam o método *Delphi* e o consenso de grupo, conhecidas técnicas de previsão subjetiva, como métodos de combinar subjetivamente previsões.

Outro estudo referente a essa classificação é o estudo de Flores & White (1989). Eles realizaram um experimento para analisar a acurácia de combinações subjetivas usando como base previsões subjetivas. Compararam, também, diferentes métodos objetivos de combinação com as previsões combinadas subjetivamente.

Segundo os autores, as combinações subjetivas foram constituídas da seguinte forma: primeiramente, foram formados grupos aleatórios de dois ou três sujeitos; após, cada grupo desenvolveu sua previsão (de grupo), combinando subjetivamente suas previsões pessoais, sendo que não era permitido obter as médias das previsões.

Com base neste experimento, os autores concluíram que a combinação subjetiva de previsões fornece resultados mais acurados que os métodos objetivos de combinações estudados (média aritmética e médias ponderadas). Além disso, para esse estudo, a combinação subjetiva forneceu um maior ganho na acurácia quando poucas previsões foram combinadas (em torno de duas a quatro).

Collopy & Armstrong (1992) compararam as previsões obtidas no *Rule-Based* com as previsões provenientes do passeio aleatório (*random walk*) e da média aritmética dos

especialistas, através da acurácia medida por: MdAPE, MAPE, MdRAE, GMRAE. O *Rule-Based*, método proposto pelos autores, consiste em um procedimento subjetivo, composto por várias regras, no qual os especialistas aplicam seu conhecimento para produzir previsões de acordo com as características dos dados, tais como variação, tendência, *outliers*.

Utilizando 126 séries temporais, os autores verificaram que o *Rule-Based* é mais acurado que o passeio aleatório. Além disso, verificaram também que o *Rule-Based* é significativamente mais acurado que a média - reconhecida como método com bom desempenho - para séries com tendência, baixa variabilidade e onde existia domínio do conhecimento.

Para Maines (1996), pouco se conhece sobre como combinar subjetivamente previsões individuais. A autora, visando a minimizar esta lacuna da literatura, examinou como os indivíduos formam uma combinação subjetiva usando previsões obtidas por especialistas e qual a influência das características dos especialistas e dos aspectos do contexto de previsão. Para atingir seus objetivos, a autora trabalhou com estudantes de M.B.A que realizaram três previsões de vendas de uma empresa fictícia. Além disso, executou dois experimentos para examinar a percepção desses estudantes através de uma escala *Likert* de nove pontos.

O primeiro experimento analisou a percepção dos previsores com relação à direção e ao grau de viés, isto é, se eles acreditavam que suas previsões eram otimistas ou pessimistas e, também, se o viés afeta a previsão combinada. Utilizando medidas de correlação, a autora concluiu que acurácia da previsão combinada parece não estar diretamente relacionada ao grau de otimismo dos previsores. Porém os previsores que acreditam na influência do viés em suas previsões tendem a obter um menor ganho ao combinar previsões.

No segundo experimento, os previsores receberam informações sobre a acurácia e sobre a dependência de suas previsões. Com base nessas informações, os previsores foram solicitados a fornecer uma previsão combinada que representasse a sua melhor estimativa e, também, a utilizar a escala de *Likert* para indicar o quanto era relevante eles acreditarem nas medidas de acurácia e de dependência fornecidas. Com o uso da ANOVA, foi possível

verificar diferença significativa na acurácia média das previsões individuais, ao serem comparadas à condição em que as previsões individuais têm acurácia igual e quando as previsões individuais apresentam acurácia desiguais. Contudo a hipótese de igualdade da média das previsões entre a condição de dependência e de independência não pode ser rejeitada.

Com os resultados encontrados, a autora conclui que: (i) quando os sujeitos acreditam que os previsores são otimistas, eles também ajustam de forma otimista as previsões descendentes; (ii) quando acreditam que os previsores são pessimistas, não realizam um ajustamento correspondente, ou seja, pessimista, para previsões ascendentes; (iii) o conservadorismo encontrado, em média, para previsões individuais combinadas, desaparece quando os indivíduos têm informações sobre a acuracidade das previsões.

Evidencia-se, assim, que as previsões individuais combinadas são influenciadas pelas características dos previsores e por aspectos do contexto de previsão.

Por fim, tem-se a célula 'F' da Figura 6, onde previsões com base objetiva e subjetiva são combinadas subjetivamente. Em relação a essa célula, a única referência encontrada foi o estudo clássico da literatura de combinação de previsões, que, na realidade, apresenta vários métodos de combinação pertinentes a mais de uma célula da Figura 6. Esse estudo é o de Lawrence *et al.* (1986). Nele, os autores buscam respostas sobre a melhoria da acurácia e, também, sobre a influência de características da série temporal na acurácia da previsão, usando dois grupos de estudantes como previsores.

As técnicas-base de previsão utilizadas foram: (i) a técnica gráfica, que consiste no previsor traçar a sentimento (*eyeballing*) uma linha que representa o comportamento da variável em estudo; (ii) a técnica tabela, similar à (i), formando uma tabela em lugar de traçar uma linha e (iii) o alisamento exponencial simples desestacionalizado (DSE). Os resultados do estudo foram baseados em nove métodos de combinação: (i) média das previsões da técnica gráfica produzidas pelos dois grupos; (ii) média das previsões da técnica tabela produzidas pelos dois grupos; (iii) a melhor estimativa entre as combinações entre a técnica gráfica e a técnica tabela; (iv) média ponderada das previsões gráfica e da

tabela; (v) método híbrido<sup>6</sup>, através do qual a previsão é obtida com base nas previsões dos nove primeiros períodos da técnica gráfica e nas previsões dos nove períodos consecutivos da técnica tabela; (vi) a melhor estimativa, entre os dois grupos, da média da técnica gráfica e do DSE; (vii) a melhor estimativa, entre os dois grupos, da média da técnica tabela e do DSE; (viii) a média da técnica gráfica, da tabela e do DSE e (ix) opiniões combinadas, onde a previsão é derivada de considerações não-sistemáticas das previsões gráfica e de tabela produzidas pelos previsores.

Dentre muitas conclusões obtidas através da comparação do MAPE, os autores confirmam que a acurácia da combinação é sempre maior que as previsões que a constituem, mas a conclusão mais importante é de que, para aumentar a acurácia da combinação, previsões subjetivas devem ser combinadas objetivamente ao invés de subjetivamente. Tal conclusão explica a lacuna existente na célula 'F' da Figura 6, além da lacuna nas células 'B' e 'D'.

#### 3.1.4. Considerações finais sobre combinação de previsões

Para Mahmoud (1989), existem três razões que encorajam o uso de combinação de previsões: (i) a combinação de previsões melhora a acurácia e diminui a variância do erro de previsão; (ii) os usuários que possuem pouca experiência com combinação podem utilizar métodos simples de combinação, que também trazem melhoras à acurácia e (iii) a combinação pode ser feita com pouco ou nenhum custo.

Desde os estudos iniciais de combinação de previsões, resultados de experimentos empíricos têm mostrado que a combinação é mais acurada que qualquer previsão individual formadora da combinação (RAUSSER & OLIVEIRA, 1976; CLEMEN, 1989; MAKRIDAKIS *et al.*, 1998 e ARMSTRONG, 2001a). Além disso, a demonstração teórica de que a combinação de várias previsões (objetivas) é superior a qualquer uma individualmente, para o método de variância mínima, foi realizada por Dickinson (1975), que pode ser consultado para maiores detalhes.

---

<sup>6</sup> Método proposto pelos autores, para um aprofundamento veja Lawrence, M. J., Edmunson, R. H. e O'Connor, M. J. An Extrapolation of the Accuracy of Judgmental Extrapolation of Time Series. **International Journal of Forecasting**, v.1, n.1, 1985, p.25-36.

Segundo Gupta & Wilson (1987), se os modelos são ‘conhecidos’ *a priori* como tendo acurácias diferentes, esta informação deveria ser incorporada à previsão combinada. Similarmente, para Armstrong (2001a), quando existem evidências de que determinada técnica possui maior acurácia que outras em uma certa situação, ela deveria representar um peso maior na combinação.

Já para Makridakis & Winkler (1983), a acurácia da combinação de previsões depende do número de técnicas e das técnicas específicas que estão sendo combinadas. A variabilidade nas medidas de acurácia está associada à escolha das técnicas e pode ser reduzida com a inclusão de mais técnicas. Porém, se a melhor técnica pode ser identificada com antecedência, o ganho obtido com a combinação de outras técnicas pode ser mínimo.

Ainda conforme Makridakis & Winkler (1983), a acurácia aumenta de acordo com o número de técnicas combinadas, embora o grau de saturação tenha sido encontrado com o emprego de quatro ou cinco técnicas. Libby & Blashfield (1978) registram que a maioria das melhorias na acurácia foi obtida com a combinação de duas ou três previsões.

Para Winkler (1989), o aumento no número de previsões incluídas na previsão combinada pode ser comparado ao aumento do tamanho da amostra em um estudo estatístico, embora a existência de dependência entre as previsões formadoras da previsão combinada determine que a quantidade de informações que irão compor a previsão final seja menor, o que a tornará menos acurada. Além disso, estudos empíricos têm mostrado que erros de previsão provenientes do uso de diferentes técnicas são, quase sempre, altamente correlacionados, e que médias ponderadas dependentes da estimativa das correlações têm apresentado, na prática, um desempenho muito fraco (NEWBOLD & GRANGER, 1974; WINKLER & MAKRIDAKIS, 1983 e CLEMEN, 1989).

Ainda de acordo com Winkler (1989), fatores complicadores, tais como dependência, incerteza sobre as características das previsões e instabilidade no processo de previsão sugerem que seria proveitoso obter combinações de técnicas relativamente robustas em relação a esses fatores. Esta possibilidade explica o bom desempenho de regras simples em estudos empíricos, tal como a média de previsões. A média não requer estimação de parâmetros e, por esse motivo, não é foco de problemas de estimação associados aos fatores mencionados acima. De um ponto de vista prático, pode ser mais



efetivo considerar a média e gerar previsões adicionais ao invés de refinar o procedimento de combinação.

Segundo Makridakis & Winkler (1983), usar uma combinação com técnicas relativamente simples pode ser mais barato e menos arriscado que usar uma técnica mais complexa e que requer análise personalizada dos dados.

Para Chambers *et al.* (1971), os custos de previsão aumentam à medida que as técnicas vão ficando mais sofisticadas; como consequência, os custos de acurácia diminuem à medida que as técnicas tornam-se mais simples. Assim, conforme Mahmoud (1989), os previsores devem considerar cuidadosamente os custos envolvidos na combinação de previsões, avaliando a necessidade de um balanceamento entre custos e aumento da acurácia.

A grande maioria dos estudos considera o melhor método de combinação aquele que apresenta a menor medida de acurácia, independente da medida selecionada para tal fim. Porém, Reeves & Lawrence (1991) explanam que, em algumas situações, não é suficiente ter habilidade para medir a magnitude da distância entre a previsão e o seu valor real, mas também é preciso verificar para que direção se desloca este distanciamento. Menezes *et al.* (2000), baseados em seu estudo, sugerem outros critérios: variância do erro; assimetria da distribuição dos erros e correlação seriada dos erros.

Uma vez que, em geral, o desempenho da combinação é medido pela acurácia, combinar previsões, para Armstrong (2001a), aumenta a acurácia, na medida em que as componentes da combinação contêm informações úteis e mais independentes. O ideal é que os erros de previsão sejam negativamente correlacionados, de forma que um possa cancelar o outro, mas isto, na prática, é raro. Todavia previsões quase sempre apresentam correlação positiva forte, mas para esse autor, existem duas maneiras de gerar previsões independentes: uma é fazer uso de previsões que empregam diferentes informações para compor as previsões com a mesma técnica e, outra, é utilizar técnicas diferentes, pois analisam os dados de diferentes formas. Além disso, a previsão combinada deve ser usada quando mais de uma técnica razoável está disponível e quando existe incerteza sobre a situação e a seleção da melhor técnica. Batchelor & Dua (1995) mostraram que a combinação é mais efetiva quando os dados e as técnicas são consideravelmente diferentes.

Para Wright *et al.* (1996), a combinação de técnicas estatísticas e de opinião é uma área particularmente promissora para os pesquisadores interessados em melhorias práticas. Deveria ser dada atenção ao estabelecimento de condições para técnicas estatísticas e de opiniões, visando a que a combinação desses dois tipos fosse mais útil.

De acordo com Gunter & Asku (1989), existe o consenso de que uma combinação linear é melhor que as previsões individuais. Não existe, porém, uma concordância referente a qual o melhor método de combinação. Por tal motivo, os autores propõem realizar combinação de outras combinações.


Conforme Menezes *et al.* (2000), muitos métodos estão disponíveis para os previsores, desde a robusta média aritmética até os teoricamente mais complexos, como *state-space*, que atende a modelos não-estacionários em combinações ponderadas, ou como o estudo de Donaldson & Kamstra (1996), que utilizam redes neurais para estimar a combinação. A literatura indica que não há uma aceitação geral de que, em qualquer situação, métodos de combinação sofisticados são melhores que os métodos simples, tal como a média das previsões individuais, pois muitas vezes os métodos simples apresentam desempenho tão bom quanto os mais sofisticados (MILLER *et al.*, 1992 e CHAN *et al.*, 1999). Dentro desse universo de opções, alguns estudos relevantes da literatura foram apresentados com resultados alguns vezes contraditórios. Encontrar a melhor combinação a ser utilizada varia de situação para situação – por exemplo, quando existe alta dependência entre as previsões individuais, ou quando não se dispõe de um número adequado de previsores para obter uma previsão subjetiva. Assim, é necessário manter a flexibilidade. Além disso, para Clemen (1989), como as combinações de previsões têm se mostrado práticas, econômicas e úteis nas mais variadas situações, o desafio não é justificar esta metodologia, mas, sim, encontrar maneiras fáceis e eficientes de implementá-la.

### **3.2. Ajuste Baseado na Opinião**

O ajuste baseado na opinião era considerado, por alguns autores, como uma forma de combinação (MAHMOUD, 1989; SANDERS, 1992), contudo este conceito mudou. Atualmente, o ajuste baseado na opinião é considerado uma forma de integrar previsões

realizadas com o emprego de métodos quantitativos e previsões baseadas em opinião (WEBBY & O'CONNOR, 1996; ARMSTRONG & COLLOPY, 1998 e SANDERS & RITZMAN, 2001). Para Webby & O'Connor (1996), em termos de uso, o ajuste baseado na opinião parece ser a principal alternativa para competir com o método de combinação na tarefa de integrar previsões objetivas e subjetivas. No entanto, nesta tese, estas formas de integração serão utilizadas de modo complementar, para que contribuam com o aumento da acurácia da previsão final.

Como pode ser observado na figura 7, o ajuste baseado na opinião consiste na geração de um modelo baseado em dados históricos, o qual irá fornecer uma previsão objetiva. Após, realiza-se um ajuste, agregando informações contextuais, de onde obtém-se a previsão ajustada. Porém é preciso ter cuidado com a acurácia da previsão inicial, uma vez que a eficácia do ajuste irá depender diretamente desta previsão (WEBBY & O'CONNOR, 1996).



**Figura 7 – Ajuste baseado na opinião**

[fonte: Webby & O'Connor, 1996]

Conforme Armstrong & Collopy (1998), a forma mais comum de integrar previsões de técnicas estatísticas e previsões baseadas na opinião, que usam informações contextuais, é o ajuste baseado na opinião. Para sustentar tal afirmação, os autores tomaram como base a pesquisa realizada por Sanders & Manrodt (1994). Nesta pesquisa, 96 companhias americanas foram abordadas, e 44,7% dos respondentes sustentaram que sempre fazem ajuste baseado na opinião em suas previsões estatísticas; apenas 9,3% expressaram que nunca realizaram ajustes. As principais razões citadas para ajustar a previsão quantitativa foram: (i) incorporar conhecimento do ambiente de previsão, com 38,9%; (ii) incorporar conhecimento do produto, com 29,8% e (iii) incorporar experiências do passado, com 25,9%.

De acordo com Bunn & Salo (1996), uma das razões mais comuns para ajustar previsões parece ser a necessidade de contemplar informações de variáveis explanatórias não-incluídas na estimação do modelo escolhido. Tal situação pode ocorrer de várias formas, caso a variável omitida: (i) não tenha dados suficientes para ser estimada; (ii) apresente alta colinearidade com as variáveis do modelo; (iii) seja puramente subjetiva e (iv) não tenha tido importância no passado.

Para Goodwin (2000b), o ajuste baseado na opinião deveria ser usado apenas quando eventos especiais pudessem afetar a série temporal, uma vez que tais eventos são tratados como ruído nos modelos estatísticos. O julgamento humano tem a habilidade de reconhecer estes eventos, quando eles ocorreram no passado, e de antecipá-los, para previsões futuras. Remus *et al.* (1995) também compartilham tal idéia. Para esses autores, o julgamento humano reconhece mudanças nos padrões dos dados, sendo hábil em integrar informações externas, referentes a mudanças, ao processo de previsão. Para exemplificar, Sanders & Ritzman (2001) citam que o previsor pode ajustar a previsão ao saber, por exemplo, que uma campanha publicitária está em andamento, que a produção será temporariamente reduzida porque uma máquina está em reparo, ou que um laboratório em greve está atrasando o carregamento de produtos.

Armstrong & Collopy (1998) consideram que a acurácia da previsão pode ser melhorada através do ajuste baseado na opinião, desde que o previsor seja hábil para identificar padrões que não são capturados pelas técnicas usadas na obtenção da previsão inicial. Apesar de existirem muitas razões para realizar ajustes baseados na opinião, é preciso cautela na sua utilização.

Segundo alguns autores, o ajuste baseado na opinião pode conduzir a um baixo desempenho das previsões, piorando a acurácia devido ao viés inerente à tomada de decisão humana (WEBBY & O'CONNOR, 1996; SANDERS & RITZMAN, 2001; SANDERS & MANRODT, 2003). Quando o julgamento é utilizado para prever padrões de séries temporais, as pessoas tendem a superestimar a quantia de crescimento ou a diminuir o que realmente está ocorrendo na série. Também tendem a identificar padrões sistemáticos em padrões aleatórios e, possivelmente, como consequência disto, tendem a exagerar nas previsões mais recentes (GOODWIN, 2000b).

As situações descritas anteriormente consistem em alguns tipos de viés que a tomada de decisão humana pode ocasionar. As previsões com viés, por sua vez, podem conduzir a vários problemas, tais como: perda de pedidos; prestação de serviço inadequado e recursos organizacionais mal utilizados. Entre os vários tipos de viés tem-se:

- **Inconsistência:** falta de habilidade para aplicar o mesmo critério de decisão em situações similares. A inconsistência é resultado, muitas vezes, do esquecimento das pessoas; outras vezes, elas são influenciadas pelo seu humor ou, então, podem estar entediadas, desejando fazer algo novo.
- **Ancoramento:** tendência dos previsores serem influenciados por alguma informação inicial (âncora), que interfere no processo de elaboração das suas previsões. Tal informação inicial pode ser baseada em tradição, conhecimento prévio ou dados disponíveis.
- **Conservadorismo:** trata-se da suposição de que a variável em estudo poderá continuar se comportando da mesma forma como se comportou no passado. Originalmente, era um termo que envolvia resistência a mudanças, isto é, há uma resistência inerente a mudanças de opinião, mesmo quando novas evidências sustentam estas mudanças.
- **Otimismo:** um estado da mente que motiva um respondente a prever que eventos favoráveis são mais prováveis de ocorrer do que seria justificado pelos fatos. Também conhecido pela expressão “*wishful thinking*”.
- **Disponibilidade:** confiança em eventos específicos, que são mais facilmente acessáveis, conduzindo à exclusão de outras informações pertinentes.
- **Correlação Ilusória:** crença em padrões que evidenciam a relação entre duas variáveis, quando, na realidade, esta relação não existe.
- **Recência:** efeito em que eventos mais recentes têm maior domínio sobre a previsão que eventos que ocorreram há mais tempo, sendo esses desprezados ou ignorados.

Como a tomada de decisão humana depende do ambiente, para obter uma maior eficácia, regras de decisões devem ser consideradas. Porém, em um ambiente que muda, muita consistência pode ser tão perigoso quanto a inconsistência, pois a não-atualização das regras pode gerar outro tipo de viés, o conservadorismo. Esse é, precisamente, o problema com o viés: na tentativa de evitar que um ocorra, pode-se cultivar a ocorrência de outro (MAKRIDAKIS *et al.*, 1998).

Para evitar a inclusão de algum tipo de viés na previsão, é preciso seguir alguns princípios. O uso de conhecimento acumulado, aliado a algum método de estruturação de ajuste, são princípios vantajosos, que podem aumentar a acurácia das previsões (SANDERS & RITZMAN, 2001 e ARMSTRONG & COLLOPY, 1998).

### 3.2.1. Uso de conhecimento acumulado

Alguns estudos revelam que ajustes baseados na opinião, realizados por pessoas que não possuem domínio do conhecimento envolvido, levam à deterioração da acurácia. Um destes estudos é o de Carbone *et al.* (1983). Nele, os autores desejavam verificar, entre outros três objetivos, se as habilidades de quem realiza ajustes pode melhorar a previsão produzida por métodos de séries temporais. Para tanto, contaram com a colaboração de estudantes e compararam a acurácia de três técnicas: modelos *Box-Jenkins*, modelos *Holt-Winters* e Filtro de *Carbone-Longini*. Os resultados obtidos permitem aos autores concluir que o ajuste baseado na opinião, feito pelos estudantes - que reconhecidamente não tinham conhecimento sobre as séries estudadas -, não melhorou a acurácia.

Outro estudo que mostra o efeito da falta de domínio do conhecimento é o de Sanders (1992). A autora utilizou séries simuladas para controlar o experimento que foi realizado com alunos de graduação, em uma disciplina de previsão. Os resultados mostraram que, para séries com baixa variabilidade, o ajuste trouxe alguns ganhos na acurácia. Para séries com alta variabilidade, o ajuste teve desempenho pior que os modelos estatísticos e, na maioria dos casos, o viés aumentou.

Os estudos acima citados foram realizados com previsores que não possuíam domínio do conhecimento referente ao assunto a ser previsto, indicando que a falta de conhecimento prejudica a acurácia quando se realiza um ajuste.

Para Webby & O'Connor (1996) é esperado, *a priori*, que o ajuste seja benéfico, pois quem o realiza dentro do contexto estudado pode contribuir com informações que o modelo não agrega à previsão. Além disso, nos estudos em que especialistas realizam previsões em seus contextos de vivência diária, possuindo familiaridade com as variáveis

envolvidas, o processo de ajuste é tido como a ‘melhor prática’ (BUNN & WRIGHT, 1991, citando estudos feitos por Huss, 1986 e Wallis *et al.*, 1988).

Nesta linha de pensamento, Sanders & Ritzman (2001) consideram que o ajuste baseado na opinião é apropriado para melhorar a acurácia quando é feito por pessoas que dominam o conhecimento. Domínio do conhecimento, como definido na seção anterior, consiste no conhecimento prático obtido através da experiência, usando informações contextuais. Além disso, se informações contextuais, que são informações específicas disponíveis no ambiente de previsão, não estão contidas no modelo estatístico de previsão, a informação pode ser incorporada através do ajuste.

Muitas pesquisas indicam que o domínio do conhecimento é valioso no ajuste baseado na opinião. Entre elas, cita-se o trabalho de Mathews & Diamantopoulos (1989). Nesse estudo, os autores verificaram a eficácia do ajuste baseado na opinião realizado por administradores, que ajustaram previsões de vendas trimestrais. Para atingir seus objetivos, os autores utilizaram cinco medidas de acurácia (erro, erro absoluto, quadrado do erro, erro percentual ajustado e erro percentual ajustado absoluto), de onde puderam concluir que a acurácia de previsões objetivas obtidas através de modelos de alisamento exponencial foram melhoradas quando revisadas através do ajuste baseado na opinião (os administradores possuíam grande conhecimento sobre o assunto em questão).

Outro estudo que revelou a importância da utilização do conhecimento para ajuste de previsões baseado na opinião é o de Mathews & Diamantopoulos (1990). Nesse estudo, os autores tiveram como objetivo verificar se os administradores de uma empresa inglesa de cuidados com a saúde foram hábeis em selecionar as previsões que apresentam os maiores erros, ou seja, as previsões ruins. Para alcançar o objetivo, foram aplicados testes não-paramétricos, para saber se os erros das previsões escolhidas para serem ajustadas e os erros das previsões não-ajustadas têm a mesma distribuição e mesmo parâmetro de locação. Para proceder tais comparações, foram utilizadas as mesmas cinco medidas de acurácia do estudo anterior, aplicadas sobre as previsões de seis períodos à frente. Os resultados obtidos mostram uma grande proporção de resultados significativos. Desta forma, foi possível concluir que os administradores são hábeis para identificar previsões ruins, sendo candidatos adequados para realizar o ajuste. Novamente, tratava-se de uma amostra que possuía amplo conhecimento sobre o assunto.

Lim & O'Connor (1996) examinaram a habilidade das pessoas em incorporar informação causal ao processo de ajuste de previsões estatísticas baseado na opinião. Para os autores, a informação causal está contida no conhecimento acumulado por aqueles que fazem o ajuste. Um exemplo de fator causal é a informação sobre a temperatura, no caso de vendas de refrigerantes ou sorvetes. O estudo foi realizado com estudantes de mestrado e doutorado, cuja maioria atuava na área de negócios em tempo integral, completando seus estudos em tempo parcial. Visando a atingir o objetivo, foi conduzido um experimento com 3 fatores: (i) presença ou ausência de previsão estatística; (ii) sem, baixo ou alto nível de informação causal e (iii) três blocos para repetições. Foram testadas quatro categorias de técnicas de previsões baseadas na opinião (uma técnica de extrapolação e três de ajuste baseado na opinião): (i) extrapolação baseada na opinião; (ii) ajuste causal; (iii) ajuste baseado na opinião; (iv) ajuste misto. Através da medida de melhoria, obtida pela diferença entre o erro percentual absoluto da previsão inicial e o erro percentual absoluto da previsão ajustada, realizou-se a comparação entre as quatro categorias. Empregando a ANOVA encontrou-se diferenças significativas para os ajustes cujas previsões possuíam base estatística e para os ajustes com suporte de informação causal. Além disso, os autores encontraram que, enquanto ajustes de previsões que utilizam informações causais de baixa confiabilidade não levam a uma melhora significativa, ajustes que utilizam informações causais de alta confiabilidade produzem previsões mais acuradas que o melhor modelo estatístico.

Um exemplo interessante de como o uso de conhecimento é vital no processo de previsão é dado por Makridakis *et al.* (1998). Os autores descrevem a previsão de demanda anual de impressoras a laser, utilizando a série mensal de 1992 a 1998 de determinada empresa, que possui uma leve tendência crescente. Em um primeiro momento, sem informações adicionais, previsões (estatísticas ou de opinião) para os próximos cinco anos provavelmente iriam seguir a tendência de crescimento. Entretanto, no caso da indústria de computadores pessoais, onde o ciclo de vida dos produtos raramente excede sete anos, certamente os previsores da empresa iriam traçar uma curva em declínio, pois neste contexto o domínio do conhecimento é fundamental para realizar uma boa previsão.



### 3.2.2. Métodos de ajuste

O fato das pessoas serem limitadas para considerar processos com grande quantidade de informações é uma das desvantagens da opinião humana. Assim, ao realizar um ajuste baseado na opinião, é importante utilizar alguma estrutura (SANDERS & RITZMAN, 2001). Algumas pesquisas empíricas sobre os métodos de ajuste baseado na opinião foram realizadas utilizando decomposição de séries temporais (EDMUNSON, 1990), métodos gráficos (HARVEY & BOLGER, 1996) ou o método de *Theil* e uma forma de regressão derivada dele (GOODWIN, 1997). Além disso, um método muito conhecido, o processo hierárquico analítico, também foi utilizado como estrutura para realizar ajustes baseados na opinião.

#### 3.2.2.1. Processo hierárquico analítico

Segundo Wolfe (1988), existem duas razões para ajustar previsões baseadas na opinião através do Processo Hierárquico Analítico (com sigla em inglês, AHP): (i) gerar previsões mais acuradas e (ii) identificar as suposições a serem usadas na preparação das previsões.

O processo hierárquico analítico tem por objetivo descrever, a partir das opiniões quantificadas de um grupo de analistas e com base em comparações pareadas de vários fatores, os pesos para cada alternativa analisada, visando a solucionar o problema em estudo, através da escolha da alternativa com maior peso (SAATY, 1991; COSTA *et al.*, 2002 e WOLFE, 1988).

Este método foi criado por Thomas Saaty na década de 70 e, desde então, muitas aplicações foram realizadas na área de tomada de decisão. No entanto, para proceder com ajustes utilizando este método, algumas adaptações foram realizadas por Wolfe (1988) e serão abordadas passo a passo. Para detalhes do funcionamento do Processo Hierárquico Analítico em sua forma original, Saaty (1991) e Costa *et al.*(2002) podem ser consultados.

### Passo 1: Estabelecer fatores

São estabelecidos fatores ou critérios (quantitativos ou qualitativos) que irão compor o primeiro nível da hierarquia na aplicação do método.

### Passo 2: Atribuição do grau de importância

Estes fatores são comparados dois a dois pelos analistas, que lhes atribuem um grau de importância. A escala de importância utilizada é a mesma da forma original do método. Quando compara-se um fator com ele mesmo, atribui-se grau um; se, ao comparar dois fatores, o fator  $i$  é fracamente mais importante que o fator  $j$ , então atribui-se grau 3; se for moderadamente mais importante, atribui-se grau 5; se for muito mais importante, atribui-se grau 7 e, se for absolutamente mais importante, atribui-se grau 9. Os graus de importância 2, 4, 6 e 8 podem ser atribuídos, indicando níveis intermediários. Na figura 8 é apresentado o exemplo dado por Wolfe (1988), comparando quatro fatores na área econômica.

Comparação dos fatores	Fator mais importante	Grau de importância
Economia e Custo	Economia	4
Economia e Tendência Histórica	Economia	6
Economia e Competição	Competição	5
Custo e Tendência Histórica	Custo	4
Custo e Competição		1
Tendência Histórica e Competição	Competição	7

**Figura 8 – Comparação de fatores**

[fonte: Wolfe, 1988]

### Passo 3: Construção da matriz de comparações e obtenção dos pesos relativos

As comparações obtidas no passo anterior permitirão formar uma matriz, sendo que os elementos desta matriz contêm o grau de importância do fator da linha  $i$ , quando comparado ao fator da coluna  $j$ . No caso do fator  $j$  ser preponderante sobre o fator  $i$ , o valor do elemento nesta posição é recíproco ao grau de importância. No exemplo, o fator economia é mais importante que o fator custo, com grau quatro; já o fator custo, em relação à economia, tem grau  $\frac{1}{4}$ . Uma vez formada a matriz, é possível obter os pesos relativos de cada fator. Os pesos relativos são obtidos através do cálculo do autovetor principal da matriz. Caso não seja possível obter o autovetor, Saaty (1991) sugere quatro formas alternativas e acessíveis, que são boas aproximações, para a obtenção dos pesos. A forma apresentada por Wolfe (1988) encontra-se no anexo B. A figura 9 apresenta a matriz

de comparações com os pesos relativos, obtidos através do cálculo do autovetor principal para o exemplo.

Fatores	Matriz de Comparações				Pesos Relativos
	Economia	Custo	Tend.Histórica	Competição	
Economia	1	4	6	1/5	0,25
Custo	1/4	1	4	1	0,19
Tend. Histórica	1/6	1/4	1	1/7	0,04
Competição	5	1	7	1	0,49

**Figura 9 – Matriz de comparações e pesos relativos**

[fonte: Wolfe, 1988]

Passo 4: Verificar a consistência das opiniões

Se uma matriz de comparações de dimensão  $N$  for consistente, então o maior autovalor ( $\lambda_{\text{máx}}$ ) será igual à dimensão  $N$  da mesma. Caso a matriz não seja consistente, Saaty (1991) sugere um índice de consistência (IC), obtido pela equação (3.27):

$$IC = \frac{(\lambda_{\text{máx}} - N)}{(N - 1)} \quad (3.27)$$

A consistência de uma matriz de comparações é medida pela razão de consistência (RC) e é calculada pela razão dada na equação (3.28):

$$RC = IC / RI \quad (3.28)$$

onde: RI = índice aleatório de consistência, cujos valores encontram-se no anexo C.

Segundo Saaty (1991), o valor limite para a razão RC é 0,10. Caso uma matriz de comparações apresente um RC maior que 0,10, significa que mais de 10% das comparações foram realizadas sem nenhum critério e precisam ser revisadas.

Passo 5: Estabelecer os percentuais de ajustes

O segundo e o terceiro níveis da hierarquia são intervalos de porcentagens, sendo que neste passo tem-se a primeira adaptação. Estes intervalos consistem no percentual que o analista julga necessário para ajustar a previsão. A única finalidade do nível 3 é dividir cada intervalo do nível 2, a fim de permitir aos analistas uma maior precisão da previsão. Em geral, o tamanho dos intervalos é pequeno. Wolfe (1988) utilizou, arbitrariamente, 10% para o nível 2 e 5% para o nível 3, como pode ser observado na figura 10.

Nível 1	Nível 2	Nível 3
Economia Custo Tendência Histórica Competência	-25 %  - -15%	-25 %  - -20 %
		-20 %  - -15 %
	-15 %  - -5%	-15 %  - -10 %
		-10 %  - - 5 %
	-5 %  - 5%	- 5 %  - 0 %
		0 %  - 5 %
	5 %  - 15%	5 %  - 10 %
		10 %  - 15 %
	15 %  - 25%	15 %  - 20 %
		20 %  - 25 %

**Figura 10 – Hierarquia para ajuste da previsão**  
[fonte: Wolfe, 1988]

Passo 6: Estabelecer os pesos do nível 2.

Para obter os pesos de cada intervalo do nível 2, executa-se os passos 2, 3 e 4, substituindo os fatores pelos intervalos percentuais de ajuste. Será necessário repetir esse procedimento tantas vezes quantos forem os fatores do estudo.

Passo 7: Estabelecer os pesos do nível 3

Para obter os pesos de cada intervalo do nível 3, executa-se os passos 2, 3 e 4, substituindo os fatores pelos intervalos percentuais de ajuste do nível 3. Será necessário repetir esse procedimento tantas vezes quantos forem os intervalos do nível 2. Na figura 11, é apresentada a matriz de comparações para obtenção dos pesos relativos do intervalo de 15% a 25% do fator economia.

Fator: Economia

Nível 2: 15% a 25%

	15 %  - 20 %	20 %  - 25 %	Pesos Relativos
15 %  - 20 %	1	9	0,9
20 %  - 25 %	1/9	1	0,1

**Figura 11 – Matriz de comparação e pesos relativos do fator economia -Nível 2**  
[fonte: Wolfe, 1988]

Passo 8: Obter os pesos combinados do nível 2 e do nível 3

Para tanto, multiplica-se os pesos do nível 2 pelos pesos do nível 3, para todos os fatores. No exemplo em estudo, tem-se que o pesos do fator economia, no nível 2 do intervalo 15 % a menos de 25% é 0,5. Para o intervalo de 15% a menos de 20%, no nível

3, o peso é 0,9; logo, o peso combinado é 0,45. Na figura 12 encontram-se os pesos combinados para todo o exemplo.

Fator		Economia		Custo		Tend.Histórica		Competência	
Nível 1		0,28		0,19		0,04		0,49	
Nível 2		Nível 3							
-25% a -15%	-25%  - -20%	0,04	0,1	0,03	0,1	0,43	0,88	0,03	0,12
	-20%  - -15%		0,9		0,9		0,12		0,88
-15%  - -5%	-15%  - -10%	0,06	0,1	0,04	0,1	0,29	0,88	0,06	0,12
	-10%  - -5%		0,9		0,9		0,12		0,88
-5%  - 5%	-5%  - 0%	0,13	0,1	0,38	0,1	0,16	0,9	0,13	0,12
	0%  - 5%		0,9		0,9		0,1		0,88
5%  - 15%	5%  - 10%	0,27	0,1	0,4	0,9	0,09	0,88	0,33	0,12
	10%  - 15%		0,9		0,1		0,12		0,88
15%  - 25%	15%  - 20%	0,5	0,9	0,15	0,9	0,03	0,88	0,45	0,65
	20%  - 25%		0,1		0,1		0,12		0,15

Nível 3 \ Fator	Economia	Custo	Tendência Histórica	Competência
-25%  - -20%	0,004	0,003	0,378	0,004
-20%  - -15%	0,036	0,027	0,052	0,026
-15%  - -10%	0,006	0,004	0,255	0,007
-10%  - -5%	0,054	0,036	0,035	0,053
-5%  - 0%	0,013	0,038	0,144	0,016
0%  - 5%	0,117	0,342	0,016	0,114
5%  - 10%	0,027	0,360	0,079	0,040
10%  - 15%	0,243	0,040	0,011	0,290
15%  - 20%	0,450	0,135	0,026	0,383
20%  - 25%	0,050	0,015	0,004	0,067

**Figura 12 – Pesos combinados de cada nível e do nível 3 para cada fator**

[fonte: Wolfe, 1988]

Passo 9: Obter os pesos compostos de cada intervalo do nível 3.

Neste passo, multiplica-se os pesos combinados pelos pesos obtidos para os fatores do nível 1. Por exemplo, o peso combinado do fator Economia no intervalo -25% |- -20% do nível 3 é 0,004 e o peso do fator economia é 0,28 resultando em 0,001. Após, soma-se os pesos dos fatores (no exemplo, 4 fatores), obtendo-se, assim, o peso composto para cada intervalo do nível 3. Os resultados para o exemplo em estudo encontra-se na figura 13.

Nível 3 \ Fator	Economia	Custo	Tendência Histórica	Competência	Pesos Compostos
-25%   -20%	0,001	0,001	0,015	0,002	0,019
-20%   -15%	0,010	0,005	0,002	0,013	0,030
-15%   -10%	0,002	0,001	0,010	0,003	0,016
-10%   -5%	0,015	0,007	0,001	0,026	0,049
-5%   0%	0,004	0,007	0,006	0,008	0,024
0%   5%	0,033	0,065	0,001	0,056	0,154
5%   10%	0,008	0,068	0,003	0,020	0,099
10%   15%	0,068	0,008	0	0,142	0,218
15%   20%	0,126	0,026	0,001	0,188	0,341
20%   25%	0,014	0,003	0	0,033	0,050

**Figura 13 – Pesos compostos de cada nível**

[fonte: Wolfe, 1988]

Passo 10: Obter o fator de ajuste.

Para cada intervalo do nível 3, obtém-se sua média, que deve ser multiplicada pelo peso composto deste intervalo. O fator de ajuste será a soma destes produtos. A figura 14 apresenta o valor do fator de ajuste para o exemplo.

Passo 11: Ajustar a previsão.

Para ajustar a previsão, primeiramente adiciona-se 1 ao fator de ajuste e, após, multiplica-se o fator pelo valor da previsão original.

Intervalos do nível 3	Média do intervalo do nível 3	Peso Composto	Ajuste
-25%   -20%	-0,23	0,019	-0,0044
-20%   -15%	-0,18	0,030	-0,0054
-15%   -10%	-0,13	0,016	-0,0021
-10%   -5%	-0,08	0,049	-0,0039
-5%   0%	-0,025	0,024	-0,0006
0%   5%	0,025	0,154	0,0038
5%   10%	0,08	0,099	0,0079
10%   15%	0,13	0,218	0,0283
15%   20%	0,18	0,341	0,0614
20%   25%	0,23	0,050	0,0115
Total		1,000	0,0965

**Figura 14 – Fator de ajuste**

[fonte: Wolfe, 1988]

A aplicação desse procedimento parece complicada e enfadonha. *Softwares* de processo hierárquico analítico, todavia, já foram desenvolvidos e facilitam os cálculos. Wolfe (1988) cita o *software EXPERT CHOICE*, que gera os pesos para hierarquias específicas.

Wolfe & Flores (1990), aplicaram o processo hierárquico analítico na área de finanças, visando verificar se previsões de modelos *Box-Jenkins* poderiam ser melhoradas ao serem ajustadas utilizando tal estrutura. Ao empregarem quatro medidas de acurácia, os autores concluíram que houve um aumento significativo na acurácia da previsão, especialmente quando as previsões dos modelos *Box-Jenkins* são, inicialmente, imprecisas, devido à volatilidade das séries.

Conforme Flores *et al.* (1992), o processo hierárquico analítico oferece uma abordagem formalizada para ajustar previsões, porém exige muito tempo para obter os pesos e realizar os ajustes. Por isso, os autores analisaram o método centróide, que assim como o AHP, compara alternativas competitivas, porém a um baixo custo, utilizando um ordenamento para estabelecer os pesos. Os autores realizaram um experimento para comparar o AHP e o método centróide, encontrando uma alta correlação ( $r = 0,99$ ) entre as séries ajustadas pelos dois métodos. O experimento indicou, ainda, que os ajustes produzidos pelo AHP são maiores que os obtidos pelo método centróide, entretanto as diferenças encontradas não foram relevantes o suficiente para afetar a acurácia da previsão.

Pelo fato de que é importante utilizar algum tipo de estrutura que permita melhorar o ajuste, o pesquisador pode optar pelo método que usará. Além disso, conforme Armstrong & Collopy (1998), o pesquisador deve guardar os registros sobre o processo de ajuste. A falta de registro indica que os previsores não estão aptos a obter informações sobre o efeito de seus ajustes, e, como resultado, terão dificuldades em aprender como melhorar os ajustes. Por isso, Sandres & Ritzman (2001) sugerem que os previsores guardem os registros de todos os ajustes feitos, em termos de magnitude, do processo que foi utilizado e das razões para tais ajustes. Assim, ao longo do tempo, os ajustes podem ser avaliados, sendo possível verificar que tipo de ajuste traz maior ganho em termos de acurácia e que tipo de ajuste não foi efetivo.

Para Webby & O'Connor (1996), o ajuste baseado na opinião é, talvez, a forma mais fácil de ser utilizada, apresentando o melhor custo/benefício, havendo, porém, a possibilidade de introdução de viés. Concluem ainda que a combinação de previsões é uma abordagem prática e simples que, geralmente, melhora a acurácia. Para utilizar a construção de modelos, é necessário quantificar informações contextuais. Já a

decomposição baseada na opinião provavelmente é mais complexa que a combinação de previsões ou que o ajuste baseado na opinião. Porém, para esses autores, os quatro tipos de integração não são mutuamente exclusivos, podendo interagir entre si. Desta forma, no próximo capítulo será estruturado e avaliado um modelo composto que tem como base a interação entre a combinação de previsões e o ajuste baseado na opinião.



## Capítulo 4 – Modelo Composto de Previsão

A necessidade das empresas manterem-se no mercado competitivo tem levado as mesmas a procurarem soluções em todos os setores, incluindo a área responsável pela previsão da demanda por seus produtos e serviços, visto que uma previsão correta facilita o bom funcionamento da empresa. Uma vez que o desempenho da empresa está relacionado à previsão da demanda, e, conseqüentemente, pela forma como ela será obtida, é vital buscar alternativas que auxiliem na tarefa de minimizar o erro de previsão visando obter, assim, as melhores previsões.

O modelo composto para realizar previsão de demanda, apresentado neste capítulo, foi desenvolvido com o intuito de obter previsões melhores. As formas de integração de previsões têm mostrado potencial para reduzir os erros. Logo, a construção de um modelo que incorpore duas destas formas - a combinação de previsões e o ajuste baseado na opinião - pode conduzir a uma previsão mais acurada, conforme relatos na literatura pesquisada. Sendo assim, o modelo utiliza essas duas formas de integração de previsões, baseando-se em informações referentes a dados históricos, a dados econômicos e à opinião de especialistas.

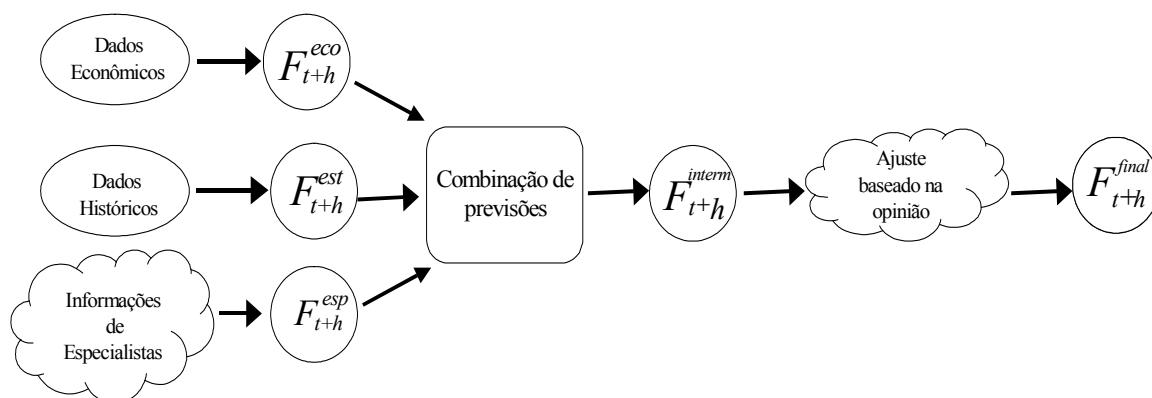
Uma vez que o modelo composto proposto nesta tese foi construído a partir do estudo da literatura, a qual revela as melhores práticas - que são fundamentadas em centenas de estudos reais e simulados - todas as etapas são amplamente referenciadas, deixando clara sua origem, indicando os autores que as estudaram e recomendando as abordagens propostas em cada passo.

Vale mencionar que os passos e etapas que constituem o modelo composto proposto nesta tese estão apresentados na literatura. A contribuição original deste trabalho reside no desenho do modelo, ou seja, na forma como os passos e as etapas são reunidos,

particularmente, na composição das duas formas de integração - a combinação de previsões e o ajuste baseado na opinião. Também constituem contribuição original algumas abordagens utilizadas no tratamento dos passos específicos do modelo.

A validação parcial do método proposto nesta tese, por sua vez, será feita através de um estudo de caso. Este estudo de caso será aplicado no setor de serviços, mais especificamente, em uma empresa de assistência técnica de computadores. O estudo de caso será assunto do Capítulo 5.

O modelo composto proposto nesta tese é formado pela combinação de três previsões individuais. Essas previsões individuais, baseadas em informações de dados históricos, de dados econômicos e na opinião de especialistas, são reunidas de maneira a permitir a obtenção de uma previsão intermediária. A previsão intermediária, por sua vez, é ajustada para formar a previsão final. A estrutura básica do modelo pode ser visualizada na figura 15.



**Figura 15 – Estrutura básica do modelo composto de previsão**

[fonte: adaptado de Webby & O'Connor, 1996]

A estrutura básica do modelo composto de previsão contempla a interação entre as formas de integração, conforme proposto por Webby & O'Connor (1996). Contudo esses autores sugerem apenas a reunião destas duas formas de integração de previsões, sugerindo o uso de uma estrutura muito simples para lidar com as complexidades observadas em casos reais. Tal fato gerou a necessidade de detalhar esta sugestão através de um modelo mais completo, que permita incorporar mais informações ao processo de previsão, bem como às tomadas de decisões inerentes a este processo.

O levantamento do estado da arte destas duas formas de integração de previsões subsidiou a construção da estrutura básica do modelo proposto e o seu detalhamento, gerando o que será chamado de modelo composto completo. Em cada uma das fases da estrutura básica, será necessário descrever a decisão a ser tomada no processo de previsão, bem como os procedimentos a serem realizados após tais decisões. Os passos da estrutura básica do modelo e as decisões e ações do modelo composto completo serão intituladas de etapas, que passam a ser descritas.

#### **4.1. Etapas de estruturação do Modelo Composto de Previsão**

O modelo composto completo, ilustrado na figura 16, está estruturado em seis etapas, listadas e abordadas a seguir. Estas seis etapas consistem em descrever o que deve ser feito para obter previsões de curto prazo, através desta modelagem:

- (i) Verificação da existência de dados e de especialistas
- (ii) Obtenção das previsões individuais
- (iii) Estudo da variância dos erros das previsões
- (iv) Obtenção da previsão combinada
- (v) Verificação da necessidade de fazer ajuste
- (vi) Obtenção da previsão final

##### **4.1.1. Etapa 1 - Verificação da existência de dados e de especialistas**

Esta etapa consiste em verificar a disponibilidade dos dados que permitirão a construção de modelos estatísticos, econométricos e qualitativos. Para a construção do modelo estatístico, será necessário que se disponha de dados históricos em relação à variável em estudo, nesse caso, a demanda. Para o modelo econométrico, será preciso dispor de variáveis socioeconômicas que descrevam o comportamento da demanda. Por fim, para a obtenção do modelo qualitativo, será necessário verificar a disponibilidade de especialistas na área de negócio em que se realiza a previsão de demanda.

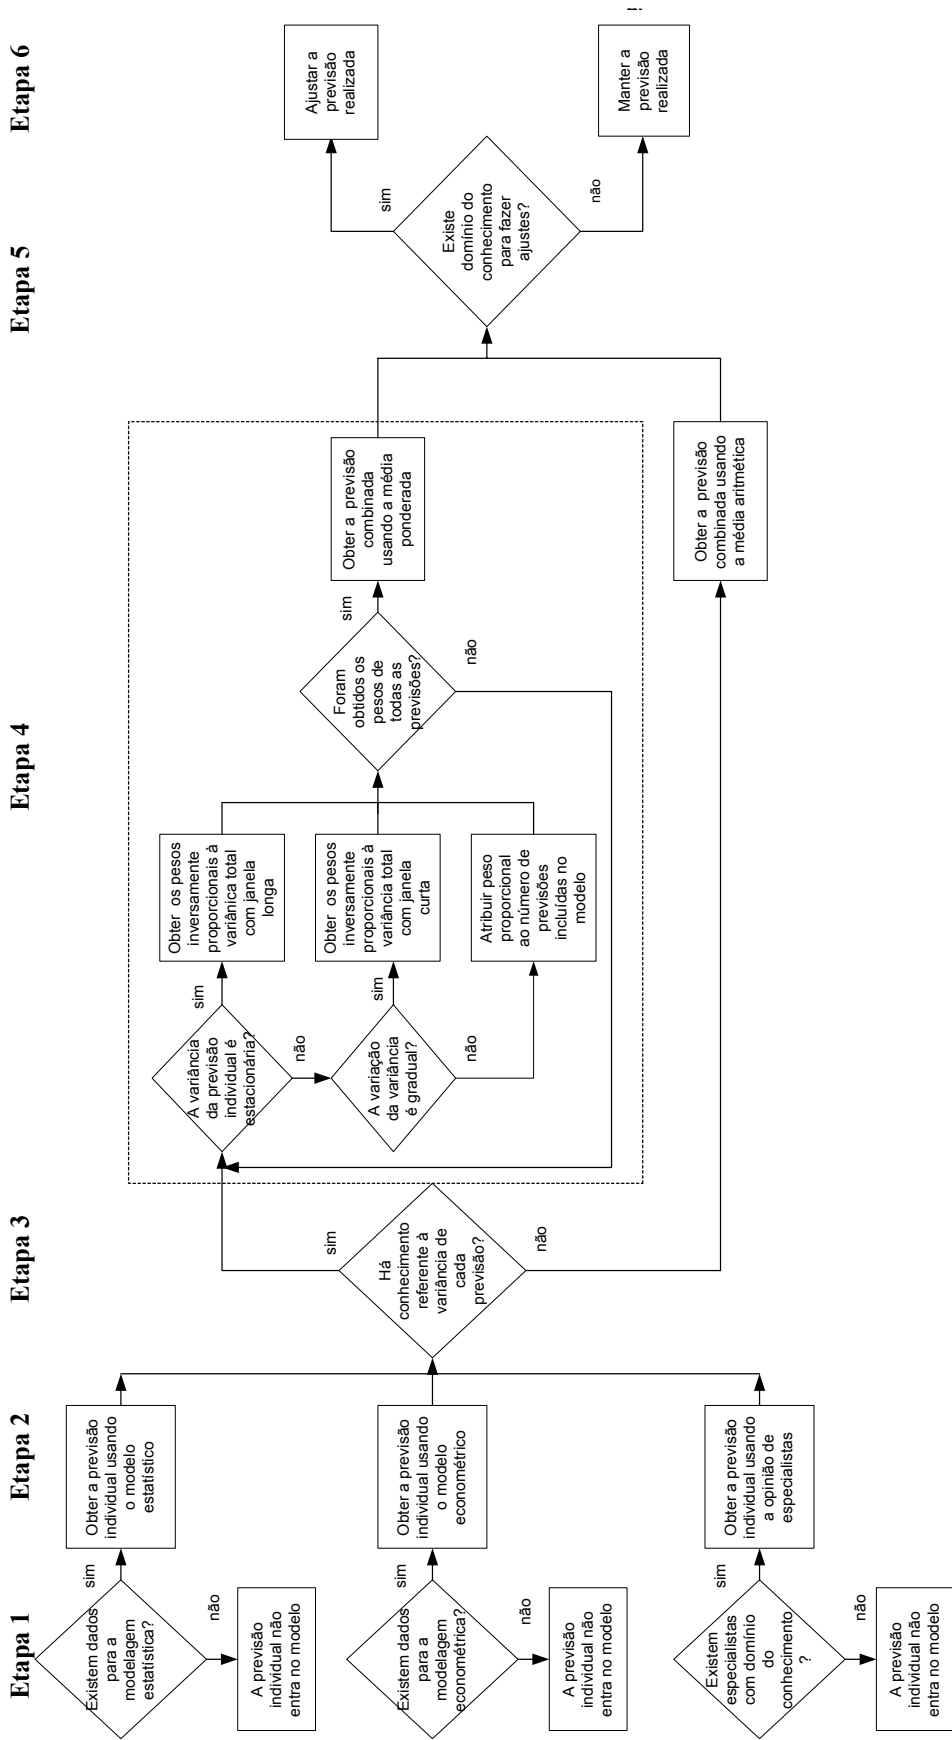


Figura 16 - Modelo composto completo de previsão  
[fonte: elaborada pela autora]

Uma vez que os dados necessários estiverem disponíveis para a modelagem estatística e econométrica, e que tenha sido confirmada a existência de especialistas na área de negócio que possam ser consultados para auxiliar a obtenção da previsão qualitativa, inicia-se a etapa 2. No caso da indisponibilidade de dados para construir o modelo estatístico ou econométrico ou, então, na falta de especialistas e, conseqüentemente, de suas opiniões, a previsão individual em questão não irá compor a previsão combinada. Sendo que são necessárias no mínimo duas previsões para que se possa utilizar o modelo.

#### 4.1.2. Etapa 2 - Obtenção das previsões individuais

Esta etapa contempla a escolha dos melhores modelos de cada caso.

##### 4.1.2.1. Obtenção da previsão individual utilizando o modelo estatístico

A obtenção da previsão usando o modelo estatístico consiste em realizar a modelagem dos dados históricos de demanda ou séries temporais obtidos junto à empresa, utilizando uma metodologia adequada a estes tipos de dados. Por exemplo, o modelo estatístico pode ser obtido através da escolha entre modelos de *Box-Jenkins* ou modelos de alisamento exponencial (MAKRIDAKIS *et al.*, 1998 e ARMSTRONG, 2001b).

##### 4.1.2.2. Obtenção da previsão individual utilizando o modelo econométrico

Para estimar a previsão econométrica é preciso, após conhecer as variáveis econômicas que explicam o comportamento da demanda, escolher uma técnica que auxilie na modelagem deste tipo de dado, fazendo uso de análise de regressão ou de outra técnica de modelos causais (JOHNSON & KING, 1988). Através da técnica escolhida, é obtido um modelo econométrico. Esse modelo pode contemplar variáveis como PIB, taxa do dólar, crescimento populacional, crescimento de um determinado setor econômico, dentre outras.

##### 4.1.2.3. Obtenção da previsão individual utilizando opinião de especialistas

A existência de especialistas com domínio do conhecimento da situação em estudo (verificado na etapa 1) permite coletar os dados qualitativos. A coleta dos dados pode

ocorrer através de formulários, entrevistas com os especialistas ou reuniões de grupo (grupo focado). Com base nessas informações, obtém-se a previsão utilizando a opinião de especialistas.

Após ter sido obtida cada uma das três previsões individuais, passa-se à etapa seguinte, envolvendo decisões que dependem do conhecimento (ou não) da variância do erro de cada previsão.

#### 4.1.3. Etapa 3 – Estudo da variância dos erros das previsões

Nesta etapa, é questionado se há conhecimento prévio referente à variância dos erros de cada previsão individual (estatística, econométrica e baseada na opinião de especialistas). Para tal questionamento, existem duas possibilidades.

Em caso positivo, a combinação das previsões pode ser obtida através dos métodos objetivos de combinação de previsões, utilizando procedimentos que atribuem pesos a cada previsão individual, conforme sugerido por vários autores (BATES & GRANGER, 1969, NEWBOLD & GRANGER, 1974 e GRANGER & RAMANATHAN, 1984). Vale ressaltar que Bates & Granger (1969) indicam que os pesos utilizados são inversamente proporcionais às variâncias das previsões individuais.

Quando não há conhecimento referente às variâncias dos erros de previsão (em geral, existe uma maior dificuldade em obter os erros de previsões subjetivas do que os de modelos estatísticos ou econométricos e, como consequência, sua variância) ou mesmo quando os erros podem alterar-se de um período para o outro, como por exemplo, quando os erros dos especialistas dependem do cenário econômico vigente, a proposta prevê a utilização da média aritmética, defendida por muitos autores (BESSLER & BRANDT, 1981, MAKRIDAKIS & WINKLER, 1983, CLEMEN & WINKLER, 1986, GUPTA & WILTON, 1987, BLATTEBERG & HOGH, 1990 e ASKU & GUNTER, 1992).

Uma vez que tenha sido verificada a possibilidade de obter a variância dos erros de cada previsão individual, procede-se com a investigação sobre a estacionariedade destas. No caso em que não se conhece a variância dos erros de cada previsão individual, procede-se diretamente com o cálculo da previsão combinada.

#### 4.1.4. Etapa 4 - Obtenção da previsão combinada

Como pode ser visto, a proposta incorpora a combinação de previsões, defendida por muitos autores (CLEMEN, 1989, WEBBY & O'CONNOR, 1996 e GOODWIN, 2002). Além disso, a proposta prevê o uso de previsões que possuem maior chance de serem independentes, uma vez que utilizam fontes de dados distintas (o modelo estatístico é baseado em dados históricos; o modelo econométrico utiliza indicadores socioeconômicos e a opinião de especialistas é influenciada por eventos que podem ocorrer no futuro). De acordo com vários autores, a combinação de previsões é particularmente vantajosa quando os erros das previsões são independentes (FIGLEWSKI & URICH, 1983, RIDLEY, 1995 e ARMSTRONG, 2001a).

A combinação das previsões é realizada através de uma média. Caso as variâncias dos erros de previsão sejam conhecidas para todas as previsões individuais, utiliza-se uma média ponderada, com pesos inversamente proporcionais à variância total, conforme proposto por Bates & Granger (1969).

Para obter as previsões através da média ponderada, é verificado se as variâncias de todas as previsões individuais são estacionárias ao longo do tempo. Em caso positivo, os pesos para obter a previsão combinada são calculados com base em informações provenientes de uma longa janela temporal. Caso a variância de pelo menos uma previsão individual apresentar problemas de estacionariedade, é necessário verificar que tipo de não-estacionariedade está ocorrendo. Se for uma variação gradual, a estimativa da variância da previsão será previsível, sendo então o peso obtido utilizando informações de uma janela temporal relativamente curta. Por outro lado, se a falta de estacionariedade caracterizar-se por variações erráticas, então a estimativa da variância das previsões não será previsível. Nesse caso, o peso dessa previsão deverá ser atribuído qualitativamente. Na medida em que três previsões estão sendo feitas, é razoável atribuir o peso de 33,3% para a previsão cuja variância não pode ser prevista.

No caso em que as variâncias dos erros de previsão para todas as previsões individuais não são conhecidas ou não podem ser estimadas, deve ser utilizada a média

aritmética simples (CLEMEN & WINKLER, 1986). A média aritmética simples corresponde ao peso de 33,3% para cada uma das três previsões individuais.

#### 4.1.5. Etapa 5 - Verificação da necessidade de fazer ajuste

Uma vez obtida a previsão combinada, a proposta prevê questionar a possibilidade de realizar um ajuste baseado na opinião. Vários estudos reportados na literatura (MATHEWS & DIAMANTOPOULOS, 1989, LIM & O'CONNOR, 1996 e SANDERS & RITZMAN, 2001) indicam que esse tipo de ajuste pode ser vantajoso, desde que os especialistas que o realizam tenham domínio do conhecimento na área de negócio em questão.

Desta forma, se existe conhecimento, por parte dos especialistas, para efetuar ajuste, procede-se o mesmo. É importante ressaltar, todavia, que nesta proposta já existe a contribuição de especialistas nas previsões individuais. Assim, nesta etapa, faz-se necessário identificar especialistas que possam refinar a previsão já obtida. Em geral, especialistas que conhecem aspectos relativos ao comportamento do mercado, da área de negócio ou dos clientes da empresa são aqueles que podem colaborar durante a realização do ajuste da previsão combinada.

#### 4.1.6. Etapa 6 - Obtenção da previsão final

A última etapa fornece a previsão final. Quando não houver conhecimento dos especialistas de maneira a permitir os ajustes para refinar a previsão combinada, ela poderá, então, ser mantida. Por outro lado, quando os especialistas possuem o domínio do conhecimento, permitindo fazer ajustes, é necessário utilizar algum método estruturado para aprimorar a acurácia da previsão combinada (ARMSTRONG & COLLOPY, 1998 e SANDERS & RITZMAN, 2001).

## 4.2. Proposta de construção do Modelo Composto de Previsão

Na seção anterior, foram descritas as etapas de estruturação do modelo composto completo, em outras palavras, o que deve ser feito para obter uma previsão através da



modelagem proposta. Nesta seção, será proposta a forma como cada uma dessas etapas deve ser executada.

Como o modelo composto completo foi desenvolvido para realizar previsões de curto prazo, é importante realizar toda a modelagem a cada novo período de tempo. Tal necessidade impõe-se em função da dinâmica do processo, pois o comportamento da demanda e do cenário econômico pode alterar as respectivas previsões individuais. Além disso, as mudanças que ocorrem repentinamente na área do negócio podem ser captadas e refletidas na opinião dos especialistas, alterando, assim, a previsão baseada na sua opinião. Essas possíveis alterações que talvez ocorram com as previsões individuais podem, inclusive, determinar a necessidade de mudar o método de combinação a ser utilizado para obter a previsão combinada.

#### 4.2.1. Etapa 1 – Como verificar a existência de dados e de especialistas

Os dados históricos para a construção do modelo estatístico de previsão de demanda, em geral, encontram-se em um banco de dados da empresa. Caso for realizado um estudo mais abrangente, como, por exemplo, demanda agropecuária, se pode buscar informações em publicações ou em fontes de dados de instituições que prestam este tipo de serviço. Os dados para a construção do modelo estatístico referem-se às próprias demandas observadas nos períodos anteriores. Para modelar adequadamente as componentes de tendência e sazonalidade, muitos autores recomendam que seja observado um período de, no mínimo, cinco anos, caso as observações sejam mensais.

Para o modelo econométrico, é preciso fazer um estudo sobre quais variáveis econômicas subsidiarão o modelo econômico. Caso a situação a ser prevista esteja consolidada na literatura da teoria econômica, busca-se por essas informações. Em algumas situações específicas, em que a teoria econômica não está consolidada, é preciso utilizar outras variáveis socioeconômicas, tais como o dólar, o crescimento da população ou, ainda, o PIB. Os especialistas da área do negócio podem auxiliar nesta tarefa, indicando as variáveis socioeconômicas que interferem na previsão de demanda.

Já em relação à previsão qualitativa, obtida com base na opinião de especialistas, é fundamental que se possa contar com a colaboração de pessoas que tenham conhecimento


sobre a situação em estudo. Segundo Morris (1977), especialistas são pessoas que têm conhecimentos especiais sobre o tópico em estudo. A obtenção de dados qualitativos confiáveis requer encontrar tais especialistas. Os especialistas não precisam ser, necessariamente, funcionários da empresa que solicita a previsão, podendo ser estudiosos do tópico específico, como acadêmicos, ou outros especialistas da área de negócio, os quais conhecem o comportamento do mercado consumidor.

#### 4.2.2. Etapa 2 – Como obter as previsões individuais

##### 4.2.2.1. Como obter a previsão individual utilizando o modelo estatístico

O primeiro passo desta fase é coletar uma grande quantidade de dados retratando a demanda no passado. Esta coleta será possível apenas se estes dados estiverem disponíveis, conforme verificado na etapa 1. Após, passa-se à fase de escolher a metodologia que irá auxiliar a modelagem dos dados. Nesta proposta, será utilizada a metodologia de *Box-Jenkins*, por tratar-se de uma metodologia amplamente consolidada na literatura, com tendência a produzir previsões mais acuradas quando comparadas a outras técnicas univariadas de previsão de séries temporais (NEWBOLD & GRANGER, 1974 e MAKRIDAKIS *et al.*, 1998).

Com os dados históricos disponibilizados, e contando com uma ferramenta que auxilie a realizar todos os passos pertinentes à metodologia de *Box-Jenkins*, em geral um pacote estatístico, obtém-se o modelo estatístico. Por fim, utiliza-se o modelo construído e gera-se a previsão estatística (ou histórica). Essa fase pode ser visualizada na figura 17.



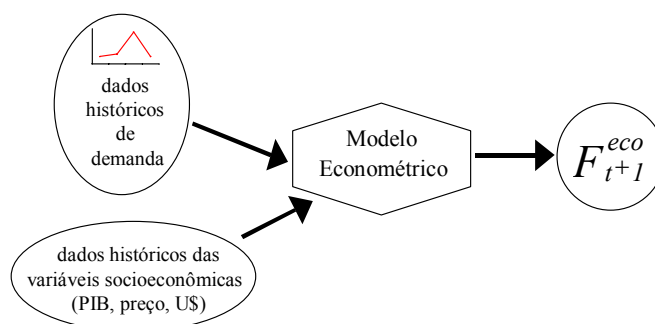
**Figura 17 – Obtenção da previsão estatística**

**[fonte: elaborada pela autora]**

#### 4.2.2.2. Como obter a previsão individual utilizando o modelo econométrico

Uma vez identificadas as variáveis socioeconômicas que explicam o comportamento da demanda, é preciso coletar tais dados para o mesmo período de tempo em que estão disponíveis os dados históricos da demanda no passado. De posse desses dados, será possível estabelecer o modelo econométrico. Nesta proposta será empregada a análise de regressão para construir o modelo econométrico, por se tratar da técnica mais utilizada para modelar relações causais, além de ser uma técnica amplamente conhecida (JOHNSON & KING, 1988).

Ao aplicar a técnica de análise de regressão aos dados coletados, gera-se o modelo econométrico para a situação em estudo, permitindo obter a previsão econométrica. Na figura 18, encontra-se a ilustração desta fase.

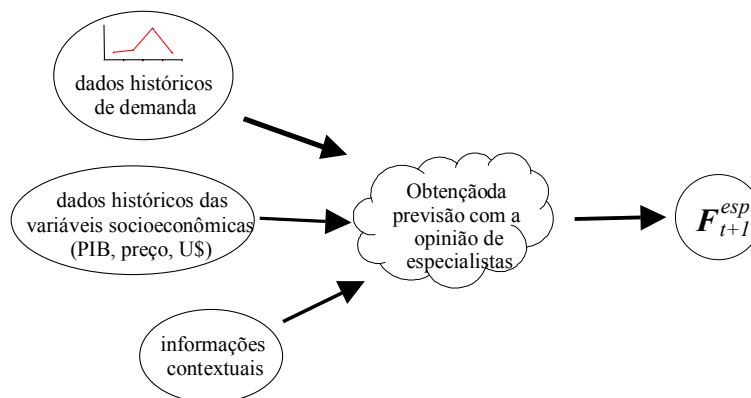


**Figura 18 – Obtenção da previsão econométrica**

[fonte: elaborada pela autora]

#### 4.2.2.3. Como obter a previsão individual utilizando opinião de especialistas

Após ter sido escolhida a forma como os dados serão coletados (por exemplo, através de entrevistas individuais), subsidia-se os especialistas com dados históricos e dados das variáveis socioeconômicas, procedendo-se a coleta das informações qualitativas. Nesta fase, que envolve um procedimento subjetivo, os especialistas devem utilizar informações contextuais para compor a previsão. Na figura 19, encontra-se a ilustração dos passos descritos nesta fase.



**Figura 19 – Obtenção da previsão usando opinião de especialistas**

[fonte: elaborada pela autora]

O modelo para tratar a opinião dos especialistas poderá contemplar a média simples entre vários especialistas consultados ou utilizar técnicas qualitativas mais sofisticadas de previsão, como o *bootstrapping* subjetivo (CLEMEN, 1989, ARMSTRONG, 2001d). Tal escolha depende do problema que está sendo analisado, bem como do acesso aos especialistas que detêm o conhecimento.

#### 4.2.3. Etapa 3 – Como obter as variâncias dos erros das previsões

Nesta etapa, primeiramente verifica-se a possibilidade de estimar os erros associados a cada uma das três previsões individuais incorporadas no modelo composto completo. Para atingir tal objetivo, é necessário ter disponível as previsões da demanda no passado (neste caso, chamadas de predições). De posse dos valores preditos, é possível calcular os erros (de previsão), que, conforme definido anteriormente, são as diferenças entre os valores observados e os valores preditos pelo modelo.

Os modelos matemáticos (estatísticos e econométricos) permitem a obtenção dos erros (de previsão). Porém, para a previsão qualitativa, isto nem sempre se verifica. Caso não exista registro das previsões realizadas em períodos anteriores, é inviável obter os erros. Depois de obtidos os erros de previsão, é preciso buscar informações sobre a variância destes erros, procedendo-se, então, com a obtenção das estimativas das variâncias.

Para os modelos *Box-Jenkins*, a variância dos erros de previsão pode ser estimada através do erro quadrático médio com  $(n-k)$  graus de liberdade, onde  $n$  é o número de erros

obtidos a partir do modelo e  $k$  é o número de parâmetros a serem estimados, acrescidos da quantidade de integrações realizadas para a obtenção do modelo. Para os modelos econométricos obtidos fazendo uso da análise de regressão, o melhor estimador para a variância dos erros é o erro quadrático médio da regressão, o qual pode ser obtido da tabela ANOVA, tanto para o caso simples como para o caso multivariado. Quando se trata de previsão qualitativa, sugere-se usar a variância dos erros da ANOVA de um fator, ao comparar as previsões de  $k$  períodos, utilizando como número de repetições a quantidade de especialistas que estão fazendo as previsões. Na tabela 2 tem-se  $n$  especialistas que realizaram  $k$  previsões no passado. Desta forma, a variância do erro pode ser estimada pelo erro quadrático médio com  $(N-k)$  graus de liberdade, onde  $N=n \times k$ .

**Tabela 2 – Tabela ANOVA de um fator para comparar opinião de especialistas**

	Período 1	Período 2	...	Período $k$
Especialista 1	$f_{11}$	$f_{12}$	...	$f_{1k}$
Especialista 2	$f_{21}$	$f_{22}$	...	$f_{2k}$
...	...	...	...	...
Especialista $n$	$f_{n1}$	$f_{n2}$	...	$f_{nk}$

Caso não tenha sido possível obter a variância dos erros para as previsões individuais, segue-se para a etapa quatro, a fim de obter a previsão combinada através da média aritmética. Caso contrário, executa-se os passos da etapa quatro, para obter a previsão combinada através da média ponderada.

#### 4.2.4. Etapa 4 – Como obter a previsão combinada

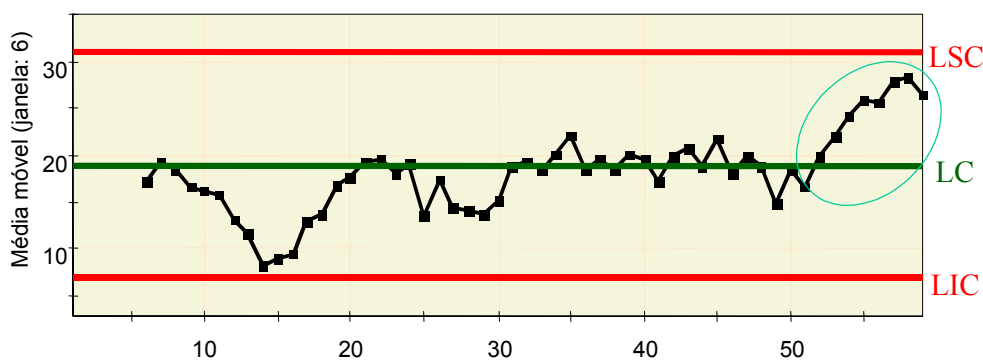
No caso em que as variâncias são conhecidas para todas as previsões individuais, a previsão combinada é obtida através da média ponderada das previsões individuais, conforme proposto por Bates & Granger (1969). Porém, para obtê-la, é necessário investigar, para cada previsão (estatística, econométrica e baseada na opinião), qual a melhor forma de obter os pesos. Primeiramente, verifica-se a estacionariedade da variância e, caso seja preciso, analisa-se o seu comportamento. Conforme o comportamento apresentando pelas variâncias, estas são estimadas, e, uma vez estimadas, os pesos das

previsões individuais serão obtidos. Por fim, depois de estabelecidos os pesos, calcula-se a previsão combinada.

O passo inicial consiste em verificar a estacionariedade das variâncias das previsões individuais. Para tanto, sugere-se utilizar um gráfico de controle. Para verificar a estabilidade das variâncias, pode ser utilizado um gráfico de médias móveis, sendo que a variável a ser controlada é o erro absoluto de previsão. Ao analisar o comportamento das médias móveis no gráfico, será possível verificar se a série apresenta estacionariedade ou algum tipo de não-estacionariedade.

Analisa-se, primeiramente, se as médias móveis estão sob controle. O fato das médias estarem sob controle e de apresentarem um padrão aleatório, irá indicar que a série é estacionária. Neste caso, os pesos podem ser estimados por uma janela temporal longa (maior que 12 meses). Por outro lado, se a variância da previsão individual em análise apresentar problemas de estacionariedade, verifica-se o tipo de não-estacionariedade apresentada: gradual ou errática. Esta verificação pode ser realizada através da busca por padrões de comportamento no gráfico de controle. Um crescimento ao longo do tempo, como o destacado na figura 20, indica que a variância não é estacionária. Contudo será possível prever o seu comportamento, uma vez que as mudanças são graduais.

Se existe algum comportamento indicativo de que a variância não é estacionária, e apresenta uma variação gradual ao longo do tempo, a variância deverá ser estimada com dados recentes, utilizando uma pequena janela móvel. Isto significa que será utilizada uma quantidade menor de erros de previsões recentes, comparado à situação anterior.



**Figura 20 – Gráfico de controle com comportamento não-estacionário: padrão de crescimento temporário [fonte: elaborada pela autora]**

Se, porém, o gráfico de controle apresentar pontos além dos limites, isso implica um comportamento errático, indicando a não-estacionariedade da variância e a impossibilidade de prever seu comportamento. Nesta situação, o peso da respectiva previsão deve ser atribuído qualitativamente.

Após avaliar a estacionariedade da variância da previsão individual, o segundo passo consiste em obter os pesos. Apesar da literatura apresentar várias alternativas de combinações objetivas de previsões e, conseqüentemente, de obtenção dos pesos, optou-se pelo método proposto por Bates & Granger (1969), primeiramente, pelo fato deste método apresentar a facilidade de interpretação dos pesos. Como os pesos somam 1, cada peso representa a importância relativa da previsão à qual está associado. Além disso, este método propõe, conforme a equação (4.1), o uso das variâncias dos erros das previsões individuais para o cálculo dos pesos, não sendo necessário utilizar técnicas estatísticas mais elaboradas para obtê-los, como, por exemplo, a análise de regressão, proposta nos métodos abordados por Granger & Ramanathan (1984).

$$w_i = \frac{1/\sigma_i^2}{1/\sigma_{est}^2 + 1/\sigma_{eco}^2 + 1/\sigma_{esp}^2} \quad (4.1)$$

onde:  $\sigma_i^2$  é a variância para  $i = \{est, eco, esp\}$ ;

$\sigma_{est}^2$  é a variância para a previsão estatística;

$\sigma_{eco}^2$  é a variância para previsão econométrica e

$\sigma_{esp}^2$  é a variância para a previsão baseada na opinião de especialistas.

Como referenciado anteriormente, se a variância  $\sigma_i^2$  apresentar um comportamento estacionário, poderá ser estimada através de uma janela temporal mais longa, contemplando 12 ou mais períodos. Se a variância não for estacionária, mas apresentar mudanças graduais, poderá ser estimada através de uma janela temporal mais curta, de 6 períodos, por exemplo. Existem muitos estimadores para a variância, dentre eles, o erro quadrático médio (MSE). O MSE consiste na soma dos quadrados dos erros para  $k$  períodos, dividido pela quantidade de períodos. A forma de estimar a variância será

detalhada no estudo de caso apresentado no capítulo 5. No caso da variação apresentar um comportamento errático, e de seu valor ser desconhecido, pode-se atribuir peso  $1/p$ , sendo que  $p$  é o número de previsões que estão incluídas no processo de obtenção da previsão combinada. É importante salientar que, no caso de alguma previsão ter seu peso atribuído, os pesos de todas as previsões precisarão ser proporcionalizados, a fim de que os pesos somem 1.

De posse dos valores dos pesos de cada previsão individual, procede-se com o cálculo da previsão combinada, conforme a equação (4.2).

$$F_c = w_{est}F_{est} + w_{eco}F_{eco} + w_{esp}F_{esp} \quad (4.2)$$

onde:  $F_{est}$  é a previsão estatística e  $w_{est}$  é o peso atribuído a previsão estatística;  $F_{eco}$  é a previsão econométrica e  $w_{eco}$  é o peso atribuído a previsão econométrica;  $F_{esp}$  é a previsão baseada na opinião de especialistas e  $w_{esp}$  é o peso atribuído a previsão baseada na opinião de especialistas, sendo que  $\sum w = 1$ .

No caso em que todas as variâncias das previsões individuais são consideradas não-conhecidas, a previsão combinada é obtida através da média aritmética simples, conforme a equação (4.3) (FIGLEWSKI & URICH, 1983 e KANG,1986). Essa equação é um caso particular da equação (4.2).

$$F_c = \frac{F_{est} + F_{eco} + F_{esp}}{3} \quad (4.3)$$

#### 4.2.5. Etapa 5 – Como verificar se existe conhecimento entre os especialistas para fazer ajustes

De posse da previsão combinada, o próximo passo consiste em verificar se existe conhecimento entre os especialistas para fazer ajustes. Esta etapa é subjetiva, sendo que tal verificação se dará através da análise da existência de especialistas, preferencialmente dentro da empresa, que possuam conhecimento específico para refinar a previsão e, assim, torná-la mais acurada.



#### 4.2.6. Etapa 6 – Como obter a previsão final

Esta é a última etapa, onde a previsão final é estabelecida. Se os especialistas que poderiam ser designados para a tarefa de ajuste não têm domínio do conhecimento, então a previsão combinada é mantida, sem ajuste. Por outro lado, se os especialistas possuem o domínio do conhecimento que permita fazer ajuste, o mesmo deve ser realizado.

Primeiramente é necessário estabelecer a estrutura que será utilizada para realizar o ajuste, para após, efetivamente, fazer o ajuste. A utilização de uma estrutura de ajuste visa a minimizar a introdução de viés, inerente à tomada de decisão humana (WEBBY & O'CONNOR, 1996; SANDERS & RITZMAN, 2001).

Vários autores abordaram este tópico buscando apresentar métodos que melhorem a acurácia das previsões (WOLFE, 1988, EDMUNSON, 1990, WOLFE & FLORES, 1990, FLORES *et al.*, 1992, HARVEY & BOLGER, 1996, GOODWIN, 1997). Contudo a melhor forma de realizar o ajuste é um assunto pouco aprofundado. Sendo assim, dentro do modelo proposto será apresentada uma estrutura para ajustar previsões com base na opinião de especialistas. A estrutura proposta para a realização do ajuste é fundamentada na estrutura de ajuste utilizando o AHP (Wolfe, 1988), que foi abordada no Capítulo 3. A estrutura descrita a seguir passo a passo trata-se de uma simplificação lógica da estrutura baseada no AHP.

Passo 1: Estabelecer o percentual máximo e mínimo de ajuste

A estrutura a ser apresentada inicia solicitando aos especialistas que estabeleçam um **percentual máximo** e um **percentual mínimo** através dos quais a previsão pode ser ajustada, considerando o contexto global da empresa ao longo de sua história. Se a previsão de demanda combinada for ajustada em um percentual que, por exemplo, exceda a capacidade produtiva da empresa, ou seja, irreal, considerando a dinâmica do mercado em que a empresa atua, então o ajuste não irá retratar a realidade e, por consequência, não estará sendo efetivo. Por isso, a delimitação deste intervalo é necessária, para que não se criem situações onde o ajuste foge da realidade. O ajuste será realizado com base no **percentual médio** obtido entre todos os especialistas.

## Passo 2: Montar a listagem dos fatores

Solicita-se aos especialistas que descrevam fatores que podem influenciar o comportamento da demanda. Após, com a listagem obtida junto a cada especialista, se estabelece uma lista única de fatores considerados influentes. Essa lista é formada a partir das prioridades atribuídas pelos próprios especialistas. Em geral, os fatores estabelecidos pelos especialistas são descritos de forma distinta (diferenças semânticas), e precisam ser trabalhados para a elaboração de uma lista única, sem redundâncias.

Vale observar que a lista deve incluir apenas fatores que não tenham sido contemplados nas previsões anteriores (estatística, econométrica, baseada em especialistas). Em geral, tratam-se de fatos novos, que irão influenciar a demanda futura, e de fatos desconhecidos (inclusive pelos especialistas que fizeram a previsão individual), porém que ainda não causaram efeito (sobre a demanda passada). A diferença entre o trabalho realizado pelos primeiros especialistas, que fazem a previsão individual, e esses últimos, que ajustam a previsão combinada, ficará mais clara na apresentação do estudo de caso (Capítulo 5).


## Passo 3: Mensurar o impacto de cada um dos fatores identificados

Os especialistas atribuem pesos para os fatores, visando identificar a sua possível influência sobre a demanda (pequena, média, grande). A escala de importância sugerida é similar àquela utilizada por Saaty (1991) na aplicação do método AHP. Se o fator  $i$  é muito fracamente importante, então se atribui grau 1; se for fracamente importante, então atribui-se grau 3; se for moderadamente importante, atribui-se grau 5; se for muito importante, atribui-se grau 7 e, se for absolutamente importante, atribui-se grau 9. Os graus de importância 2, 4, 6 e 8 podem ser atribuídos, indicando níveis intermediários. Atribuídos os pesos, os mesmos devem ser normalizados, de forma que a sua soma resulte igual a 1.

## Passo 4: Mensurar a opinião dos especialistas

Este passo consiste em cada especialista informar sua opinião com relação a cada fator, considerando a situação em que ele se apresenta e como pode influenciar a demanda para o próximo período. Utilizando uma escala que varia entre -1 e +1, o especialista atribui um valor desta escala para cada fator. Se, por exemplo, na opinião do especialista, a situação do fator em um respectivo mês favorece o aumento da demanda, ele indicará um valor positivo; se sua situação for muito favorável (aumento da demanda), este valor estará

próximo de 1. Em uma estrutura similar apresentada por Makridakis *et al.* (1998), os fatores exemplificados foram: economia, indústria em geral, competitividade, tecnologia e outros. Na figura 21 encontra-se um exemplo hipotético para as opiniões de um especialista, utilizando os fatores citados.



**Figura 21 – Exemplo hipotético para as opiniões de um especialista**  
[fonte: adaptado de Makridakis *et al.*, 1998]

Passo 5: Calcular as médias ponderadas

Uma vez que cada especialista emitiu sua opinião referente ao peso de cada fator e a sua situação atual, procede-se a obtenção da média ponderada de cada especialista. A média ponderada é obtida ao somar o produto dos pesos normalizados com a opinião, para todos os fatores. Esta média ponderada irá resultar em um valor no intervalo [-1; +1].

Passo 6: Calcular o ajuste percentual

As médias ponderadas devem ser então multiplicadas pelo percentual mínimo médio ou então pelo percentual máximo médio, indicados no primeiro passo deste procedimento. O resultado deve ser convertido em percentual. O valor convertido representa o **ajuste percentual** que o especialista considera que deve ser aplicado à previsão combinada, o qual pode ser positivo ou negativo. Após o percentual de ajuste ter sido estabelecido para cada especialista, calcula-se a média aritmética dos percentuais de ajuste de todos os especialistas, obtendo-se o **percentual de ajuste médio**.

Passo 7: Calcular a previsão final

Para proceder 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. Detalhes matemáticos desse procedimento serão esclarecidos no estudo de caso.

## Capítulo 5 Aplicação do Modelo Composto: um Estudo na Área de Assistência Técnica de Computadores Pessoais

Este capítulo apresenta um estudo em que o modelo composto completo é aplicado aos dados de demanda de uma empresa prestadora de serviços na área de assistência técnica de computadores pessoais, mais especificamente, na manutenção de equipamentos de informática. O estudo de caso foi realizado nesta empresa, pois esta possuía a necessidade de melhorar suas previsões, visto que sua demanda apresenta alta variabilidade.

Na área de assistência técnica de computadores, prever a demanda dos serviços está intimamente ligado às tarefas de disponibilizar recursos, tanto humanos como de equipamentos, para viabilizar o atendimento eficaz aos clientes. Tal fato indica que o planejamento da empresa precisa ser realizado em períodos curtos. Assim, a previsão de demanda será realizada em períodos mensais, o que fica facilitado devido à maneira como os dados da empresa são organizados.

A empresa, de pequeno porte, atua atendendo a três tipos diferenciados de clientes: clientes que assinam **contratos** de manutenção, em geral pessoas jurídicas; clientes que trazem o equipamento para manutenção durante o período de **garantia** do mesmo e clientes **avulsos**, em geral pessoas físicas. A empresa realiza serviços de manutenção de *hardware* e *software* e, raramente, vende peças sem a prestação de algum serviço de manutenção. Cada tipo de cliente - contratos, garantia ou avulsos - possui peculiaridades. Por esse motivo, foi necessário modelar e prever a demanda direcionada a cada tipo de cliente. Sendo assim, a previsão de demanda total da empresa deve ser uma soma da

previsão da demanda individual dos três tipos de clientes. Porém, nesta tese, o modelo proposto será utilizado somente para prever a demanda dos clientes do tipo avulsos. Os clientes avulsos representam o maior desafio no esforço de previsão, pois o seu comportamento apresenta maior variabilidade, sendo influenciado de forma mais intensa pela conjuntura econômica e pelo cenário competitivo.

Seguindo os passos do modelo proposto, primeiramente são apresentadas as etapas 1 e 2, contemplando a obtenção da previsão da demanda através da metodologia *Box-Jenkins*; após, através de modelos econométricos e, finalmente, através da opinião de especialistas. Em seguida, é verificada a possibilidade de obter a variância dos erros, a fim de selecionar o método de combinação de previsões a ser utilizado. Uma vez obtida a previsão de demanda combinada, verifica-se a necessidade de realização de ajuste, conduzindo à previsão final. Neste estudo será obtida a previsão para “um passo à frente”, isto é, apenas para o período 61.

## **5.1. Etapa 1 - Verificação da Existência de Dados e de Especialistas**

### **5.1.1. Obtenção dos dados para a metodologia *Box-Jenkins***

Para a construir o modelo estatístico de previsão de demanda, geralmente utiliza-se os dados armazenados em algum banco de dados da empresa. É o que ocorre neste estudo de caso, cujos dados disponibilizados encontram-se no sistema que controla o número de atendimentos realizados a clientes pela empresa. Com o objetivo de obter previsões de demanda utilizando a metodologia de *Box-Jenkins*, foram reunidos dados históricos do número de atendimentos (demanda) de clientes do tipo avulsos em um período de 5 anos. Cabe esclarecer que, nesta situação, o número de atendimentos corresponde à demanda da empresa, pois durante o período de cinco anos, houve disponibilidade para o atendimento a todos os clientes. No apêndice A, encontram-se os dados, referentes à demanda da empresa, analisados neste estudo.

### 5.1.2. Obtenção dos dados para a modelagem econométrica

Para o modelo econométrico, será preciso dispor, além dos dados de demanda mencionados anteriormente, de dados socioeconômicos que descrevam o comportamento do número de atendimentos (demanda). Através de autores como Troster & Mochón (1999), Gujarati (2000), Hill *et al.* (2000), fica claro que a demanda, sob o enfoque da microeconomia, é função do preço do bem ou do serviço, do preço de outros bens ou serviços concorrentes ou complementares e da renda do consumidor.

Como nem todas as variáveis consideradas pela teoria econômica para prever a demanda estavam disponíveis para o estudo em questão, optou-se por prever o número de atendimentos dos clientes tipo avulsos através de indicadores econômicos. Os indicadores econômicos a serem apontados pelos especialistas substituirão as variáveis designadas pela teoria econômica.

Uma vez que a modelagem para previsão de demanda sob o enfoque econômico se dará através dos indicadores econômicos apontados pelos especialistas, à luz da teoria econômica (microeconomia), será considerado, na modelagem, o preço praticado pela empresa; o dólar (americano), para representar o preço de bens de concorrentes ou complementares e, por fim, o PIB, para representar o comportamento da renda do consumidor.

Os preços praticados pela empresa no período do estudo passaram por um reajuste, e este fato exigiu o ajuste de preços para corrigir eventuais inflações ou deflações que tenham ocorrido no período. O ajuste foi realizado utilizando o Índice de Preços ao Consumidor do Instituto de Estudos e Pesquisas Econômicas da UFRGS (IPC-IEPE). O IPC-IEPE é o índice de custo de vida da cidade de Porto Alegre e consiste na variação de preços de 54 itens para famílias com rendimentos entre 1 e 21 salários mínimos.

Já o dólar foi utilizado para modelar o comportamento do preço do concorrente ou de bens relacionados. Como os preços praticados pelos concorrentes não estavam disponíveis, optou-se por modelar o comportamento dos bens relacionados. No caso da demanda de serviços de assistência técnica de computadores, a relação entre o preço dos bens relacionados e a demanda é inversa, de acordo com a informação prestada pelos

especialistas. Sempre que ocorre a valorização do dólar, a demanda diminui, pois muitas peças de reposição acompanham sua cotação.

A renda do consumidor afeta diretamente a demanda. Se a renda aumenta, a demanda por determinado bem também aumenta. Na área de assistência técnica, o PIB pode modelar este comportamento, pois, conforme os especialistas da empresa, quando a economia aquece, os usuários adquirem, utilizam e consertam seus equipamentos de forma mais intensa, gerando, assim, uma demanda maior.

Apesar de não ser indicado na teoria econômica, os especialistas da empresa apontaram a quantidade de equipamentos vendidos no mercado como fator que exerce influência sobre a demanda. Como tais quantidades não foram disponibilizadas pelos fabricantes, buscou-se por um índice substituto, o Índice de Vendas de Equipamentos de Informática da Associação Brasileira Nacional de Eletro-Eletrônicos (ABNEE), também indicado pelos especialistas. Porém este índice também não estava disponível, e para contemplar o indicativo de volume de vendas, foi utilizado o Índice da Produção Física Industrial do IBGE, já que o volume de vendas de fabricantes específicos não foi encontrado.

Sendo assim, o modelo para a previsão da demanda por serviços de assistência técnica de computadores será função do preço praticado pela empresa, deflacionado pelo IPC-IEPE; do dólar (valor mensal ou variação mês a mês); do PIB (valor mensal estimado ou variação acumulada mês a mês) e do Índice da Produção Física Industrial do IBGE.

É importante ressaltar que, na visão dos especialistas, não existe defasagem entre os dados do mês em que são observados esses indicadores e o momento da prestação do serviço por parte da empresa. Assim, por exemplo, se o dólar aumenta em um determinado mês, o reflexo deste aumento na demanda da empresa deve ocorrer no mês em questão.

### 5.1.3. Disponibilidade de especialistas com domínio do conhecimento

Nesta fase, são selecionados os especialistas que possuem domínio do conhecimento os quais, depois de subsidiados por dados históricos, geram a previsão de

demanda. Tais especialistas estão em contato com o cliente e indicam se o mercado está aquecido ou não, fazendo sua previsão em função do presente e do passado recente.

Apesar da literatura recomendar de cinco a vinte especialistas, neste estudo de caso apenas três especialistas foram consultados. Tal situação se deve ao fato de que o mercado analisado é altamente competitivo e especialistas externos à empresa, mostraram-se desfavoráveis a fornecer informações que podem ser vitais no seu entender. Já na empresa os demais especialistas que poderiam colaborar, foram preservados a fim de contribuírem no ajuste da previsão final.

O primeiro especialista consultado é um representante da empresa, que a conhece muito bem, pois é responsável pela previsão de demanda. O segundo especialista consultado é o responsável pelo setor de manutenção, que conhece o comportamento dos clientes e as suas demandas. O terceiro especialista conhece procedimentos de previsão e é da área do negócio de computadores pessoais.


## **5.2. Etapa 2 - Obtenção das Previsões Individuais**

### **5.2.1. Obtenção da previsão de demanda através da metodologia *Box-Jenkins***

#### **5.2.1.1. Etapa de identificação**

A análise da figura 22 auxilia a identificar os possíveis modelos a serem utilizados. Essa figura revela a presença de tendência crescente, o que indica que a série é não-estacionária. Além disso, a série apresenta um nível que deve ser considerado no modelo a ser proposto.





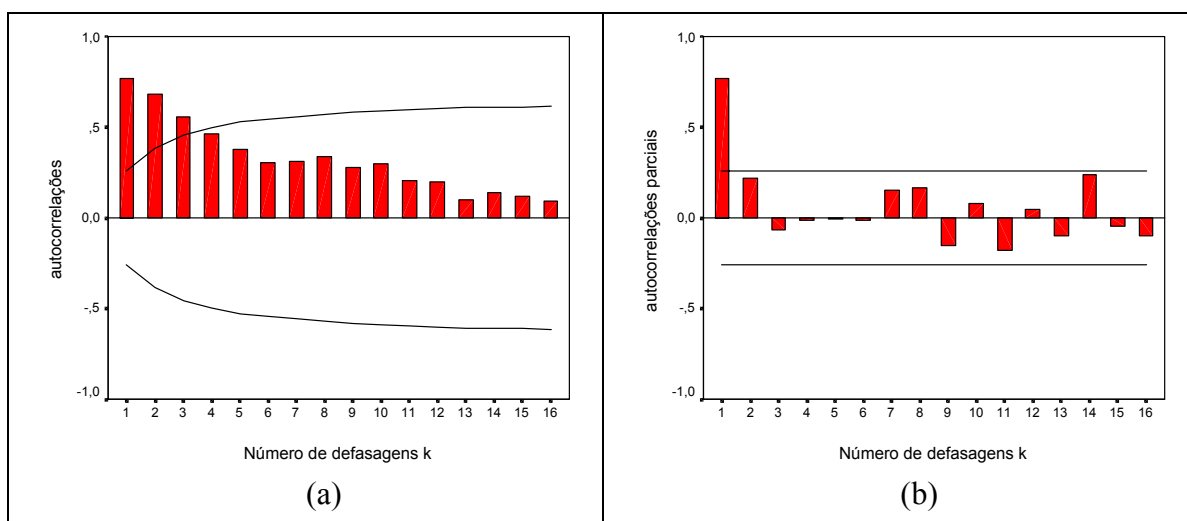
**Figura 22 – Número de atendimentos para clientes do tipo avulsos e sua tendência**  
[fonte: dados fornecidos pela gerência da empresa em estudo]

A seguir, realiza-se a análise das funções de auto-correlações (ACF) e de auto-correlações parciais (PACF), que auxiliam a verificação da estacionariedade e, também, com base nos seus comportamentos, auxiliam a proposição de um modelo.

A figura 23(a), contendo a ACF do número de atendimentos de clientes do tipo avulsos, revela que as auto-correlações apresentam um decaimento exponencial, típico de um processo auto-regressivo; contudo, o leve aumento na auto-correlação da defasagem 8 pode ser uma indicação de que a série apresente sazonalidade.

A figura 23(b) contém a PACF que apresenta apenas a auto-correlação parcial 1 significativa. Assim, existe a indicação de que a ordem do modelo auto-regressivo é 1, reforçando a indicação de um modelo auto-regressivo de primeira ordem, AR(1).

Para reforçar a análise da condição de estacionariedade da série, foi realizado o teste *Dickey-Fuller*, utilizando o pacote econométrico *Eviews* (versão 3.0). A hipótese de não-estacionariedade não foi rejeitada, ao nível de 5% de significância. Isto quer dizer que, em virtude da evidência de não-estacionariedade da série, é necessário utilizar a diferença. Utilizando a primeira diferença e reaplicando o teste *Dickey-Fuller*, verifica-se que a série é estacionária ao nível de 5% de significância. Assim, tem-se a indicação de que a ordem de integração deva ser 1, isto é, de que  $d = 1$ . Com base nessas informações, o modelo indicado é um ARIMA(1,1,0), incluindo o termo constante.



**Figura 23 – (a) Função de auto-correlação e (b) Função de auto-correlação parcial para o número de atendimentos a clientes do tipo avulsos**  
[fonte: elaborada pela autora, utilizando o *software* SPSS 8.0]

### 5.2.1.2. Etapa de estimação

Para estimar os parâmetros do modelo, foi utilizado o pacote estatístico SPSS (versão 8.0). Além dos parâmetros do modelo, foi estimada a variância dos resíduos  $\sigma_{\varepsilon}^2$ . O modelo ARIMA(1,1,0), indicado para prever o número de atendimentos dos clientes avulsos foi o mais adequado, como será visto na próxima seção. A estimativa do coeficiente auto-regressivo obtida para este modelo foi de  $\phi_1 = -0,3301$ , e a média do processo foi de  $\mu = 6,0082$ .

Rescrevendo o modelo dado pela equação (2.25), com  $p = 1$  e  $d = 1$ , e substituindo o valor do coeficiente  $\phi_1 = -0,3301$  de  $\mu = 6,0082$ , tem-se:

$$(1 - \phi_1 L)(Z_t - Z_{t-1}) = \mu + \varepsilon_t$$

$$Z_t - Z_{t-1} - \phi_1 Z_{t-1} + \phi_1 Z_{t-2} = \mu + \varepsilon_t$$

$$Z_t - Z_{t-1} + 0,3301 Z_{t-1} - 0,3301 Z_{t-2} = 6,0082 + \varepsilon_t$$

$$Z_t = 0,6699 Z_{t-1} + 0,3301 Z_{t-2} + 6,0082 + \varepsilon_t \quad (5.1)$$

### 5.2.1.3. Etapa de verificação

O modelo proposto pela análise da ACF, da PACF e da estacionariedade foi um modelo ARIMA(1,1,0). Na figura 24 pode ser verificado que os resíduos se comportam como ruído branco, porém a PACF revela a defasagem 13 significativa, o que indica a presença de sazonalidade, já referida na figura 23(a). Entretanto, mesmo com a defasagem 13 apresentando auto-correlação parcial, tal fato não influenciou a opção pelo modelo, pois conforme os critérios apresentados na tabela 3, o modelo ARIMA (1,1,0) estima melhor os dados.

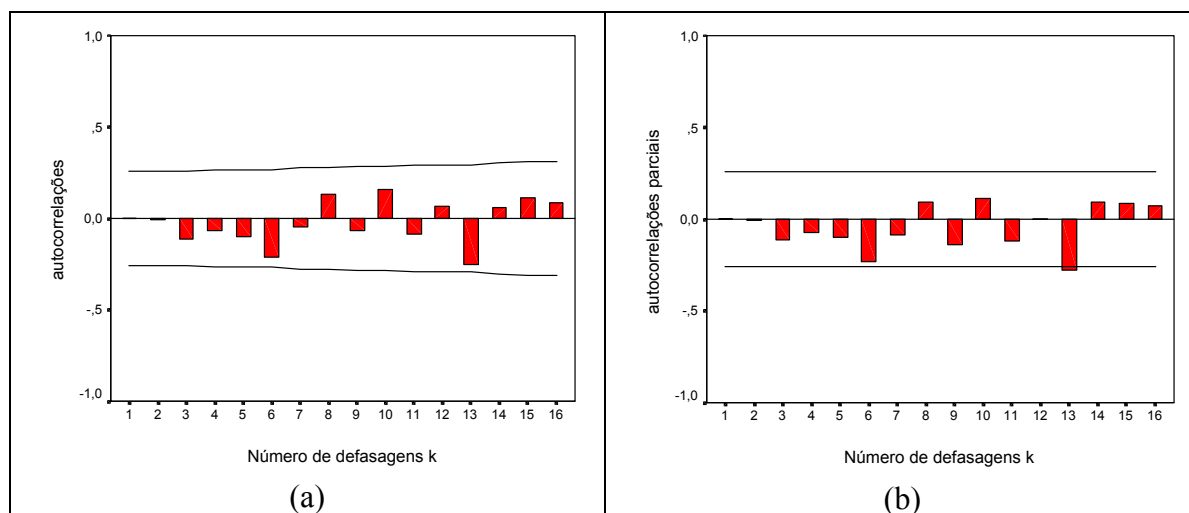


Figura 24- (a) Função de auto-correlação e (b) Função de auto-correlação parcial para o modelo ARIMA(1,1,0)

[fonte: elaborada pela autora, utilizando o software SPSS 8.0]

A tabela 3 apresenta alguns dos modelos analisados e os critérios que levaram à escolha definitiva do modelo ARIMA (1,1,0). Os demais modelos não relacionados ou apresentavam um coeficiente não-significativo ou apresentavam variância do erro maior que o modelo escolhido.

Tabela 3: Critérios de comparação para verificação do melhor modelo

Modelo	<i>p-value</i> dos coeficientes	Critério AIC	Critério SBC	Estimativa $\sigma_{\varepsilon}^2$
ARIMA(1,1,0)	$\phi_1 : 0,011$ $\mu : \mathbf{0,703}$	768,12 (T=59)	772,27 (T=59)	25470,19
ARIMA (0,1,1)	$\theta_1 : 0,013$ $\mu : \mathbf{0,686}$	768,60 (T=59)	772,76 (T=59)	25682,38
SARIMA(0,1,0)(0,0,1) <sub>12</sub>	$\Theta_1 : \mathbf{0,173}$ $\mu : \mathbf{0,857}$	771,92 (T=59)	776,07 (T=59)	26883,91
SARIMA(0,1,0)(0,1,1) <sub>12</sub>	$\Theta_1 : 0,091$ $\mu : \mathbf{0,428}$	627,84 (T=47)	631,54 (T=47)	29506,42

Fonte: Análise no pacote SPSS, versão 8.0.

Os coeficientes de auto-correlação dos resíduos do modelo ARIMA(1,1,0) são estatisticamente não-significativos. Isso pode ser afirmado com base na conclusão obtida pelo teste de *Ljung-Box*, que não rejeita, para qualquer defasagem  $k$ , a hipótese de erros não-correlacionados. Assim, pode-se considerar, com base no teste *Ljung-Box*, que os resíduos comportam-se como ruído branco, e que este modelo é adequado para realizar previsões.

#### 5.2.1.4. Etapa de previsão

Conforme Box & Jenkins (1976), as previsões para o modelo ARIMA(1,1,0)  $h$  ‘passos à frente’ são expressas pela equação (5.2).

$$\hat{Z}_t(h) = Z_t + \mu h + (Z_t - Z_{t-1} - \mu) \frac{\phi_1(1 - \phi_1^h)}{(1 - \phi_1)} \quad (5.2)$$

Assim para obter a previsão ‘um passo à frente’ do número de atendimentos dos clientes tipo avulsos, substitui-se os valores dos parâmetros na equação (5.2) resultando nas equações (5.3).

$$\hat{Z}_t(1) = Z_t + 6,0082 * 1 + (Z_t - Z_{t-1} - 6,0082) \frac{-0,3301(1 + 0,3301^1)}{(1 + 0,3301)}$$

$$\hat{Z}_t(1) = 0,6699Z_t + 0,3301Z_{t-1} + 7,9915 \quad (5.3)$$

A previsão da demanda do número de atendimentos dos clientes tipo avulsos, para ‘um passo à frente’ (no tempo 61), é dado pela equação (5.4).

$$\hat{Z}_{60}(1) = 0,6699 * 552 + 0,3301 * 720 + 7,9915 \cong 616 \quad (5.4)$$

#### 5.2.2. Obtenção da previsão de demanda através da modelagem econométrica

Considerando a opinião de especialistas, assim como os preceitos da teoria econômica, para verificar quais fatores poderiam explicar economicamente o comportamento do número de atendimentos, formulou-se a expressão (5.5). Nesta equação, o fator renda é representado pelo PIB; o fator preço do produto é representado pelo preço do serviço e o fator preço de bens relacionados é representado pelo dólar. Desta forma,

foram escolhidas algumas variáveis para explicar cada um dos fatores indicados, servindo de base para a modelagem e para a previsão da demanda.

$$\text{Demanda} = f(\text{US\$}, \text{PIB}, \text{preço}, \text{vendas}) \quad (5.5)$$

Entre as variáveis que fazem parte do estudo, está o número de atendimentos realizados na empresa, para clientes do tipo avulsos, como variável dependente. Como variáveis independentes foram utilizadas variantes dos fatores econômicos. A primeira delas é o valor médio do dólar no mês. Ainda para explicar o comportamento do dólar, foi obtida a variação mensal do mesmo. Também foi utilizado o valor do PIB industrial mensal, estimado através da média aritmética, durante o trimestre. Uma variante do PIB foi a variação acumulada do PIB industrial, a qual consiste no valor acumulado até o mês em estudo em relação ao valor inicial acumulado do PIB industrial. O valor inicial acumulado do PIB industrial é a soma do valor do PIB industrial por um período de 30 meses. Optou-se por utilizar o PIB industrial visto que os serviços da empresa estão atrelados ao comportamento do setor.

Outra variável independente incluída no processo de modelagem foi o índice IPC-IEPE. Com base neste índice, calculou-se um índice acumulado, que consiste no produto entre o índice IPC-IEPE do mês e o índice acumulado do mês anterior, sendo o valor inicial do índice acumulado considerado 1. Com base no índice acumulado, foi obtido o preço deflacionado, que também foi considerado como variável independente para construir o modelo. O preço deflacionado é a razão entre o preço praticado pela empresa e o índice acumulado. Para efeitos de modelagem, este preço foi dividido por 30, para equiparar-se à magnitude dos demais índices. Por fim, optou-se por incluir o Índice da Produção Física Industrial, que representa o comportamento da produção no país, visto que não se dispõe dos números de vendas no setor.

#### *5.2.2.1. Modelo de regressão linear múltipla*

O procedimento inicial foi realizar uma regressão linear múltipla para o modelo da equação (5.6), utilizando todos os indicadores disponíveis para cada fator, conforme citado no item anterior. Após este procedimento, iniciou-se a modelagem considerando aqueles indicadores que revelaram maior significância. Após analisar muitos modelos, resultantes

das combinações dos indicadores e de suas variantes, chegou-se ao modelo dado pela equação (5.6). Os valores das variáveis explicativas encontram-se no apêndice B.

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \beta_3 X_3 \quad (5.6)$$

onde:  $Y$  = demanda ou número de atendimentos dos clientes do tipo avulso;

$\beta_0$  = constante do modelo;

$\beta_1$  ;  $\beta_2$  ;  $\beta_3$  = coeficientes do modelo;

$X_1$  = valor médio do dólar;

$X_2$  = variação acumulada do PIB industrial e

$X_3$  = preço deflacionado pelo IPC-IEPE (dividido por 30).


Utilizando o método de mínimos quadrados ordinários (MQO) para estimar o modelo da equação (5.6), obteve-se o modelo dado pela equação (5.7). Neste modelo, os coeficientes são significativos, e o *p-value* de cada um deles encontra-se entre parênteses, logo abaixo do coeficiente (ver equação 5.7). A análise de variância também revela um modelo significativo, com *p-value* inferior a 0,0005. Contudo o coeficiente de determinação ajustado é baixo (0,514), apesar de ser o mais alto dentre os modelos estudados.

$$Y = -509 \quad -854,2 X_1 + 480 X_2 + 618,1 X_3 \quad (5.7)$$

(0,122)   (0,000)        (0,000)        (0,006)


Para verificar a adequação deste modelo, inicialmente traçou-se, como mostra a figura 25, o papel de probabilidade para os resíduos. Através deste gráfico, é possível verificar que os resíduos não apresentam distribuição normal, o que foi confirmado pelo teste de *Anderson-Darling*, que resultou em um *p-value* de 0,003.

Após a auto-correlação dos resíduos, foi verificada, através do teste *Durbin-Watson*, onde ocorreram problemas de auto-correlação. Como o valor do teste é de 0,941, ao compará-lo ao valor tabelado tem-se a indicação da presença de auto-correlação positiva. A presença de auto-correlação pode ser devida à ausência de uma variável importante como, por exemplo, as vendas mensais de computadores, a qual não foi explicada pelo Índice de Produção Física Industrial.



**Figura 25 – Papel de probabilidade normal para os resíduos da regressão linear múltipla**  
[fonte: elaborada pela autora, utilizando o software Minitab10.2]

Além de problemas de auto-correlação, é necessário verificar a homocedasticidade da variância do erro. Para tanto, procede-se uma análise de resíduos plotando-os contra a variável Y predita. Analisando a figura 26, podemos observar que os resíduos não são aleatórios, mas apresentam a forma com dois vales.



**Figura 26 – Análise de resíduos contra os resíduos padronizados para a regressão linear múltipla**  
[fonte: elaborada pela autora, utilizando o software Minitab10.2]

#### 5.2.2.2. Modelo de regressão linear polinomial

Como o modelo da equação (5.7) tem um poder de explicação baixo e problemas de auto-correlação e de heterocedasticidade, foram testados aproximadamente 30 outros modelos. Dentre eles, havia modelos com transformação logarítmica das variáveis, modelos não-lineares para as variáveis, tais como modelos polinomiais, e outros. O modelo que apresentou simultaneamente um bom poder explicativo (coeficiente de determinação

razoável), coeficientes estatisticamente significativos e coeficientes com sinais tecnicamente corretos, é dado pela equação (5.8).

$$Y = 617,45 - 4403,9 X_1^{0,25} + 3703,18 X_2^{0,25} + 16,45 X_3^4 \quad (5.8)$$


(0,206)      (0,000)                      (0,000)                      (0,004)

Neste modelo, os coeficientes são significativos, e o *p-value* de cada um deles encontra-se entre parênteses. A análise de variância do modelo também é significativa, com *p-value* inferior a 0,0005. Mesmo sendo o melhor modelo encontrado pelo método de estimação MQO, o coeficiente de determinação ajustado é 0,589, considerado como coeficiente de baixo poder explicativo.

Segundo Montgomery & Peck (1982), os coeficientes finais da regressão devem ser analisados para determinar se são estáveis e se seus sinais e suas magnitudes são razoáveis. Experiência prévia e considerações teóricas, ainda segundo os autores, podem fornecer informações que dizem respeito à direção e ao tamanho relativo dos efeitos dos regressores. Desta forma, é importante ressaltar que as variáveis  $X_1$  (valor médio do dólar) e  $X_2$  (variação acumulada do PIB industrial) apresentam coeficientes com sinais corretos.

Quando o dólar sobe, a demanda por serviços de assistência técnica de computadores diminui. Isso era esperado pelos especialistas e foi capturado pelo modelo, que apresenta um coeficiente com sinal negativo para esta variável. Quando o PIB tem um acréscimo, sinal de aquecimento da economia, a demanda por assistência técnica de computadores também aumenta. Isso era esperado pelos especialistas e também está adequadamente modelado, uma vez que o coeficiente desta variável apresenta sinal positivo. Por outro lado, a variável  $X_3$ , relativa ao preço deflacionado pelo IPC-IEPE (dividido por 30), apresentou, nos modelos estudados, um coeficiente positivo, quando se esperava o contrário, pois um aumento no preço neste tipo de serviço faz com que a demanda diminua. Apesar das expectativas, se for observada a figura 27, que apresenta o número de atendimentos e o preço deflacionado em uma escala comparável, nota-se que a demanda, em algumas situações, apresentou aumento quando o preço dos serviços foi reajustado.






**Figura 27 - Número de atendimentos e o preço do serviço em escala comparável**  
**[fonte: elaborada pela autora, utilizando o software SPSS 8.0]**


Visando ainda verificar a adequação deste modelo, plotou-se o papel de probabilidade para os resíduos. Através do gráfico apresentado na Figura 28, é possível verificar que os resíduos apresentam distribuição aproximadamente normal, o que é confirmado pelo teste de *Anderson-Darling*, que não rejeita normalidade, apresentando um *p-value* de 0,195.

Após, a auto-correlação dos resíduos foi verificada através do teste de *Durbin-Watson*. Este teste detectou problemas de auto-correlação. O resultado do teste foi 1,09 e, ao compará-lo ao valor tabelado, tem-se a indicação da presença de auto-correlação positiva. O fato de persistir a auto-correlação reforça a idéia da ausência de uma variável importante no modelo.



**Figura 28 – Papel de probabilidade normal para os resíduos da regressão múltipla polinomial**  
**[Fonte: elaborada pela autora, utilizando o software Minitab10.2]**

Além do problema de auto-correlação, é necessário verificar a homocedasticidade da variância do erro; para tanto, procede-se uma análise de resíduos plotando-os contra a variável Y predita. Analisando a figura 29, observa-se que os resíduos não são aleatórios, apresentando maior dispersão associada aos maiores valores preditos.



**Figura 29 – Análise de resíduos contra os resíduos padronizados da regressão múltipla polinomial**  
[fonte: elaborada pela autora, utilizando o software Minitab10.2]

### 5.2.2.3. Modelo linear polinomial estimado por Mínimos Quadrados Generalizados

Apesar do modelo apresentado na equação (5.8) indicar os melhores indicadores de ajuste entre a classe dos modelos lineares (nos parâmetros), faz-se necessário buscar soluções para os problemas de auto-correlação e de heterocedasticidade. A solução, então, é utilizar outro método de estimação. Assim, escolheu-se estimar os coeficientes do modelo apresentado na equação (5.8) pelo método dos mínimos quadrados generalizados.

Para utilizar os métodos de mínimos quadrados generalizados (com sigla em inglês GLS), é necessário estabelecer os pesos. Os pesos utilizados foram obtidos pelo inverso do quadrado dos erros obtidos na estimação via MQO, conforme recomendado por Montgomery & Peck (1982).


O modelo obtido encontra-se representado pela equação (5.9), na qual os coeficientes são significativos; a análise de variância do modelo também revela

significância, com  $p$ -value inferior a 0,0001. Além disso, o coeficiente de determinação ajustado teve um acréscimo desejável, passando a valer 0,989.

$$Y = 615,6 - 4408,4 X_1^{0,25} + 3678,2 X_2^{0,25} + 18,9 X_3^4 \quad (5.9)$$


(0,000)    (0,000)                    (0,000)                    (0,000)

Para verificar a adequação deste modelo, inicialmente traçou-se, como mostra a figura 30, o papel de probabilidade para os resíduos. Através deste gráfico é possível verificar que os resíduos apresentam distribuição aproximadamente normal, hipótese que não pôde ser rejeitada pelo teste de *Anderson-Darling* ( $p$ -value 0,277).



**Figura 30 – Papel de probabilidade normal para os resíduos da regressão do modelo polinomial usando método dos mínimos quadrados generalizados [fonte: elaborada pela autora, utilizando o software Minitab10.2]**

Após, aplicou-se o teste de *Durbin-Watson* para checar a auto-correlação dos resíduos. Ao comparar o valor do teste, que é de 0,914, ao valor tabelado, conclui-se que persiste o problema de auto-correlação (positiva). Além dos problemas de auto-correlação, também é necessário verificar a homocedasticidade da variância do erro. Para tanto, procede-se uma análise de resíduos plotando-os contra a variável  $Y$  predita. Analisando a figura 31, pode-se observar que os resíduos permanecem não-aleatórios, pois apresentam uma forma de funil. É importante lembrar que, conforme Diaz (2000), problemas de auto-correlação e de heterocedasticidade podem ser uma característica intrínseca da função em estudo ou resultado da omissão de uma variável explicativa, neste caso as vendas, apesar de ter sido utilizado o método de estimação recomendado.



**Figura 31 – Análise de resíduos contra os resíduos padronizados da regressão do modelo polinomial usando método dos mínimos quadrados generalizados [fonte: elaborada pela autora, utilizando o software Minitab10.2]**

Sendo o modelo linear polinomial estimado pelo método dos mínimos quadrados generalizados o melhor modelo encontrado, a equação (5.9) será utilizada para realizar as previsões. Para proceder essas previsões, é necessário disponibilizar as variáveis que fazem parte do estudo, a saber:  $X_1$  = valor médio do dólar;  $X_2$  = variação acumulada do PIB industrial e  $X_3$  = preço deflacionado pelo IPC-IEPE. Para efeitos de modelagem, o preço foi dividido por 30 para equiparar-se à magnitude dos demais índices. Na tabela 4 encontra-se a previsão para o próximo período ( $t = 61$ ).

**Tabela 4 – Previsão de demanda através do modelo econométrico**

Tempo	Dólar	Pib acumulado	Preço deflacionado	Atendimentos previstos
61	2,51	4,45	1,94	677

Neste estudo, as variáveis explicativas  $X_1$ ,  $X_2$  e  $X_3$  já eram conhecidas na realização da previsão, porém, se elas não estiverem disponíveis, precisarão ser estimadas para que seja possível obter a previsão econométrica.

### 5.2.3. Obtenção da previsão de demanda através da opinião de especialistas

Para obter a previsão de demanda através da opinião de especialistas, foram consultados os especialistas previamente selecionados. Em entrevistas individuais, foram

apresentados os dados da série histórica da empresa e solicitado a cada especialista que realizasse uma previsão qualitativa para o próximo período. Na tabela 5 encontram-se as previsões individuais de cada um dos três especialistas que colaboraram com o estudo, e a previsão de demanda individual baseada na opinião dos especialistas, obtida através da média aritmética dos três especialistas colaboradores.

**Tabela 5 – Previsões de demanda através da opinião de especialistas**

Especialista	Atendimentos previstos
Especialista 1	590
Especialista 2	550
Especialista 3	600
média	580

### 5.3. Etapa 3 – Estudo das Variâncias dos Erros das Previsões

Uma vez obtidos os modelos estatístico e econométrico, foi possível obter os valores preditos (previsões em tempos passados) e, por conseqüência, foi possível, também, obter os erros de previsão.

De posse dos erros de previsão, estimou-se a variância associada a eles. A variância do modelo estatístico foi estimada em 25470,19, com 57 graus de liberdade (na estimativa da variância do modelo estatístico, perde-se três graus de liberdade, um grau referente à componente auto-regressiva, outro referente à constante e outro referente à componente de integração), conforme dados da tabela 3. Para o modelo econométrico, a variância também foi estimada pela variância dos erros de previsão, mas com 56 graus de liberdade (na estimativa da variância do modelo econométrico, perde-se quatro graus de liberdade, um grau referente à constante do modelo e três graus referentes aos coeficientes da regressão), sendo seu valor de 27925,77.

Para os dados qualitativos, a variância foi calculada usando a ANOVA de um fator, onde o fator (grupos) são os períodos de previsão, e as repetições são formadas pelos especialistas. Os especialistas selecionados para realizar a previsão na etapa 5.2.3 já realizaram previsões de demanda. Tais previsões foram obtidas para os últimos seis meses e registradas pela empresa, sendo apresentadas no apêndice C. Com estes dados, estimou-se a variância dos erros de previsão em 4854,17.

## 5.4. Etapa 4 – Obtenção da Previsão Combinada

Visto que é possível obter as variâncias das previsões, a previsão combinada é obtida através da média ponderada das previsões individuais, conforme proposto por Bates & Granger (1969). Para obter a previsão combinada, será necessário analisar o comportamento das variâncias para cada uma das três previsões individuais, de onde será possível calcular os seus respectivos pesos.

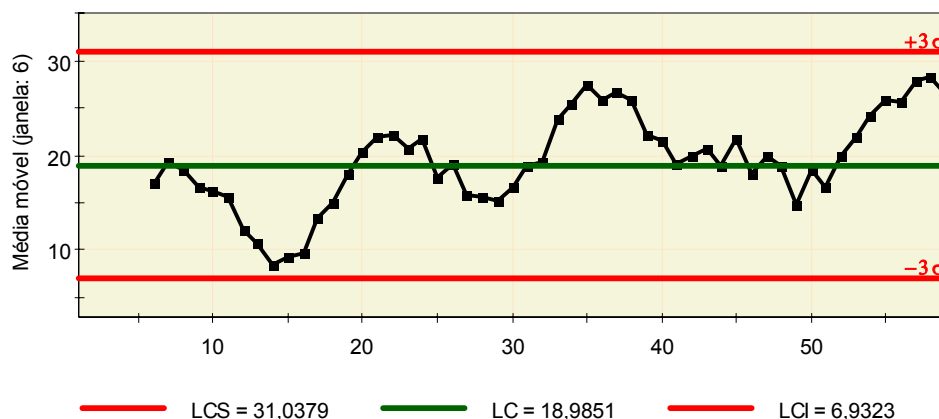
### 5.4.1 Avaliação da estacionariedade das variâncias

Uma vez que os erros de previsão para as previsões quantitativas estão disponíveis, obtém-se, em relação a elas, o gráfico de controle para as médias móveis dos erros, visando verificar se as variâncias apresentam um comportamento estacionário.

#### 5.4.1.1. Avaliação da estacionariedade da variância para a previsão estatística

A fim de construir o gráfico de controle, foi realizada uma análise preliminar com os erros de previsão. Apesar dos erros serem normalmente distribuídos, eles apresentam uma variabilidade muito alta. Passou-se, então, a analisar os erros absolutos e o logaritmo neperiano dos mesmos, que apresentam alta variabilidade e assimetria, respectivamente. A melhor transformação encontrada foi o quadrado do logaritmo neperiano dos erros absolutos, pois apresenta distribuição aproximadamente normal, com menor variabilidade.

Na figura 32 encontra-se o gráfico de controle do quadrado dos logaritmos neperianos dos erros absolutos de previsão para a previsão estatística, utilizando-se seis previsões para calcular a média móvel. Apesar do gráfico estar sob controle estatístico, ele apresenta uma tendência cíclica, indicando que a variância aumenta e diminui ao longo do tempo. Tal padrão evidencia uma série não-estacionária, com variação gradual, indicando a necessidade de estimar a variância da previsão estatística utilizando uma janela pequena.



**Figura 32– Gráfico de controle de médias móveis dos erros absolutos de previsão para a previsão estatística [fonte: elaborada pela autora, utilizando o software Procep]**


Visto que a variância da previsão estatística apresenta um comportamento com variação gradual, a estimativa da variância global, obtida na etapa 5.3, não seria uma boa estimativa nesta situação, então a estimativa da variância foi obtida com uma pequena quantidade de erros de previsões recentes, mais especificamente, de 6 meses para trás. Para estimar a variância da previsão, utilizou-se o erro quadrático médio (MSE), calculado com base nos erros observados nos seis últimos períodos. Para o tempo 61, alvo da previsão deste modelo, estima-se a variância para a previsão estatística em 47.902. As estimativas das variâncias para cada período de tempo, obtidas através do MSE, encontram-se no apêndice D.

#### *5.4.1.2. Avaliação da estacionariedade da variância para a previsão econométrica*

Da mesma forma que para a previsão estatística, para a previsão econométrica foi realizada uma análise preliminar dos erros de previsão, utilizando o gráfico de controle. As mesmas transformações foram analisadas e a melhor transformação foi o quadrado do logaritmo neperiano dos erros absolutos, pois estes apresentam distribuição normal, com menor variabilidade.

Na figura 33, encontra-se o gráfico de controle do quadrado dos logaritmos neperianos dos erros absolutos de previsão para a previsão econométrica, utilizando seis previsões para calcular a média móvel. Apesar dos pontos do gráfico estarem dentro dos limites de controle, é possível observar que, ao longo de todo o período estudado, a variância apresenta variações graduais. Assim, pode-se considerar que a série é não-

estacionária, recomendando-se uma janela mais curta para estimar a variância da previsão econométrica.



**Figura 33 – Gráfico de controle de médias móveis dos erros absolutos de previsão para a previsão econométrica [fonte: elaborada pela autora, utilizando o software Procep]**

Uma vez que a variância da previsão econométrica também apresenta um comportamento não-estacionário gradual, ela será, da mesma forma, estimada com uma janela curta, de 6 meses. Utilizando o mesmo procedimento descrito para o modelo estatístico, a variância para a previsão econométrica no tempo 61 foi estimada em 25.148. As estimativas das variâncias da previsão econométrica para cada período de tempo, obtidas através do MSE, encontram-se no apêndice E.

#### *5.4.1.3. Avaliação da estacionariedade da variância para a previsão baseada na opinião de especialistas*

No estudo em questão, não havia dados disponíveis para testar a hipótese de estacionariedade da variância. As previsões feitas por especialistas e registradas na empresa cobriam um período de apenas seis meses. Sendo assim, a estimativa da variância foi feita utilizando todo o conjunto de dados disponíveis. Tal estimativa já foi obtida na etapa 5.3, sendo que a variância de previsão foi estimada em 4.854. No futuro, quando a série referente às estimativas dos especialistas e a seus respectivos erros estiver mais longa, a estacionariedade da variância poderá ser testada.



### 5.4.2 Cálculo dos pesos

Uma vez definido o comportamento das variâncias e obtidas as estimativas das variâncias de previsão para cada modelo, é possível obter os pesos para cada uma das três previsões individuais. Isso é feito utilizando a equação (4.1), reproduzida a seguir. A tabela 6 apresenta os cálculos dos pesos para as três previsões.

$$w_i = \frac{1/\sigma_i^2}{1/\sigma_{est}^2 + 1/\sigma_{eco}^2 + 1/\sigma_{esp}^2} \quad i = \{est, eco, esp\} \quad (4.1)$$

**Tabela 6 – Valor dos pesos para as três previsões individuais**  
[fonte: elaborada pela autora]

Previsão	Valor do peso
Estatística	$w_{est} = \frac{1/47902}{1/47902 + 1/25148 + 1/4854} = \frac{0,000021}{0,000267} = 0,078$
Econométrica	$w_{eco} = \frac{1/25148}{1/47902 + 1/25148 + 1/4854} = \frac{0,000040}{0,000267} = 0,149$
Baseada na opinião de especialistas	$w_{esp} = \frac{1/4854}{1/47902 + 1/25148 + 1/4854} = \frac{0,000206}{0,000267} = 0,772$

### 5.4.3 Cálculo da previsão combinada

Uma vez que os pesos foram calculados para todas as três previsões, a previsão combinada “um passo à frente” (período 61) foi obtida através da aplicação dos pesos e das previsões individuais na equação (4.2), também reproduzida a seguir:

$$F_c = w_{est}F_{est} + w_{eco}F_{eco} + w_{esp}F_{esp} \quad (4.2)$$

Assim, aplicando os valores das previsões obtidas na etapa 5.2 e os pesos calculados anteriormente, chega-se à estimativa de previsão de demanda combinada em 598 atendimentos a clientes avulsos, conforme a equação (5.10).

$$F_c = 0,078 * 616 + 0,149 * 677 + 0,772 * 580 \cong 598 \quad (5.10)$$

## **5.5. Etapa 5 – Verificação da necessidade de fazer ajuste**

De posse da previsão combinada, o próximo passo consiste em verificar se existem especialistas conhecedores de aspectos que dizem respeito ao mercado e ao ambiente competitivo, os quais possam indicar os acontecimentos das próximas semanas (aspectos que ainda não foram detectados pelos primeiros especialistas, porque ainda não aconteceram ou porque estão em curso), contribuindo para um possível ajuste da previsão combinada. Para este estudo de caso, a empresa conta com a colaboração de dois especialistas que conhecem o mercado. Um deles é o sócio-gerente, responsável pela administração geral da empresa (especialista 1). O outro especialista é um fornecedor da empresa, que conhece bem a área de assistência técnica de computadores pessoais (especialista 2).

## **5.6. Etapa 6 – Obtenção da Previsão Final**

Uma vez que a empresa dispõe de especialistas com conhecimento para realizar eventuais ajustes, a estrutura proposta foi aplicada para os dois especialistas. Novamente aqui, não foi utilizado o número de especialistas indicado pela literatura devido às dificuldades inerentes à área de estudo.

Passo 1: Estabelecer o percentual máximo e mínimo de ajuste

O especialista 1 estabeleceu o percentual máximo em 100% e o percentual mínimo em -40%, o que indica que, passando de um mês para outro, a demanda pode apresentar de um crescimento de 100% até uma redução de 40%. Já o especialista 2 estabeleceu o percentual máximo em 100% e o percentual mínimo em -50%. Tendo em vista as informações fornecidas pelos dois especialistas, os limites foram definidos como percentual máximo de 100% e percentual mínimo de -45%.

Passo 2: Montar a listagem dos fatores

Estabelecidos os percentuais máximo e mínimo de ajuste, os especialistas passam a descrever os fatores que influenciam o comportamento da demanda. A listagem com todos os fatores descritos se encontra na tabela 7.

**Tabela 7 – Pesos e opiniões dos especialistas para os fatores que influenciam a demanda**  
 [fonte: elaborada pela autora considerando o relato dos especialistas 1 e 2]

Fatores que Influenciam a Demanda	Especialista 1			Especialista 2		
	Peso	Peso normalizado em %	Intensidade de manifestação no próximo período	Peso	Peso normalizado em %	Intensidade de manifestação no próximo período
Avanço da tecnologia (internet, hw, sw)	8	8,6	0	9	9,7	0
Condições de pagamento facilitadas	6	6,5	0,05	5	5,4	0,1
Desempenho comercial da empresa	1	1,1	0	1	1,1	0
Dias comemorativos (pais, mães, Natal, Páscoa, das crianças, namorados)	4	4,3	0,03	5	5,4	0,05
Disponibilidade de <i>Softwares</i> livres	5	5,4	0	4	4,3	0
Estabilidade econômica	6	6,5	0	5	5,4	0
Familiarização dos usuários com a informática	3	3,2	0	2	2,2	0
Férias de inverno	5	5,4	0	6	6,5	0
Fim das férias de verão	5	5,4	0	6	6,5	0
Inflação	7	7,5	-0,2	8	8,6	-0,3
Lançamento de um novo <i>hardware</i>	7	7,5	0	8	8,6	0
Modo de utilização (intensidade do uso)	1	1,1	0	1	1,1	0
Novo perfil de usuários (adolescentes, terceira idade, etc.)	2	2,2	0	1	1,1	0
Lançamento de um novo <i>software</i>	6	6,5	0	8	8,6	0
Alteração na qualidade dos produtos	4	4,3	0	2	2,2	0
Promoção de vendas	7	7,5	0,02	6	6,5	0,05
Qualidade dos técnicos (preparado para venda)	4	4,3	0	2	2,2	0
Variação do dólar	9	9,7	-0,35	9	9,7	-0,4
Outro: <u>Ampliação do horário de funcionamento</u>	3	3,2	0,05	5	5,4	0,1

Passo 3: Mensurar o impacto de cada um dos fatores identificados

Após a listagem dos fatores, os especialistas indicam o seu peso, que traduz a eventual influência do respectivo fator sobre a demanda, e a sua opinião a respeito da intensidade com que o respectivo fator estará atuando no próximo período.

Exemplificando, ‘avanço da tecnologia’ pode ser um fator com um peso pronunciado (peso 8, informado em uma escala de 1 a 9), mas para o próximo período, este fator pode não exercer influência, uma vez que não há nenhuma indicação de ‘avanços tecnológicos’ para o próximo período. Os pesos indicados pelos especialistas são normalizados dividindo o peso do fator  $i$  pela soma de todos os pesos.

#### Passo 4: Mensurar a opinião dos especialistas

Os especialistas manifestam a sua opinião conforme expresso na tabela 5.5.

#### Passo 5: Calcular as médias ponderadas

De posse dos pesos normalizados e da opinião dos especialistas referente à influência de cada fator, procede-se o cálculo da média ponderada de cada especialista. Para o especialista 1 a média foi de -0,0413 e para o especialista 2 a média foi de -0,0479.

#### Passo 6: Calcular o ajuste percentual

Após obter as médias ponderadas, que indicam uma redução (sinal negativo) foi obtido aplicado o percentual (mínimo) de ajuste sugerido por eles e calculado o ajuste percentual. Para o especialista 1, o valor do ajuste percentual encontrado foi de  $-0,0413 \times 0,45 = -1,86\%$ , ou seja, o especialista 1 sugere que a previsão combinada deve ser reduzida em 1,86%. Já para o especialista 2, o valor do ajuste percentual encontrado foi de  $-0,0479 \times 0,45 = -2,15\%$ , ou seja, o especialista 2 sugere que a previsão combinada deve ser reduzida em 2,15%. Ao calcular a média aritmética dos percentuais de ajuste dos dois especialistas, obtém-se o **percentual de ajuste médio** que, neste caso, vale -2,0%.

#### Passo 7: Calcular a previsão final

Para proceder com o ajuste da previsão combinada, adiciona-se o valor 1 ao **percentual de ajuste médio**, resultando em 0,98, e multiplica-se o valor desta soma à previsão combinada, obtendo-se como previsão final ( $0,98 \times 598 \cong$ ) 586 atendimentos a clientes avulsos.

## 5.7. Discussão do Modelo Composto Completo

Esta seção tem como objetivo promover uma discussão sobre o modelo proposto. Para dar sustentação a essa discussão, serão abordados quatro tópicos: *(i)* os princípios gerais que regem a proposta; *(ii)* as vantagens do modelo; *(iii)* as dificuldades em utilizar o modelo e *(iv)* generalidades do modelo.

### 5.7.1. Princípios gerais do modelo proposto

A aplicação do modelo proposto em um estudo de caso exemplificou o princípio geral do modelo composto completo, que é compor duas formas de integrar previsões: a combinação de previsões e o ajuste baseado na opinião. Essa composição é feita com o propósito de melhorar a acurácia da previsão. Dentre as características da abordagem proposta, destacam-se:

- (i)* usar várias fontes de informações. Foram utilizadas três fontes de dados: dados passados, que consistem na análise da demanda em períodos anteriores ao estudo, a fim de explicar o comportamento desta no futuro; dados econômicos, que descrevem o comportamento do cenário econômico no qual a empresa está envolvida, empregando, para tanto, indicadores econômicos disponibilizados pelas agências de informações e conhecimento de especialistas, que contribuem com a bagagem de conhecimento adquirido sobre a área de negócio em que a previsão está sendo realizada;
- (ii)* usufruir destas fontes de informações para combinar as previsões individuais visando obter a previsão combinada. De posse das informações provenientes das três fontes de dados acima citadas, utiliza-se um método de combinação de onde resulta uma previsão combinada. Conforme a literatura, a previsão combinada, desde que as parcelas sejam devidamente ponderadas, será mais acurada que as previsões individuais;
- (iii)* avaliar as variâncias das previsões individuais a fim de viabilizar o cálculo da previsão combinada através da forma mais adequada. Uma vez que se conhece o comportamento das variâncias, os pesos serão estimados adequadamente, obtendo-se, assim, uma melhor previsão combinada e

- (iv) captar a contribuição de especialistas que conhecem aspectos relativos ao mercado e ao ambiente competitivo, para aperfeiçoar a previsão combinada através do ajuste baseado na opinião de especialistas.

Uma vez estabelecidos os princípios gerais do modelo composto completo, é possível descrever as vantagens e benefícios que tal modelo apresenta para os previsores.

### 5.7.2. Vantagens do modelo proposto

O modelo composto completo apresenta várias vantagens que o tornam atraente, permitindo ao previsor obter uma previsão mais precisa.

A primeira vantagem a ser apresentada coincide com um de seus princípios, que é usufruir de várias fontes de informações. O fato das fontes de informações serem diferentes e independentes permite que determinada informação, a qual não é agregada por uma previsão, seja agregada por outra. Isto é verificado quando analisa-se os tipos de fontes de informações incluídos no modelo, pois a modelagem estatística captura o comportamento pregresso, a modelagem econômica captura o cenário atual e os especialistas são influenciados pelo passado, presente e futuro, na medida que possuem informações referentes a eventos que ainda não aconteceram (exemplo: um determinado cliente está duplicando a sua planta).

Outra vantagem ainda vinculada às fontes de informações é que elas fornecem suportes diferenciados. Enquanto a previsão estatística e a previsão econométrica têm um enfoque quantitativo, a previsão baseada na opinião de especialistas tem um enfoque qualitativo, permitindo, dessa forma, cobrir diferentes aspectos do problema.

Ao utilizar fontes diferentes de informações, o modelo composto completo apresenta, também, a vantagem de obter a previsão combinada considerando as variâncias de previsão próprias de cada modelo. Se não existe possibilidade de obter esta informação, atribui-se o mesmo peso às três fontes de informação (média aritmética). Por outro lado, se a variância dos erros de previsão é conhecida, estuda-se a variabilidade de cada previsão, o que possibilitará obter uma previsão combinada mais acurada que as previsões individuais.

Além das vantagens citadas, o modelo ainda apresenta o benefício de utilizar duas formas de integração amplamente consolidadas na literatura. A combinação de previsões teve seu início no fim da década de 60. Devido ao longo tempo transcorrido desde a época, muito se pesquisou sobre isso, e as conclusões obtidas pelos diversos estudos comprovam a relevância desta forma de integração. Do mesmo modo, apesar da literatura sobre ajuste baseado na opinião não ser tão numerosa, os resultados apresentados na literatura também são favoráveis ao seu uso.

Além de ser duas formas de integração de previsões consolidadas na literatura, cada uma delas apresenta um benefício específico. A combinação de previsões resulta em previsões mais acuradas, quando comparadas às previsões individuais que a compõem. Já o ajuste baseado na opinião é realizado por especialistas que conhecem o comportamento do mercado e, portanto, podem prever movimentos que não seriam explicados pela série histórica.

Outra vantagem do modelo proposto é, a indicação de procedimentos originais e estruturados para orientar os especialistas na realização de ajustes da previsão combinada. A literatura comenta a respeito das vantagens do ajuste baseado em especialistas, mas é escassa no que concerne à descrição de procedimentos operacionais para a implementação do ajuste baseado em especialistas.

### 5.7.3. Dificuldades no uso do modelo proposto

Naturalmente, o modelo proposto não apresenta apenas vantagens. A sua aplicação apresenta algumas dificuldades que merecem ser comentadas. Algumas dessas dificuldades são inerentes ao processo de previsão como, por exemplo, a dificuldade de obter os dados para construir os modelos quantitativos ou, então, a dificuldade de possuir um profissional habilitado a analisar este tipo de dados.

Para construir o modelo estatístico necessita-se apenas dos dados de demanda ao longo do tempo, mas, muitas vezes, isso já representa uma dificuldade, pois a empresa ainda não armazena estas informações. Além disto, para analisar este tipo de dados, o modelo proposto indica o uso da metodologia de *Box-Jenkins*, sendo, portanto, primordial o auxílio de um profissional habilitado, que domine tal metodologia.

Já para o modelo econométrico, as dificuldades vão além de obter dados e possuir um profissional capacitado para analisá-los. No modelo econométrico, é preciso ter conhecimento para escolher adequadamente as variáveis que explicarão o comportamento da demanda. É preciso definir a estrutura do modelo econométrico, o que envolve (i) descobrir quais as variáveis, dentre as disponíveis, melhor explicarão o comportamento da demanda e (ii) estabelecer a forma do modelo, se o modelo será linear simples ou se será um polinômio, por exemplo. Vencida esta etapa, confronta-se outra dificuldade, que consiste em procurar indicadores econômicos apropriados para descrever as variáveis escolhidas. Infelizmente, os órgãos detentores de informações ainda têm dificuldades na divulgação das mesmas em tempo hábil.

Outra dificuldade, inerente às técnicas qualitativas de previsão, é dispor de especialistas com domínio do conhecimento da área em estudo para realizar e ajustar as previsões. Este estudo, apesar de contar com a colaboração de vários especialistas, foi prejudicado pela falta de previsões qualitativas em tempos passados, o que impossibilitou a obtenção da previsão combinada e da previsão ajustada para períodos diferentes do período 61, alvo deste estudo.

Mesmo vencida a dificuldade de obtenção de dados para subsidiar o cálculo das três previsões individuais, a aplicação do método de combinação ponderada é complexa e exige cuidado na aplicação. Um dos passos mais difíceis é a análise do comportamento dos erros de cada modelo e da correspondente estimativa das variâncias de previsão. Uma análise superficial na avaliação do comportamento das variâncias pode gerar erro na definição dos pesos, o que comprometerá a previsão combinada e, por sua vez, a previsão final.

#### 5.7.4. Generalidade do modelo proposto

O modelo proposto tem características e princípios que permitem aos seus usuários obter uma previsão de demanda confiável em diferentes cenários. Em função disso, as empresas inseridas dentro de um mercado competitivo têm neste modelo uma opção atraente para melhor conhecer sua fatia de mercado e, conseqüentemente, melhor atender a seus clientes finais.



Particularmente, empresas que possuem uma demanda volátil também podem ser beneficiadas com a aplicação deste modelo, pois ele contempla a visão de três enfoques distintos, incluindo a visão de especialistas. Conforme a literatura, para este tipo de demanda a previsão subjetiva (especialistas) fornece os melhores resultados (SANDERS & RITZMAN, 1990).

Este modelo também pode trazer ganhos para empresas que possuem um estreito relacionamento com seus clientes. Uma vez que a decisão do cliente influencia a demanda da empresa, conhecer os seus mecanismos de tomada de decisão como, por exemplo, a quantidade de estoque do cliente, pode ser fundamental para obter uma boa previsão. Tal situação está contemplada no modelo proposto, através do mecanismo de ajuste.

A possibilidade de utilização do modelo proposto irá depender basicamente da disponibilidade da empresa em possuir um sistema de armazenamento de dados e profissionais habilitados a realizar as previsões e ajustes. O armazenamento de dados pode ser feito em bancos integrados, contendo todas as informações da empresa, mas pode, também, ser organizados em planilhas eletrônicas de manuseio simples. Para realizar as previsões quantitativas e analisar as variâncias de previsão, é vital a empresa contar com um profissional especializado nesta área, como um estatístico, por exemplo. Já para realizar a previsão subjetiva e fazer os devidos ajustes, a empresa precisa da colaboração de profissionais que conheçam o mercado e o ambiente econômico no qual a empresa está inserida, bem como os clientes da empresa.

De posse dos elementos necessários para aplicar o modelo, a empresa certamente poderá realizar previsões mais acuradas, conforme comprovado em outros estudos da literatura, os quais contemplaram combinação de previsões e ajuste baseado em especialistas. No entanto, para referendar essa afirmativa, seria necessário realizar a comparação entre as medidas de acurácia propostas na literatura para as previsões individual, combinada e ajustada. Como a empresa não dispunha de previsões qualitativas por mais de seis períodos atrás, não foi possível calcular as medidas de acurácia.

## **Capítulo 6 – Considerações Finais**

### **6.1. Conclusões**

Realizar previsão de demanda é uma atividade importante, pois pode revelar as tendências de mercado e contribuir para o posicionamento estratégico da empresa. As previsões de demanda auxiliam também na solução de problemas mais imediatos como, por exemplo, a definição da quantidade de insumos a serem adquiridos pela empresa.

Existem diversas técnicas de previsão de demanda. Algumas empresas procuram analisar quais são os desejos dos consumidores através de pesquisa de mercado; outras, avaliam a demanda ocorrida no passado através da análise de séries temporais, para prever sua demanda futura; algumas, ainda, verificam o relacionamento da empresa com o contexto econômico, procurando encontrar indicadores econômicos que expressem o comportamento da demanda.

Esta tese apresentou uma modelagem para realizar previsões de demanda que aborda diversos contextos, visando encontrar previsões de curto prazo mais acuradas. O desenvolvimento da modelagem contemplou a utilização de duas formas de integração de previsões - combinação de previsões e ajuste baseado na opinião - e teve como base de informação dados históricos, econômicos e de especialistas.

A combinação de previsões consiste em empregar algum procedimento, seja ele matemático ou subjetivo, de forma a reunir as informações, provenientes de várias previsões, em uma única. Já o ajuste baseado na opinião se refere a correções que devem ser realizadas por pessoas que possuem domínio de conhecimento na área de negócio em que a previsão está sendo realizada, com o intuito de aperfeiçoar a previsão.

Para obter a previsão combinada, foi necessário prever a demanda individualmente, considerando dados históricos, econômicos e opinião de especialistas. Para estimar a previsão de demanda com base em dados históricos, o modelo propõe o uso da metodologia de *Box-Jenkins*, por ser mais robusta. Para obter a previsão de demanda através de dados econômicos, o modelo sugere o uso de análise de regressão, o que possibilita a obtenção de um modelo matemático que trata as variáveis econômicas pertinentes à área de negócio em estudo. A terceira previsão individual consiste em informações provenientes de especialistas, que compõem uma previsão com base no seu conhecimento.

Após obter as melhores estimativas individuais de previsão, o modelo proposto prevê combiná-las. A literatura sobre o assunto é vasta, e muitos são os métodos de combinação de previsões. Estes métodos podem ser classificados como objetivos e subjetivos. Os métodos objetivos usam algum procedimento matemático, como o cálculo da média aritmética das previsões, por exemplo. Já os métodos subjetivos consistem em expressar o pensamento ou conhecimento de pessoas que conheçam a área de negócio em estudo.

A modelagem proposta proporciona a opção de utilização de dois métodos objetivos de combinação. Para escolher entre os diversos métodos existentes na literatura, foi necessário definir quesitos, como facilidade de cálculo ou facilidade de interpretação. Isso ocorreu porque, apesar de a literatura ser farta, não existe consenso sobre qual método fornece a maior acurácia numa situação específica. Existem estudos empíricos que ora indicam um método, ora indicam outro, sendo a média aritmética simples o procedimento que apresenta o maior número de citações na literatura.

A escolha entre as opções sugeridas na modelagem depende do comportamento dos erros das previsões individuais. Sempre que for possível estimar os erros associados às previsões individuais, sugere-se a combinação através da média ponderada das previsões, onde os pesos são inversamente proporcionais às variâncias das previsões individuais. Caso contrário, sugere-se o uso da média aritmética simples. A forma de estimar os pesos neste método depende, ainda, do comportamento das variâncias das previsões individuais, que podem ser consideradas estacionárias ou não.

Uma vez estabelecida a forma de cálculo da previsão combinada e obtida essa previsão, a modelagem prevê verificar se existem especialistas com conhecimento suficiente para realizar ajustes. Em caso positivo, o método apresenta uma estrutura para realizar o ajuste com base no conhecimento dos especialistas. A proposição de uma estrutura formal para subsidiar o ajuste é uma contribuição original deste trabalho e pode minimizar um problema reportado na literatura: o viés inerente à tomada de decisão humana.

A estrutura de ajuste proposta consiste nos especialistas estabelecerem uma listagem de novos fatores, não-contemplados nas previsões individuais, atribuindo pesos de importância e influências que os respectivos fatores podem exercer no próximo período. Uma vez atribuídos os pesos e influências, a estrutura especifica o cálculo do percentual de ajuste obtido a partir de cada especialista consultado. Ao calcular a média para todos os especialistas, tem-se o ajuste percentual médio que, ao ser aplicado à previsão combinada, resulta na previsão final.

A realização de um estudo aplicado em uma empresa de assistência técnica de computadores pessoais permitiu verificar a viabilidade da utilização da modelagem proposta. Utilizando os dados disponíveis na empresa, o estudo foi concluído, comprovando a exequibilidade da proposta que inclui as duas formas de integração. Entre as dificuldades na aplicação da modelagem, destaca-se a necessidade de grande conhecimento das técnicas estatísticas, visando a realizar a escolha dos modelos mais apropriados para o problema em questão (especificação do modelo *Box-Jenkins*, variáveis incluídas no modelo econômico). Essa dificuldade, no entanto, restringe-se ao primeiro ciclo de previsão. Conhecidos os modelos mais apropriados, as previsões subsequentes são fáceis de obter, utilizando-se pacotes estatísticos.

Por outro lado, o modelo revelou muitas vantagens, dentre as quais devem ser citadas: (i) a correta ponderação das previsões individuais, na medida em que o modelo considera o erro inerente a cada previsão; (ii) a possibilidade de fornecer previsões mais robustas, devido ao uso de diversas fontes de informação e (iii) a indicação de procedimentos originais e estruturados para orientar os especialistas na realização de ajustes da previsão combinada.

## 6.2. Pesquisas Futuras

O modelo composto completo, descrito nesta tese, apresenta uma maneira de obter uma previsão de demanda mais acurada. Grande parte das informações foi tratada em pacotes estatísticos, e seus resultados, analisados na planilha EXCEL. O desenvolvimento de um *software* que possua uma interface com os pacotes estatísticos de ambiente WINDOWS facilitaria a aplicação da modelagem.

Muitas são as técnicas quantitativas de previsão de demanda já estudadas. Foram exploradas apenas aquelas consideradas mais robustas, como a metodologia de *Box-Jenkins* ou a análise de regressão. Fica em aberto a possibilidade de continuar a explorar essa mesma modelagem com o uso de outras técnicas de previsões.

Outra possibilidade refere-se a explorar diferentes métodos de combinação. Seria oportuna uma pesquisa que considerasse outros métodos de combinar previsões a ser utilizados e que comparasse seus resultados aos dos métodos utilizados nesta tese. Incluisse aqui também os métodos bayesianos de combinação que não foram abordados nesta tese.

Caso o método de combinação a ser utilizado seja a combinação ponderada, também é possível realizar estudos que verifiquem o tamanho ideal das janelas móveis para a modelagem proposta. Da mesma forma, pode-se propor uma pesquisa que aplique outras maneiras de estruturar os ajustes baseados na opinião e comparar seus resultados com a modelagem proposta. Há poucos estudos a respeito desse assunto.

Por fim, como última sugestão, propõe-se utilizar a modelagem de forma mais ampla, buscando previsões que atendam a outros parâmetros desejados pelo previsor, tais como maior horizonte de tempo e menor custo de previsão, ao invés de enfatizar unicamente a acurácia da previsão.

## Referências

- ABRAHAM, B. & LEDOLTER, J. **Statistical Methods for Forecasting**. John Wiley & Sons, New York, 1983.
- ARMSTRONG, J. S. Forecasting by Extrapolation: Conclusions from 25 Years of Research. **Interfaces**, v.14, n.6, Nov-Dec, 1984. p.52-66.
- ARMSTRONG, J. S. Research on Forecasting: A Quarter-Century Review, 1960-1984. **Interfaces**, v.16, n.1, January-February, 1986, p. 89-109.
- ARMSTRONG, J. S. **Principles of Forecasting: A Handbook for Researchers and Practitioners**. Kluwer Academic Publishers. 2001.
- ARMSTRONG, J. S. Combining Forecasting. In: ARMSTRONG, J. S. **Principles of Forecasting: A Handbook for Researchers and Practitioners**. Kluwer Academic Publishers. 2001a.
- ARMSTRONG, J. S. Extrapolation for Time-series and Cross-section Data. In: ARMSTRONG, J. S. **Principles of Forecasting: A Handbook for Researchers and Practitioners**. Kluwer Academic Publishers. 2001b.
- ARMSTRONG, J. S. Introduction. In: ARMSTRONG, J. S. **Principles of Forecasting: A Handbook for Researchers and Practitioners**. Kluwer Academic Publishers. 2001c.
- ARMSTRONG, J. S. Selection Forecasting Methods. In: ARMSTRONG, J. S. **Principles of Forecasting: A Handbook for Researchers and Practitioners**. Kluwer Academic Publishers. 2001d.
- ARMSTRONG, J. S. & COLLOPY, F. Error Measures for Generalizing about Forecasting Methods: Empirical Comparisons. **International Journal of Forecasting**, v. 8, 1992, p.69-80.
- ARMSTRONG, J. S. & COLLOPY, F. Integration of Statistical Methods and Judgment of Time Series Forecasting: Principles for Empirical Research. In: WRIGHT, G. & GOODWIN, P. (Ed.) **Forecasting with Judgment**. Wiley & Sons, 1998. Disponível em: [www-marketing.wharton.upenn.edu/ideas/pdf/integ.pdf](http://www-marketing.wharton.upenn.edu/ideas/pdf/integ.pdf). Acessado em: 21/08/2003.
- ASHTON, A. H. & ASHTON, R. H. Aggregating Subjective Forecasting: Some Empirical Results. **Management Science**, v.31, n.12, December 1985, p.1499-1508.
- ASKU, C. & GUNTER, S. I. An Empirical Analysis of the Accuracy of AS, OLS, ERLS, and NRLS Combination Forecasts. **International Journal of Forecasting**, v. 8, 1992, p.27-43.
- BATCHELOR, R. & DUA, P. Forecaster Diversity and the Benefits of Combining Forecasts. **Management Science**, v.41, 1995, p.68-75.

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

BESSLER, D. A. & BRANDT, J. A. Forecasting Livestock Prices with Individual and Composite Methods. **Applied Economics**, v.13, 1981, p.513-522.

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

BOX, G. E. P. & JENKINS, G. M. **Time Series Analysis. Forecasting and Control**. Holden-Day. Edição revisada. San Francisco, 1976.

BUNN, D.W. A Bayesian approach to the linear combination of forecasts. **Operational Research Quarterly**, 26, 1975, p.325-329

BUNN, D. W. & SALO, A. A. Adjustment of Forecast with Model Consistent Expectations. **International Journal of Forecasting**, v.12, 1996. p. 163-170.

BUNN, D. W. & WRIGHT, G. Interaction of Judgemental and Statistical Forecasting Methods: Issues & Analysis. **Management Science**, v.37, n.5, May 1991, p.501-518.

CARBONE, R., ANDERSEN, A., CORRIVEAU, Y. & CORSON, P.P. Comparing for Different Time Series Methods the Value of Technical Expertise Individualized Analysis, and Judgmental Adjustment. **Management Science**, v. 29, n.5, May,1983. p. 559-566.

CERVO, A. L. & BERVIAN, P. A. **Metodologia Científica**. 5ª Ed., Prentice Hall, São Paulo. 2002.

CHAMBERS, J. C., MULLICK, S. K. & SMITH, D. D. How to Choose the Right Forecasting Technique. **Harvard Business Review**. July-August, 1971, p.45-74.

CHAN, C. K., KINGSMAN, B. G. & WONG, H. The Value of Combining Forecasts in Inventory Management – a Case Study in Banking. **European Journal of Operational Research**, v.117, 1999, p.199-210.

CHAN, C. K., KINGSMAN, B. G. & WONG, H. Determining when to update the weights in combined forecasts for product demand – an application of the CUSUM technique. **European Journal of Operational Research**, v.153, 2004, p.757-768.

CHUNGLO, F. J. Developing Sales Forecasting – Master Scheduling Software. **Production and Inventory Management Review**, v.5, n.2, 1985, p.56-60

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

CLEMEN, R. T. & WINKLER, R. L. Combining Economic Forecasts. **Journal of Business and Economic Statistics**. v.4, 1986, p.39-46.

COLLOPY, F. & ARMSTRONG, J. S. Rule-Based Forecasting: Development and Validation of an Expert Systems Approach to Combining Time Series Extrapolations. **Management Science**, v.38, n.10, October, 1992, p.1394-1414.

COSTA, M. B. B., LINDAU, L. A., SOUSA, F. B. B. & FOGLIATTO, F. Estudo Comparativo entre Empresas de Ônibus utilizando AHP: o Caso das Empresas Consorciadas de Porto Alegre. In: Transporte em transformação VI, Confederação Nacional de Transporte. Organizadores: Associação Nacional de Pesquisa e Ensino em Transporte. Editora: Universidade de Brasília, 2002, p.76-90. Cap4.

DALRYMPLE, D. J. Sales Forecasting Practices. Results from a United States Survey. **International Journal of Forecasting**, v.3, 1987, p.379-391.

DENZIN, N. K. & LINCOLN, Y. S. **Handbook of Qualitative Research**. Second Edition. Sage Publications, London, 2000.

DEUTSCH, M., GRANGER, C. W. J. & TERÄSVIRTA, J. W. The Combination of Forecasts Using Changing Weights. **International Journal of Forecasting**, v.10, 1994, p.47-57.

DICKINSON, J. P. Some Comments on the Combination of Forecasts. **Operational Research Quarterly**, v.26, 1975, p. 205-210.

DONALDSON, R. & KAMSTRA, M. Forecasting Combining with Neural Networks. **Journal of Forecasting**, v.15, 1996, p.49-61

DRAPER, N. & SMITH, H. **Applied Regression Analysis**, 2<sup>o</sup> edition. John Wiley & Sons, New York, 1981.

EDMUNSON, R.H. Decomposition: a Strategy for Judgemental Forecasting. **Journal of Forecasting**, v.9, 1990, p. 305-314.

EDMUNSON, B., LAWRENCE, M. & O'CONNOR, M. The Use of Non-Time Series Information in Sales Forecasting: a Case Study. **Journal of Forecasting**, v.7, 1988, p.201-211.

ENDERS, W. Applied Econometric Time Series. John Wiley & Sons. New York, 1995.

FAVA, V. L. Metodologia de Box-Jenkins para Modelos Univariados In: **Manual de Econometria**. Vasconcelos, M. A. S. & Alves, D. Editora Atlas, São Paulo, 2000.

FIGLESWSKI, S. & URICH, T. Optimal Aggregation of Money Supply Forecasts: Accuracy, Profitability and Market Efficiency. **The Journal of Finance**, v.28, n.3, June 1983, p.695-710.

FILDES, R. Efficient Use of Information in the Formation of Subjective Industry Forecasts. **Journal of Forecasting**, v.10, 1991, p.597-617.

FLORES, B. E., OLSON, D. L. & WOLFE, C. Judgemental Adjustment of Forecasts: A Comparison of Method. **International Journal of Forecasting**, v.7, 1992, p.421-433.

FLORES, B.E. & WHITE, E.M. A Framework for the Combination of Forecasts. **Journal Academic Marketing Science**, v.16 (3-4), 1988, p.95-103.

FLORES, B.E. & WHITE, E.M. Subjective versus Objective Combining of Forecasts: An Experiment. **Journal of Forecasting**, v.8, 1989, p.331-341.



FONTANA, A. & FREY, J. H. The Interview. From Structured Questions to Negotiated Text. In: DENZIN, N. K. & LINCOLN, Y. S. **Handbook of Qualitative Research**. Second Edition. Sage Publications, London, 2000.

GELADI, P. & KOWALSKI, B.R. Partial Least-Square regression: a tutorial. *Analytica Chimica Acta*, 185, 1986, p.1-17.

GOODWIN, P. Adjusting Judgemental Extrapolations using Theil's Method and Discounted Weighted Regression. **Journal of Forecasting**, v.16, 1997, p. 37-46.

GOODWIN, P. Correct or Combine? Mechanically Integration Judgmental Forecasts with Statistical. **International Journal of Forecasting**, v.16, 2000, p.261-275.

GOODWIN, P. Improving the Voluntary Integration of Statistical Forecasts and Judgement. **International Journal of Forecasting**, v.16, 2000b, p. 85-99.

GOODWIN, P. Integration Management Judgement and Statistical Methods to Improve Short-term Forecasts. **Omega. The International Journal of Management Science**, v.30, 2002, p.127-135.

GRANGER, C. W.J. & RAMANATHAN, R. Improved Methods of Forecasting. *Journal of Forecasting*, v.3, 1984, p.197-204.

GUJARATI, D. **Econometria Básica**. Makron Books. 3<sup>a</sup> Ed., São Paulo, 2000.

GUNTER, S. I. & ASKU, C. N-Step Combinations of Forecasts. **Journal of Forecasting**, v.8, 1989, p.253-267.

GUPTA, S. & WILTON, P. C. Combination of Forecasts: An Extension. **Management Science**. v.33, n.3, March, 1987, p.356-372.

HAMILTON, J. D. *Time Series Analysis*. Princeton University Press, New Jersey, 1994.

HARVEY, N. Improving Judgment in Forecasting. In: ARMSTRONG, J. S. **Principles of Forecasting: A Handbook for Researchers and Practitioners**. Kluwer Academic Publishers. 2001.

HARVEY, N. & BOLGER, F. Graphus versus Tables: Effects of Data Presentation Format on Judgemental Forecasting. **International Journal of Forecasting**, v.12, 1996, p.119-137.

HILL, C., GRIFFITHS, W. & JUDGE, G. **Econometria**. Ed. Saraiva. São Paulo, 2000.

HOLMEN, J. S. A Note on the Value of Combining Short-Term Earnings Forecasts. A test of Granger and Ramanathan. **International Journal of Forecasting**, v.3, 1987, p.239-243.

HUSS, W. R. Comparative Analysis of Company Forecasts and Advanced Time-Series Techniques Using Annual Electric Utility Energy Sales Data. **International Journal of Forecasting**, v.1, n.3, 1985. p.217-239.

JOHNSON, D. & KING, M. **BASIC Forecasting Techniques**. Butterworth & Co., London, 1988.

JOHNSON, J. **Métodos Econométricos**. Ed. Atlas. São Paulo, 1986.

KANG, H. Unstable Weights in the Combination of Forecasting. **Management Science**, v.32, n.6, June, 1986, p.683-695.

KOTLER, P. **Administração de Marketing. Análise, Planejamento, Implementação e Controle**. Editora Atlas, 5ª Ed., São Paulo, 1998.

KOTLER, P. & ARMSTRONG, G. **Princípios de Marketing**. Editora Prentice-Hall do Brasil, 7ª Ed., Rio de Janeiro, 1998.

KUYVEN, P. S. & CUNHA, G. D. **Proposta de uma Abordagem Orientada à Previsão de Demanda de Produtos**. In: 3º Congresso Brasileiro de Gestão de Desenvolvimento de Produto. Florianópolis, SC. Setembro, 2001.

LARRÉCHÉ, J. C. & MOINPOUR, R. Managerial Judgment in Marketing: the Concept of Expertise. **Journal of Marketing Research**, v.20, n.2, 1983, p.110-121.

LAWRENCE, M. J., EDMUNSON, R. H. & O'CONNOR, M. J. The accuracy of Combining Judgmental and Statistical Forecasts. **Management Science**, v.32, n.12, December 1986, p.1521-1532.

LeSAGE, J. P. & MAGURA, M. A Mixture-Model Approach to Combining Forecasts. **Journal of Business & Economic Statistics**, v.10, n.4, 1992, p.445-452.

LIBBY, R. & BLASHFIELD, R. K. Performance of a Composite as a Function of the Number of Judges. **Organizational Behavior and Human Performance**, v.21, 1978, p. 121-129.

LIM, J. S. & O'CONNOR, M. Judgemental Forecasting with Time Series and Causal Information. **International Journal of Forecasting**, v.12, 1996, p.139-153.

LOBO, G. J. Alternative Methods of Combining Security Analysts' and Statistical Forecasts of Annual Corporate Earnings. **International Journal of Forecasting**, v.7, 1991, p.57-63.

MacGREGOR, D. J. Decomposition for Judgmental Forecasting and Estimation. In: ARMSTRONG, J. S. **Principles of Forecasting: A Handbook for Researchers and Practitioners**. Kluwer Academic Publishers. 2001.

MACKAY, M. M. & METCALFE, M. Multiple Methods Forecasts for Discontinuous Innovations. **Technological Forecasting & Social Science**, v.69, 2002, p.221-232.

MAINES, L. An Experimental Examination of Subjective Forecast Combination. **International Journal of Forecasting**, v.12, 1996, p. 223-233.

MAKRIDAKIS, S. Metaforecasting. Ways of Improving Forecasting Accuracy and Usefulness. **International Journal of Forecasting**, v.4, 1988, p.467-491.

MAKRIDAKIS, S. Why Combining Works? **International Journal of Forecasting**, v.5, 1989, p.601-603.

MAKRIDAKIS, S., WHEELWRIGHT, S. C. & HYNDMAN, R. J. **Forecasting. Methods and Applications**. Third Edition. John Wiley & Sons. New York, 1998.

MAKRIDAKIS, S. & WINKLER, R.L. Averages of Forecasts: Some Empirical Results. **Management Science**, v.29, n.9, 1983, p.987-996.

MAHMOUD, E. Combining Forecasts: Some Managerial Issues. **International Journal of Forecasting**, v.5, 1989, p.599-600.

MATHEWS, B. P. & DIAMANTOPOULOS, A. Judgemental Revision of Sales Forecasts: a Longitudinal Extension. **Journal of Forecasting**, v. 8, 1989, p. 129-140.

MATHEWS, B. P. & DIAMANTOPOULOS, A. Judgemental Revision of Sales Forecasts: Effectiveness of Forecast Selection. **Journal of Forecasting**, v. 9, 1990, p. 407-415.

MENEZES, L. M., BUNN, D. W. & TAYLOR, J. W. Review of Guidelines for the Use of Combined Forecasts. **European Journal of Operational Research**, v.120, 2000, p. 190-204.

MILLER, C. M., CLEMEN, R. T. & WINKLER, R. L. The Effect of Nonstationarity on Combined Forecasts. **International Journal of Forecasting**, v.7, 1992, p.515-529.

MONTGOMERY, D. & PECK, E. **Introduction to Linear Regression Analysis**. John Wiley & Sons. New York, 1982.

MORRETIN, P. A. & TOLOI, C. M. de C. **Previsão de Séries Temporais**. Atual Editora, 2<sup>a</sup> Edição. São Paulo, 1987.

MORRIS, P. Combining Expert Judgement: an Bayesian Approach. **Management Science**, v.23, n.7, March, 1977, p. 649-693.

MURDICK, R. G. & GEORGOFF, D. M. Forecasting: A Systems Approach. **Technological Forecasting and Social Change**, v.44, 1993, p.1-16.

NELSON, C. R. The Prediction Performance of the FRB-MIT-PENN Models of U.S. **The American Economic Review**. v.62, n.5, December, 1972, p.902-917.

NELSON, C. R. **Applied Time Series Analysis for Managerial Forecasting**. Holden-Day, San Francisco, 1973.

NEWBOLD, P. & GRANGER, C. W. J. Experience with Forecasting Univariate Time Series and Combination of Forecasts. **Journal Royal Statistical Society**, series A, v.137, n.2, 1974, p.131-165.

PATTON, M. Q. **How to Use Qualitative Methods in Evaluation**, Sage Publications, 1987.

PELLEGRINI, F. & FOGLIATTO, F. Estudo Comparativo entre os Modelos de Winters e de Box-Jenkins para Previsão de Demanda Sazonal. **Produto & Produção**. v. 4, n. especial, abril 2000, p.72-85.

PEREIRA, B. B., COQUEIRO, R. C. O. & PERROTA, A. H. V. Experience in Combining Subjective and Quantitative Forecasts of Open Market Rates. **Journal of Forecasting**, v.8, 1989, p.343-348.

PINDYCK, R. S. & RUBINFELD, L. **Microeconomia**. Prentice-Hall. 5<sup>a</sup> Ed. São Paulo, 2002.

RAUSSER, G. C. & OLIVEIRA, R. A. An Econometric Analysis of Wilderness Area Use. **Journal of the American Statistical Association**, v.71, n.354, Application Section. June, 1976.

REEVES, G. R. & LAWRENCE, K. D. Combining Multiple Forecasts given Multiple Objectives. **Journal of Forecasting**, v.1, 1982, p.271-279.

REMUS, W., O'CONNOR, M. & GRIGGS, K. Does reliable information improve the accuracy of judgmental forecasts? **International Journal of Forecasting**, v.11, 1995, p.285-293.

RIBEIRO, J. L. D. Planejando e conduzindo entrevistas individuais. In: **Entrevistas Individuais: teoria e aplicações**. Programa de Pós-Graduação em Engenharia de Produção. UFRGS. Porto Alegre, 2004.

RIDLEY, D. Combining Global Antithetic Forecasts. **International Transactions in Operational Research**. v.2, n.4, 1995, p.387-398.

ROWE, G. & WRIGHT, G. Expert Opinions in Forecasting: the Role of the Delphi Technique. In: ARMSTRONG, J. S. **Principles of Forecasting: A Handbook for Researchers and Practitioners**. Kluwer Academic Publishers. 2001.

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

SANDERS, N. R. Accuracy of Judgmental Forecasts: A Comparison. **Omega. The International Journal of Management Science**, v.20, n.3, 1992. p.353-364.

SANDERS, N. R. & MANRODT, K. B. Forecasting Practices in US Corporations: Survey Results. **Interfaces**, v. 24, n.2, 1994. p. 92-100.

SANDERS, N. R. & MANRODT, K. B. The Efficacy of Using Judgmental versus Quantitative Forecasting Methods in Practice. **Omega. The International Journal of Management Science**, v.31, 2003. p.511-522.

SANDERS, N. R. & RITZMAN, L. P. Improvement Short-Term Forecasts. **Omega International Journal of Management Science**, v.18, n.4, 1990, p.365-373.

SANDERS, N. R. & RITZMAN, L. P., Bringing Judgment into Combination Forecasts. **Journal of Operations Management**, v.13, 1995, p.311-321.

SANDERS, N. R. & RITZMAN, L. P. Judgmental Adjustment of Statistical Forecasts. In: ARMSTRONG, J. S. **Principles of Forecasting: A Handbook for Researchers and Practitioners**. Kluwer Academic Publishers. 2001.

SANDHUSEN, R. L. **Marketing Básico**. Editora Saraiva. São Paulo, 1998.

TAGLIACARNE, G. **Pesquisa de Mercado. Técnica e Prática**. Editora Atlas, 2a Ed., São Paulo, 1978.

TAYLOR, J. W. & BUNN, D. W. Investigating Improvements in the Accuracy of Prediction Intervals for Combinations of Forecasts: A Simulation Study. **International Journal of Forecasting**, v. 15 , 1999, p. 325-339.

TROSTER, R. L. & MOCHÓN, F. **Introdução à Economia**. Ed. Makron Books. Edição revisada e ampliada. São Paulo, 1999.

WALLIS, K. F. *et al.* **Models of the UK Economy: reviews 1-5**. Oxford University Press, Oxford, 1984-88.

WEBBY, R. & O'CONNOR, M. Judgement and Statistical Time Series Forecasting: a Review of the Literature. **International Journal of Forecasting**, 12, 1996, p.91-118.

WEBBY, R., O'CONNOR, M. e LAWRENCE, M. Judgmental Time-Series Forecasting Using Domain Knowledge. In: ARMSTRONG, J. S. **Principles of Forecasting: A Handbook for Researchers and Practitioners**. Kluwer Academic Publishers. 2001.

WEISBERG, S. **Applied Linear Regression**. John Wiley & Sons. 2<sup>a</sup> Ed., New York, 1985.

WILLEMMAIN, T. R. Graphical Adjustment of Statistical Forecasts. **International Journal of Forecasting**, v.5, 1989, p. 179-185.

WINKLER, R. L. Combining Forecasts: A Philosophical Basis and Some Current Issues. **International Journal of Forecasting**, v.5, 1989, p. 605-609.

WINKLER, R. L. & MAKRIDAKIS, S. The Combination of Forecasting. **Journal of the Royal Statistical Society**, series A, v.146, 1983, p.150-157.

WINKLHOFFER, H. DIAMANTOPOULOS, A. & WITT, S. F. Forecasting practice: a review of the empirical literature and an agenda for future research. **International Journal of Forecasting**, v.12, 1996, p. 193-221.

WOLFE, C. How to Adjust Forecast with the Analytic Hierarchy Process. *Journal of Business Forecasting Methods & Systems*, v.7, n.1, 1988. P.13-17.

WOLFE, C. & FLORES, B. Judgmental Adjustment of Earnings Forecasts, **International Journal of Forecasting**, v.6, 1990, p. 389-405.

WRIGHT, G. LAWRENCE, M. J. & COLLOPY, F. The Role and Validity of Judgement in Forecasting. **International Journal of Forecasting**, v.12, 1996, p.1-8.

ZELLNER, A. **An Introduction to Bayesian Inference in Econometrics**. John Wiley & Sons. New York, 1971

ZOU, H. & YANG, Y. Combining Time Series Models for Forecasting. **International Journal of Forecasting**, v.20, n.1, 2004, p.69-84.

ZOTTERI, G. & VERGANTI, R. Multi-level Approaches to Demand Management in Complex Environments: An Analytical Model. **International Journal of Production Economics**, v.71, 2001, p.221-233.

## APÊNDICES

### APÊNDICE A

Dados do número de atendimentos dos clientes tipo avulsos

Período	Atendimentos	Período	Atendimentos
1	234	31	561
2	267	32	738
3	420	33	438
4	273	34	861
5	252	35	954
6	258	36	1074
7	360	37	1002
8	474	38	819
9	351	39	735
10	375	40	798
11	315	41	627
12	345	42	666
13	342	43	729
14	402	44	1047
15	375	45	900
16	441	46	765
17	348	47	810
18	513	48	708
19	444	49	720
20	804	50	702
21	789	51	1167
22	945	52	963
23	810	53	900
24	909	54	1233
25	939	55	978
26	915	56	990
27	717	57	603
28	780	58	492
29	684	59	720
30	690	60	552

## APÊNDICE B

Valores das variáveis explicativas para a modelagem econométrica

Período	Dólar ( $X_1$ )	Pib ( $X_2$ )	Preço ( $X_3$ )	Período	Dólar ( $X_1$ )	Pib ( $X_2$ )	Preço ( $X_3$ )
1	1,013	1,046	1,982	31	1,914	2,529	2,376
2	1,019	1,092	1,979	32	1,897	2,575	2,317
3	1,025	1,140	1,963	33	1,694	2,631	2,287
4	1,030	1,187	1,950	34	1,684	2,686	2,283
5	1,037	1,234	1,939	35	1,765	2,741	2,281
6	1,043	1,278	1,932	36	1,800	2,800	2,274
7	1,049	1,321	1,923	37	1,881	2,859	2,252
8	1,057	1,364	1,899	38	1,898	2,917	2,236
9	1,061	1,413	1,873	39	1,970	2,979	2,220
10	1,068	1,462	1,867	40	1,930	3,040	2,197
11	1,075	1,511	1,863	41	1,843	3,101	2,178
12	1,081	1,564	1,863	42	1,804	3,159	2,160
13	1,088	1,617	1,856	43	1,775	3,216	2,151
14	1,096	1,670	1,854	44	1,742	3,274	2,143
15	1,103	1,721	1,836	45	1,768	3,340	2,140
16	1,110	1,773	1,816	46	1,828	3,405	2,135
17	1,116	1,825	1,800	47	1,808	3,470	2,134
18	1,124	1,872	1,792	48	1,798	3,540	2,099
19	1,130	1,919	1,788	49	1,809	3,609	2,062
20	1,137	1,966	1,772	50	1,839	3,679	2,059
21	1,144	2,018	1,761	51	1,880	3,750	2,050
22	1,151	2,070	1,759	52	1,948	3,821	2,039
23	1,155	2,121	1,760	53	1,963	3,893	2,034
24	1,162	2,175	1,765	54	1,955	3,961	2,003
25	1,172	2,229	1,788	55	2,002	4,029	2,005
26	1,181	2,283	1,789	56	2,089	4,097	1,996
27	1,188	2,334	1,786	57	2,193	4,166	1,977
28	1,194	2,384	1,811	58	2,297	4,236	1,975
29	1,205	2,435	1,825	59	2,376	4,305	1,966
30	1,502	2,482	2,406	60	2,466	4,379	1,950



**APÊNDICE C**

## Previsões baseadas na opinião dos especialistas

Período	55	56	57	58	59	60
Especialista 1	845	1000	880	680	720	600
Especialista 2	770	960	790	780	640	670
Especialista 3	800	860	1000	640	770	590
Previsão qualitativa (média)	805	940	890	700	710	620

## APÊNDICE D

Valores dos erros e das variâncias estimadas via MSE de 6 períodos para as previsões estatística

Período	erro	Quadrado erro	MSE	Período	erro	Quadrado erro	MSE
1	-			31	-135,01	18227,97	9567
2	26,99	728,55		32	126,42	15982,72	12106
3	155,90	24305,51		33	-249,56	62280,42	14689
4	-104,48	10916,77		34	315,97	99838,45	17442
5	-77,52	6009,25		35	224,65	50467,23	34064
6	-8,92	79,64		36	142,71	20365,99	41322
7	95,99	9213,89		37	-40,38	1630,33	44527
8	139,68	19510,65	8542	38	-214,76	46122,02	41761
9	-93,36	8715,72	11673	39	-152,40	23226,89	46784
10	-24,60	604,99	9074	40	27,28	744,10	40275
11	-60,07	3608,26	7356	41	-158,19	25025,39	23759
12	2,20	4,84	6956	42	-25,44	647,31	19519
13	-1,09	1,18	6943	43	67,88	4608,10	16233
14	51,02	2602,83	5408	44	330,81	109432,51	16729
15	-15,18	230,57	2590	45	-50,01	2501,35	27281
16	49,10	2410,32	1175	46	-191,52	36679,67	23826
17	-79,20	6273,24	1476	47	-7,56	57,12	29816
18	126,31	15953,49	1920	48	-95,14	9050,92	25654
19	-22,52	507,24	4579	49	-29,66	879,95	27055
20	329,23	108392,39	4663	50	-22,03	485,33	26434
21	95,85	9187,52	22295	51	451,07	203460,64	8276
22	143,06	20465,16	23787	52	-58,49	3420,59	41769
23	-91,49	8370,96	26797	53	-138,34	19136,91	36226
24	46,44	2156,86	27146	54	304,21	92544,16	39406
25	54,69	2991,02	24847	55	-153,06	23427,88	53321
26	-22,09	487,88	25261	56	-80,17	6427,61	57079
27	-213,91	45759,46	7277	57	-391,03	152904,68	58070
28	-10,36	107,24	13372	58	-246,75	60884,69	49644
29	-83,19	6921,27	9979	59	183,36	33622,70	59221
30	-33,68	1134,56	9737	60	-100,72	10145,39	61635
				61			47902

## APÊNDICE E

Valores dos erros e das variâncias estimadas via MSE de 6 períodos para as previsões econométrica

Período	erro	Quadrado erro	MSE	Período	erro	Quadrado erro	MSE
1	29,12	847,83		31	-111,18	12361,11	30787
2	30,18	910,68		32	91,05	8289,55	24602
3	158,30	25060,39		33	-350,71	122996,21	20596
4	-14,51	210,42		34	44,17	1951,34	40890
5	-59,31	3517,53		35	174,38	30408,24	41214
6	-77,15	5952,07		36	300,38	90228,76	43979
7	3,63	13,21	6083	37	279,32	78018,99	44373
8	107,09	11469,12	5944	38	97,56	9517,84	55316
9	-33,70	1135,94	7704	39	50,01	2500,60	55520
10	-33,70	1135,38	3716	40	80,50	6480,45	35438
11	-117,88	13894,97	3871	41	-159,19	25342,98	36192
12	-116,93	13671,75	5600	42	-156,34	24443,17	35348
13	-143,67	20641,80	6887	43	-129,15	16679,14	24384
14	-108,03	11670,49	10325	44	148,97	22192,23	14161
15	-150,85	22755,48	10358	45	-1,75	3,08	16273
16	-99,95	9989,35	13962	46	-114,49	13106,86	15857
17	-210,47	44296,84	15437	47	-106,50	11343,10	16961
18	-61,12	3736,10	20504	48	-215,59	46477,83	14628
19	-149,10	22229,51	18848	49	-194,97	38014,35	18300
20	198,49	39399,23	19113	50	-214,33	45935,55	21856
21	166,56	27740,71	23734	51	260,56	67891,29	25813
22	302,37	91425,51	24565	52	85,68	7340,73	37128
23	143,99	20732,66	38138	53	11,82	139,62	36167
24	219,84	48328,25	34211	54	336,38	113152,91	34300
25	222,42	49469,25	41643	55	89,09	7936,29	45412
26	179,79	32323,69	46183	56	140,76	19812,11	40399
27	-35,16	1236,35	45003	57	-192,10	36900,63	36045
28	-1,53	2,34	40586	58	-261,36	68309,87	30880
29	-117,57	13823,42	25349	59	-3,43	11,78	41042
30	-296,42	87864,86	24197	60	-133,85	17916,24	41021
				61			25148

## ANEXOS

### ANEXO A

Procedimentos de estimação de pesos da combinação do método variância mínima para  $p$  combinações

$$1) w_{i,T} = \frac{\left( \sum_{t=T-v}^{T-1} e_{i,t}^2 \right)^{-1}}{\sum_{j=1}^p \left( \sum_{t=T-v}^{T-1} e_{j,t}^2 \right)^{-1}}, \text{ para } i = 1, 2, \dots, p \text{ e } T \text{ o período de tempo}$$

atual.

$$2) w_T = \frac{(\hat{\Sigma}^{-1} \mathbf{1})}{(\mathbf{1}' \hat{\Sigma}^{-1} \mathbf{1})} \text{ onde: } 0 \leq w_{i,T} \leq 1 \text{ para todo } i, \text{ e } \hat{\Sigma}_{i,j} = v^{-1} \sum_{t=T-v}^{T-1} e_{i,t} e_{j,t}$$

$$3) w_{i,T} = \alpha w_{i,T-1} + \frac{\left( (1-\alpha) \left( \sum_{t=T-v}^{T-1} e_{i,t}^2 \right)^{-1} \right)}{\sum_{j=1}^p \left( \sum_{t=T-v}^{T-1} e_{j,t}^2 \right)^{-1}}, \quad 0 < \alpha < 1.$$

$$4) w_{i,T} = \frac{\left( \sum_{t=1}^{T-1} Z^t e_{i,t}^2 \right)^{-1}}{\sum_{j=1}^p \left( \sum_{t=T-v}^{T-1} Z^t e_{j,t}^2 \right)^{-1}},$$

com  $Z \geq 1$  e sendo  $Z$  um peso que dá maior importância a variância de erros recentes.

$$5) w_T = \frac{(\hat{\Sigma}^{-1} \mathbf{1})}{(\mathbf{1}' \hat{\Sigma}^{-1} \mathbf{1})}, \text{ onde: } 0 \leq w_{i,T} \leq 1 \text{ para todo } i, \text{ e}$$

$$\hat{\Sigma}_{i,j} = \frac{\left( \sum_{t=1}^{T-1} Z^t e_{i,t} e_{j,t} \right)}{\left( \sum_{t=1}^{T-1} Z^t \right)} \text{ com } Z \geq 1.$$

É importante salientar que: (i) pequenos valores de  $v$  limita o processo de estimação, utilizando apenas os valores mais recentes; (ii) pequenos valores de  $\alpha$  e grandes valores de  $Z$  significa que é dado mais peso ao valores mais recentes.

**ANEXO B**

Cálculo dos pesos, aproximação para valores do autovetor da matriz de comparações no processo hierárquico analítico

- 1) Soma-se cada coluna da matriz de comparações, então divide-se cada elemento da coluna pela soma da coluna.
- 2) Soma-se cada linha da matriz resultante do passo 1.
- 3) Divide-se cada soma obtida no passo 2 pelo número de linhas da matriz.

**ANEXO C**

Valores do índice aleatório de consistência (RI) no processo hierárquico analítico

N	3	4	5	6	7	8	9	10	11	12	13	14	15
RI	0,58	0,90	1,12	1,24	1,32	1,41	1,45	1,51	1,51	1,48	1,56	1,57	1,59