

**UNIVERSIDADE FEDERAL DE SANTA CATARINA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE
PRODUÇÃO**

Francielly Hedler Staudt

**ESTUDO DE MÉTODOS DE PREVISÃO DE DEMANDA COM
INCORPORAÇÃO DE JULGAMENTOS**

Dissertação submetida ao Programa de Pós-Graduação em Engenharia de Produção da Universidade Federal de Santa Catarina para a obtenção do Grau de Mestre em Engenharia de Produção.

Orientadora: Prof.^a Dr.^a Mirian Buss Gonçalves

Florianópolis

2011

Catálogo na fonte elaborada pela biblioteca da
Universidade Federal de Santa Catarina

S798e Staudt, Francielly Hedler.

Estudo de métodos de previsão de demanda com incorporação de julgamentos [dissertação] / Francielly Hedler Staudt; orientadora, Mirian Buss Gonçalves. – Florianópolis, SC, 2011.

169p.: il., tabs.

Dissertação (mestrado) – Universidade Federal de Santa Catarina, Centro Tecnológico. Programa de Pós-Graduação em Engenharia de Produção.

Inclui referências

1. Engenharia de Produção. 2. Empresas – Previsão. 3. Oferta e procura. 4. Administração da produção. I. Gonçalves, Mirian Buss. II. Universidade Federal de Santa Catarina – Programa de Pós-Graduação em Engenharia de Produção. III. Título.

CDU 658.5

Francielly Hedler Staudt

ESTUDO DE MÉTODOS DE PREVISÃO DE DEMANDA COM INCORPORAÇÃO DE JULGAMENTOS

“Esta Dissertação foi julgada adequada para obtenção do Título de Mestre em Engenharia de Produção, Área de Concentração Logística e Transportes, e aprovada em sua forma final pelo Programa de Pós-Graduação em Engenharia de Produção da Universidade Federal de Santa Catarina”.

Florianópolis, 25 de fevereiro de 2011.

Prof. Antônio Cezar Bornia, Dr.
Coordenador do Curso de Pós-Graduação em Engenharia de Produção

Banca Examinadora:

Prof.^a Mirian Buss Gonçalves, Dra.
Orientadora

Prof. Antônio Sérgio Coelho, Dr.
Universidade Federal de Santa Catarina - UFSC

Prof. Edson Tadeu Bez, Dr.
Universidade do Vale do Itajaí - UNIVALI

Prof. Sérgio Fernando Mayerle, Dr.
Universidade Federal de Santa Catarina - UFSC

Dedico este trabalho aos meus pais.
Seu exemplo de zelo, empenho e
superação me inspiram.

AGRADECIMENTOS

Agradeço ao meu Senhor e Salvador pela oportunidade de viver intensamente com alegria no coração e paz de espírito.

Agradeço às pessoas maravilhosas que fazem parte da minha vida e são um precioso presente para mim: meu pai, minha mãe, meu marido, minha irmã, amigos e colegas. Sem o apoio e perseverança de vocês eu não teria chegado até aqui.

Ao meu pai, agradeço pela educação e amor proporcionados ao longo da minha vida, e em especial pelo auxílio e apoio na execução deste trabalho. Sem você eu não teria alcançado essa conquista!

À minha mãe, batalhadora incansável, agradeço o amor incondicional em todos os momentos.

Ao meu amado marido, Tiago, agradeço pelo auxílio, incentivo e cumplicidade durante todo este período turbulento. Obrigada por ter suportado as dificuldades e ter sido crucial na minha recuperação. A cada dia sou mais completa ao seu lado. Você me faz feliz!

À minha irmã, agradeço o carinho e a estadia durante a execução deste trabalho. Seu companheirismo foi fundamental.

À minha segunda família, de Passo Fundo, agradeço o apoio e auxílio em todos os momentos, apesar da distância.

À minha orientadora, Mirian Buss Gonçalves, por sempre acreditar em mim e no meu trabalho, mesmo em situações controversas. Obrigada pelas orientações preciosas e detalhadas ao longo do mestrado.

Ao professor Antônio Sérgio Coelho e professor Carlos Manuel Taboada Rodriguez pelo apoio e incentivo durante a caminhada.

À colega Vanina M. Durski Silva pelo companheirismo e apoio seja de longe ou de perto.

Agradeço à empresa que disponibilizou os dados para o estudo de caso e tornou possível a conclusão deste trabalho.

Ao CNPq, pelo apoio financeiro que possibilitou minha dedicação exclusiva ao mestrado.

“Previsão é muito difícil, especialmente se for sobre o futuro”.

(Niels Boer, Prêmio Nobel de Física).

RESUMO

A previsão de demanda é a base para o planejamento dos mais diversos níveis de uma empresa. Existem inúmeros métodos quantitativos e qualitativos para calcular ou estimar uma previsão. Porém, no meio empresarial frequentemente utiliza-se uma abordagem que agrega conhecimento de especialistas em resultados quantitativos. As previsões integradas (incorporação de informações contextuais em modelos quantitativos) ainda são pouco discutidas no meio acadêmico. Por isso, o trabalho descreve os diferentes métodos de previsão de demanda existentes, focando especialmente naqueles que consideram alguma incorporação de julgamento ao longo do processo de predição. Apresenta-se um procedimento para implantação de um sistema de previsão de demanda em uma empresa, demonstrando as fases do processo e as ocasiões em que o especialista deve incorporar informações ao resultado estatístico. Para demonstrar uma aplicação prática do procedimento, realizou-se um estudo de caso com três itens classe A de uma indústria madeireira de pequeno porte. A incorporação de julgamento foi realizada pelo gerente da empresa após avaliar o resultado do método quantitativo, aumentando ou reduzindo o valor da previsão para cada produto considerado. Como resultado, os valores previstos após o julgamento tiveram erros médios menores do que utilizando somente a previsão quantitativa. O incremento em acuracidade ocorreu devido a alta variabilidade dos dados e pela estruturação do processo de incorporação de julgamentos.

Palavras-chave: Previsão de demanda, Incorporação de julgamentos, Integração de previsões.

ABSTRACT

Demand forecasting is the fundamental part of several levels in company planning. There are many quantitative and qualitative methods to calculate a forecast that usually are used independently. However, companies frequently use an approach that involves expert knowledge and statistical forecasts. The integrated forecasts (incorporation of contextual information in quantitative models) are still few discussed in academic level. This dissertation describes some existents forecasting methods, specially focusing on judgmental adjustments along with the prediction process. This work presents a procedure to implement a demand forecasting system in a company, showing the process steps and the occasions where the specialist shall incorporate contextual information to statistical outcome. A case study was realized in a small company that deals with wood to illustrate the proposed procedure. Three different high demand products were evaluated. The judgmental adjustments were performed by the company's management, which increased or decreased the outcome of quantitative sales forecasting for each material. The results showed that final forecasts, after the qualitative adjustment, had smaller mean error measures than quantitative forecast alone. The performance increased because of the high data variability and the structured process of judgmental adjustments.

Keywords: Demand forecasting, Judgmental adjustment, Integration of forecasts.

LISTA DE FIGURAS

Figura 3-1 Integração de previsões subjetivas e objetivas – abordagem Webby e O’Connor (1996).	68
Figura 3-2 Métodos de integração de julgamentos e métodos estatísticos – abordagem Armstrong (2001).	70
Figura 3-3 Integração de julgamentos e métodos estatísticos – abordagem Goodwin (2002).	72
Figura 4-1 Passos para implantação de um modelo de previsão. 97	
Figura 4-2 Modelo proposto.	100
Figura 5-1 Gráfico do histórico de demanda com desvios padrões – madeira Itaúba.	113
Figura 5-2 Gráfico do histórico de demanda com desvios padrões – madeira Peroba.	114
Figura 5-3 Gráfico do histórico de demanda com desvios padrões – madeira Cambará.	114
Figura 5-4 Regressão linear (mm de chuva na semana (t) x quantidade vendida semana (t+1)).	116
Figura 5-5 Regressão linear (mm de chuva no mês (t) x quantidade vendida no mês (t+1)).	116
Figura 5-6 Regressão linear (chuva no mês de agosto nos anos 2005 a 2009 x vendas no mesmo período).	117
Figura 5-7 Avaliação relação vendas peroba x vendas cambará.	118
Figura 5-8 Série histórica Cambará sem <i>outliers</i>	119
Figura 5-9 Série histórica Peroba sem <i>outliers</i>	119
Figura 5-10 Série histórica Itaúba sem <i>outliers</i>	119
Figura 5-11 Comparativo da previsão quantitativa e as vendas mensais do Cambará.	125
Figura 5-12 Comparativo da previsão quantitativa e as vendas mensais da Peroba.	126
Figura 5-13 Comparativo da previsão quantitativa e as vendas mensais da Itaúba.	126
Figura 5-14 Previsão cambará mês de dezembro.	130
Figura 5-15 Previsão cambará mês de janeiro.	130
Figura 5-16 Previsão cambará mês de fevereiro.	132
Figura 5-17 Previsão cambará mês de março.	132
Figura 5-18 Previsão cambará mês de abril.	133
Figura 5-19 Previsão cambará mês de maio.	133
Figura 5-20 Previsão cambará mês de junho.	134
Figura 5-21 Previsão cambará mês de julho.	134

Figura 5-22 Previsão cambará mês de agosto.....	135
Figura 5-23 Comparativo entre o desempenho da previsão quantitativa e ajustada – madeira Itaúba.	138
Figura 5-24 Comparativo entre o desempenho da previsão quantitativa e ajustada – madeira Cambará.....	138
Figura 5-25 Comparativo entre o desempenho da previsão quantitativa e ajustada – madeira Peroba.	139
Figura A-1 Relação das chuvas (t) com faturamento (t+1) no período mensal – total geral.	155
Figura A-2 Relação das chuvas (t) com vendas (t+1) no período semanal – madeira Itaúba.	156
Figura A-3 Relação das chuvas (t) com vendas (t+1) no período semanal – madeira Cambará.....	156
Figura A-4 Relação das chuvas (t) com vendas (t+1) no período semanal – madeira Peroba.....	157
Figura A-5 Relação das chuvas com vendas no mesmo período mensal (t) – três madeiras.....	157
Figura A-6 Relação das chuvas com vendas no mesmo período semanal (t) – três madeiras.....	158
Figura A-7 Relação das chuvas (t) com vendas (t) no período mensal – madeira Itaúba.....	158
Figura A-8 Relação das chuvas (t) com vendas (t) no período mensal – madeira Itaúba.....	159
Figura A-9 Relação das chuvas (t) com vendas (t) no período mensal – madeira Itaúba.....	159
Figura A-10 Relação entre as vendas da madeira itaúba e cambará.	160
Figura A-11 Relação entre as vendas da madeira itaúba e peroba.	160

LISTA DE QUADROS

Quadro 3-1 Métodos de combinação de previsões.	77
Quadro 5-1 Classificação ABC das matérias primas (em m ³ /mês).	111
Quadro 5-2 Valores iniciais e de convergência dos coeficientes de amortização do método Brown – madeira peroba.	121
Quadro 5-3 Valores iniciais e de convergência dos coeficientes de amortização do método Holt – madeira peroba.	122
Quadro 5-4 Valores iniciais e de convergência dos coeficientes de amortização do método Média móvel ponderada – madeira cambará.	122
Quadro 5-5 Planilha de avaliação mensal dos métodos de previsão Cambará - junho.	124
Quadro 5-6 Planilha de avaliação método de previsão – mês de agosto – Itaúba.	125
Quadro 5-7 Métodos de previsão selecionados mensalmente... ..	127
Quadro 5-8 Erros de previsão dos métodos quantitativos.	127
Quadro 5-9 Comparativo de vendas dezembro e janeiro – madeira cambará.	131
Quadro 5-10 Erros associados à previsão quantitativa e ajustada – madeira Cambará.	139
Quadro 5-11 Erros associados à previsão quantitativa e ajustada – madeira Itaúba.	140
Quadro 5-12 Erros associados à previsão quantitativa e ajustada – madeira Peroba.	140
Quadro 5-13 Erros médios das previsões ajustadas.	141
Quadro B-1 Comparativo entre <i>Focus Forecasting</i> e método quantitativo mais selecionado.	161
Quadro B-2 Seleção do método quantitativo ano 2009 – madeira itaúba.	162
Quadro B-3 Desempenho FOCUS e método único anual – madeira itaúba.	163
Quadro B-4 Seleção do método quantitativo ano 2009 – madeira cambará.	164
Quadro B-5 Desempenho FOCUS e método único anual – madeira cambará.	164
Quadro B-6 Seleção do método quantitativo ano 2009 – madeira Peroba.	165
Quadro B-7 Seleção do método quantitativo ano 2009 – madeira Peroba.	165
Quadro C-1 Resumo previsões mensais itaúba.	167

Quadro C-2 Resumo previsões mensais peroba.	168
Quadro C-3 Comparativo de vendas dezembro e janeiro – madeira itaúba.	168
Quadro C-4 Comparativo de vendas dezembro e janeiro – madeira peroba.	169

SUMÁRIO

1 INTRODUÇÃO.....	23
1.1 JUSTIFICATIVA DO ESTUDO	24
1.2 OBJETIVOS DO TRABALHO	25
1.2.1 <i>Objetivo Geral</i>	25
1.2.2 <i>Objetivos Específicos</i>	25
1.3 METODOLOGIA.....	26
1.4 LIMITAÇÕES DO TRABALHO	26
1.5 ESTRUTURA DO TRABALHO	27
2 MÉTODOS DE PREVISÃO DE DEMANDA	29
2.1 MODELOS QUANTITATIVOS DE PREVISÃO DE DEMANDA	31
2.1.1 <i>Métodos de análise de séries temporais</i>	32
2.1.1.1 Previsão ingênua, Média simples, Média móvel ...	35
2.1.1.2 Média móvel ponderada e Suavização	36
exponencial	36
2.1.1.3 Média móvel dupla.....	38
2.1.1.4 Método de Brown.....	39
2.1.1.5 Método de Holt.....	40
2.1.1.6 Método de Holt-Winters.....	41
2.1.1.7 Método de decomposição.....	42
2.1.1.8 Método de Box-Jenkins.....	45
2.1.2 <i>Métodos causais</i>	47
2.1.2.1 Regressão linear simples	48
2.1.2.2 Regressão linear múltipla	50
2.1.3 <i>Redes neurais</i>	52
2.2 MODELOS QUALITATIVOS DE PREVISÃO DE DEMANDA	53
2.2.1 <i>Métodos de previsão puramente qualitativos</i>	53
2.3 ERROS DE PREVISÃO	56
2.3.1 <i>Medidas de Erros</i>	57
2.4 CONSIDERAÇÕES FINAIS	60
3 INTEGRAÇÃO DE MÉTODOS QUANTITATIVOS E	
QUALITATIVOS.....	61
3.1 MÉTODOS DE INTEGRAÇÃO DE PREVISÕES	64
3.1.1 <i>Construção do modelo</i>	73
3.1.2 <i>Bootstrapping subjetivo</i>	74
3.1.3 <i>Previsão econométrica</i>	75

3.1.4	<i>Previsão combinada</i>	76
3.1.5	<i>Correção por vieses</i>	80
3.1.6	<i>Decomposição baseada no julgamento</i>	82
3.1.7	<i>Previsão baseada em regras</i>	83
3.1.8	<i>Julgamento revisado</i>	84
3.1.9	<i>Extrapolação corrigida</i>	85
3.2	VIESES NA INCORPORAÇÃO DE JULGAMENTO	87
3.3	ESTRUTURAÇÃO DE JULGAMENTOS	91
3.4	CONSIDERAÇÕES FINAIS	94
4 METODOLOGIA PARA IMPLANTAÇÃO DE UM MÉTODO DE PREVISÃO DE DEMANDA		95
4.1	METODOLOGIAS PARA IMPLANTAÇÃO DE MÉTODOS DE PREVISÃO DE DEMANDA.....	95
4.2	MÉTODO PROPOSTO PARA IMPLANTAR O MODELO DE PREVISÃO EXTRAPOLAÇÃO CORRIGIDA.....	99
4.2.1	<i>Definição do problema</i>	101
4.2.2	<i>Obtenção e tratamento dos dados</i>	102
4.2.3	<i>Previsão Quantitativa</i>	104
4.2.4	<i>Incorporação de Julgamentos</i>	105
4.2.5	<i>Monitoramento</i>	107
4.3	CONSIDERAÇÕES FINAIS.....	108
5 ESTUDO DE CASO		109
5.1	A EMPRESA EM ESTUDO	109
5.2	DEFINIÇÃO DO PROBLEMA	110
5.3	OBTENÇÃO E TRATAMENTO DOS DADOS	111
5.3.1	<i>Coleta de dados</i>	111
5.3.2	<i>Curva ABC</i>	111
5.3.3	<i>Tratamento dos dados</i>	112
5.3.4	<i>Análise dos dados e informações causais</i>	115
5.4	PREVISÃO QUANTITATIVA	120
5.4.1	<i>Aplicação dos métodos quantitativos</i>	120
5.4.2	<i>Avaliação dos métodos quantitativos</i>	122
5.5	INCORPORAÇÃO DE JULGAMENTOS.....	127
5.5.1	<i>Estruturação do julgamento</i>	127
5.5.2	<i>Escolha de especialistas</i>	128
5.5.3	<i>Aplicação dos ajustes por julgamento</i>	129
5.6	MONITORAMENTO	136
5.6.1	<i>Determinação de medidas de erro</i>	136
5.6.2	<i>Feedback aos especialistas</i>	137

5.7	AVALIAÇÃO DOS RESULTADOS	137
5.8	CONSIDERAÇÕES FINAIS	142
6	CONCLUSÕES.....	143
7	REFERÊNCIAS BIBLIOGRÁFICAS.....	147
	APÊNDICE A	155
A.1	SIMULAÇÕES REGRESSÃO LINEAR	155
A.1.1	<i>Relação entre as chuvas e as vendas</i>	<i>155</i>
A.1.2	<i>Relação entre as vendas das madeiras</i>	<i>159</i>
	APÊNDICE B.....	161
B.1	AVALIAÇÃO FOCUS FORECASTING	161
	APÊNDICE C	167
C.1	APLICAÇÃO DOS AJUSTES POR JULGAMENTO	167

1 INTRODUÇÃO

Vive-se em uma sociedade globalizada em que os interesses econômicos geralmente se sobressaem aos demais. De tempos em tempos, enfrentam-se crises financeiras que afetam a economia como um todo, em especial os ambientes produtivos.

Além disso, consumidores cada vez mais exigentes, o mercado cada vez mais competitivo e a necessidade de sobrevivência em um ambiente cada vez mais hostil tem criado um sistema praticamente ilimitado no uso e abuso dos recursos naturais e de energias. De fato, a questão ambiental está cada vez mais presente no nosso dia-a-dia e a necessidade de preservação e desenvolvimento de energias limpas nunca esteve tão em alta. Nesse contexto, percebe-se uma demanda intensa pela eficiência em todos os sentidos.

A maneira como as empresas lidam com essas questões precisa ser modificada para que o crescimento seja sustentável. Não há mais espaço para a suposta contradição entre crescimento e preservação ambiental que dominou as últimas décadas. Mesmo num ambiente extremamente competitivo, em que se visa a minimização de custos e maximização de lucros, faz-se necessário a revisão destes conceitos.

As empresas tomam decisões hoje que irão se refletir substancialmente nas gerações futuras. Iniciando pelo modo de pensar dos gestores, uma reforma geral deve ser implantada nas empresas. Os processos produtivos precisam ser revistos e a tomada de decisão deve envolver todos os aspectos sócio-econômicos e também ambientais em que a corporação está inserida, sempre buscando aumentar a eficiência nos processos.

Neste contexto, torna-se cada vez mais importante a inserção de elementos qualitativos em planejamentos de curto, médio e longo prazo. No que se refere à previsão de demanda, a eficiência está diretamente ligada à qualidade com que os gestores conseguem se antecipar ao mercado. Caso a previsão seja acurada, os estoques podem ser minimizados, a produção pode ser planejada e a cadeia produtiva em geral torna-se mais efetiva. Com isso, os ganhos obtidos podem ser investidos em outras frentes aumentando a competitividade da empresa e permitindo espaço para o crescimento sustentável.

Este trabalho de dissertação tem como objetivo estudar as principais formas de previsão de demanda, visando contribuir para o processo de tomada de decisão dos gestores.

Existem diversas técnicas quantitativas e qualitativas para gerar previsões de demanda, cada uma com seus pontos fortes e fracos. O conhecimento abrangente, mas ao mesmo tempo limitado das pessoas pode inserir análises que nenhum método matemático consegue realizar. Em contrapartida, as previsões quantitativas avaliam um histórico de dados e encontram correlações de ocorrências do passado de forma mais eficiente. Cabe à empresa conhecer as suas necessidades e optar pelo método de previsão mais adequado à sua realidade. Contudo, no dia-a-dia da maioria das organizações os modelos preditivos geram números que passam pelo crivo dos gestores antes de tornarem-se ações, caracterizando uma integração de métodos quantitativos com incorporação de julgamentos.

As formas de integração de previsões têm mostrado potencial para reduzir o erro de previsão e obter melhores estimativas. De acordo com Armstrong e Collopy (1998), "a inclusão de julgamentos, se realizada de forma correta, aumenta a acuracidade da previsão". Porém, a questão fundamental é como as técnicas quantitativas (estatísticas) e qualitativas (julgamento humano) podem contribuir para que o processo de previsão possa ser mais bem integrado (GOODWIN, 2002).

Apesar da incorporação de julgamentos ser amplamente utilizada no meio empresarial, ela normalmente é realizada sem nenhuma estrutura ou processo definidos. Por este motivo, o presente trabalho procura preencher em parte esta lacuna, oferecendo à comunidade científica uma revisão sobre os principais modelos de previsão com incorporação de julgamentos e um procedimento para sua implementação em organizações.

1.1 JUSTIFICATIVA DO ESTUDO

Como o funcionamento da organização está intimamente ligado à previsão da demanda, esse depende, conseqüentemente, da maneira como ela será obtida. Muitos são os métodos de previsão de demanda, contudo a grande maioria desses métodos avalia somente informações quantitativas ou qualitativas. Cada técnica apresenta benefícios específicos para a melhoria da acuracidade, seja analisando as condições econômicas, através de modelos econométricos, seja verificando o que a empresa já realizou, através de séries temporais. Por isso, com a necessidade de previsões cada vez mais confiáveis pode-se exigir a utilização de vários métodos, supondo a utilização da maior quantidade de informações disponíveis.

Diversas empresas agregam análise de dados quantitativos com inclusão de julgamentos como uma tentativa de alcançar previsões mais

acuradas. Porém, poucas têm conhecimento das técnicas e pré-requisitos necessários para a implementação de métodos de previsão integrados. Desta forma, a existência de uma “cultura de ajuste” gera outra necessidade ainda não plenamente atendida e por isso passível de exploração acadêmica, que é a de elaborar formas de estruturação do processo de ajuste que possam servir de diretriz na geração de previsões de demanda de qualquer empresa.

Visto a relevância do assunto no meio empresarial, considera-se importante a discussão do tema no meio acadêmico. As justificativas relatadas embasam um estudo sobre o processo de integração de previsões quantitativas com incorporação de julgamentos, foco desta dissertação.

1.2 OBJETIVOS DO TRABALHO

1.2.1 Objetivo Geral

Apresentar um procedimento para implantação de um processo de previsão de demanda em uma empresa que integre métodos quantitativos e incorporação de julgamentos.

1.2.2 Objetivos Específicos

- Levantar os principais métodos quantitativos e qualitativos de previsão de demanda;
- Avaliar as formas de medição dos erros de previsão;
- Examinar as principais formas de integração de previsões;
- Descrever os métodos de previsão que associam incorporação de julgamentos com métodos quantitativos;
- Investigar os critérios para incorporação de julgamentos de especialistas;
- Examinar as etapas para implementação do processo de previsão de demanda encontradas na literatura;
- Descrever a implantação de um processo de previsão de demanda com integração de previsões;
- Levantar as abordagens para escolha do método de previsão quantitativo;
- Descrever as formas de estruturação de julgamentos;
- Validar o procedimento aplicando em um estudo de caso;
- Definir qual método quantitativo deve ser utilizado no estudo de caso proposto;
- Definir a forma que os julgamentos serão incorporados na previsão quantitativa;

- Observar os impactos da incorporação de julgamentos na previsão final.

1.3 METODOLOGIA

A metodologia científica adotada no trabalho foi embasada em Silva e Menezes (2001).

Quanto a seus objetivos trata-se de uma pesquisa explicativa, na medida em que se realiza um levantamento bibliográfico dos diversos métodos de previsão de demanda e as formas de incorporação de julgamentos. Também se exploram as metodologias para implantação de um sistema de previsão em empresas.

Em relação à forma de abordagem do problema classificou-se a pesquisa tanto qualitativa como quantitativa. Percebe-se seu caráter qualitativo a partir do foco dado ao processo de gerenciamento das previsões e estruturação da incorporação de julgamentos. Verifica-se seu caráter quantitativo na classificação e análise das séries temporais para construção da previsão objetiva a ser ajustada.

Sob o ponto de vista da sua natureza, a investigação aqui desenvolvida é uma pesquisa aplicada, pois realiza-se um estudo de caso a fim de validar o procedimento proposto para implantação de previsão de demanda com incorporação de julgamentos.

1.4 LIMITAÇÕES DO TRABALHO

Este estudo se limita em propor um modelo de previsão de demanda que integre incorporações de julgamento à saída de previsões quantitativas.

Quanto aos métodos de previsão quantitativos são analisados somente os métodos de séries temporais para curto prazo. O trabalho não abordará modelos de previsão para demandas intermitentes. Os métodos causais apresentados na revisão bibliográfica não serão aplicados no estudo de caso por não se ter obtido uma variável que demonstre a correlação necessária.

Outra limitação ocorre no modelo de incorporação de julgamento proposto. Seguindo os passos descritos, somente métodos que realizam ajuste por julgamento à saída de previsões estatísticas são aplicáveis ao procedimento. Além disso, para a escolha do método de previsão quantitativo não é considerado o fator custo na análise.

No estudo de caso a previsão quantitativa baseia-se somente em dados históricos de itens faturados. Produtos que estejam prontos para entrega dentro da empresa não são considerados na análise. Realizou-se a previsão de demanda somente para os itens classe A, visto que os itens

classe B e C possuem demanda intermitente, assunto não abordado neste trabalho. Outra limitação é o ajuste por julgamento ser efetuado somente por um especialista. Isto ocorreu por não haver outra pessoa qualificada para esta função na micro-empresa. Portanto, não aconteceram reuniões gerenciais para análise e consenso das previsões.

1.5 ESTRUTURA DO TRABALHO

O primeiro capítulo do trabalho inicia apresentando os quesitos que irão nortear o estudo, partindo do problema de pesquisa e suas correspondentes justificativas. Em seguida descrevem-se os objetivos que desenvolverão a pesquisa, juntamente com a metodologia utilizada. Por fim, são demonstradas as limitações do trabalho e a sua estrutura.

O capítulo 2 trata da fundamentação teórica de previsão de demanda. Demonstrem-se os modelos de previsão puramente quantitativos e qualitativos. Os métodos quantitativos são classificados em análise de séries temporais e os modelos causais. Na análise de séries temporais verificam-se padrões existentes na série e considera-se a sua repetição ao longo do tempo. Já os modelos causais avaliam a relação entre o comportamento de uma variável externa e a variável a ser prevista através de métodos como a regressão linear. Para avaliar o desempenho das previsões necessita-se de medidas de erro. Elas também servem como parâmetro de escolha do modelo de previsão. O capítulo encerra com a apresentação das principais medidas existentes.

O capítulo 3 trata dos métodos de integração de previsões existentes na literatura. Particularmente, os métodos apresentados tratam de formas de incorporar julgamentos às previsões estatísticas. São descritas três abordagens conforme Webby e O'Connor (1996), Armstrong (2001) e Goodwin (2002). Cada um apresenta diferentes formas de integração, sendo cada método exposto detalhadamente. Na sequência, descrevem-se os vieses introduzidos no julgamento humano finalizando com uma explanação sobre as formas de estruturar julgamentos de especialistas.

No capítulo 4 apresenta-se o modelo proposto no trabalho. Iniciou-se com uma revisão bibliográfica sobre as metodologias existentes para implantação de modelos de previsão, apresentando também trabalhos anteriores que criaram modelos de integração de previsões. Posteriormente, apresenta-se o modelo proposto, descrevendo todos os passos para sua aplicação.

O capítulo 5 apresenta o estudo de caso que valida o procedimento proposto. Todas as etapas demonstradas no capítulo 4 são executadas e descritas. Após o término do estudo, os resultados das

previsões quantitativas e dos ajustes por julgamentos foram avaliados quanto à acuracidade.

O trabalho termina com a apresentação, no capítulo 6, das conclusões obtidas ao longo dos meses de desenvolvimento da pesquisa. Algumas perspectivas para trabalhos futuros nesta área também são propostas.

2 MÉTODOS DE PREVISÃO DE DEMANDA

A customização de produtos fez surgir oportunidades para as empresas ganharem espaço em diversos mercados. Em contrapartida, o número de itens fabricados (SKU's – *Stock Keeping Unit*), a concorrência e a cobertura geográfica aumentaram significativamente, tornando a gestão da demanda mais complexa e exigindo maior atenção das organizações. Neste cenário, o planejamento da demanda desempenha papel de grande importância na coordenação dos fluxos de informação e produtos físicos em uma empresa.

Considerando todos os processos relacionados à previsão, Cavalheiro (2003) define a gestão da demanda como o processo de “monitorar e integrar informações de previsões com o plano de produção, para então enviar ao fornecedor as quantidades e dados dos produtos a serem fabricados”. Contudo, Wanke e Julianelli (2006) descrevem que todas as etapas do planejamento da demanda possuem desafios: seja no tratamento estatístico dos dados históricos ou na interpretação das informações do mercado, além de afirmarem que os principais custos associados às falhas no planejamento encontram-se no custo de estoques excedentes e no custo da falta de produtos.

Segundo Bowersox, Closs e Cooper (2002), todos os momentos em que a logística envolve algum aspecto de planejamento da produção (*make-to-plan, make-to-stock, etc.*), uma previsão é requerida para dirigir o processo. A previsão é uma definição específica do que se pretende vender, quando e onde. Moreira (2008) define a previsão de demanda como “um processo racional de busca de informações acerca do valor das vendas futuras de um item ou de um conjunto de itens”.

Existem duas abordagens para a realização da previsão de demanda periódica em uma empresa: Top-Down e Bottom-Up. A definição destes conceitos é descrita por Wanke e Julianelli (2006, p.155):

Na abordagem *Top-Down*, também chamada abordagem analítica, a previsão de vendas é feita para grupos ou famílias de produtos e depois desagregada para cada SKU, segundo o percentual histórico de vendas. Na abordagem *Bottom-Up*, a previsão é realizada diretamente para cada SKU ou para cada localidade e, posteriormente, agregada por família/grupo de produtos ou região.

Bowersox, Closs e Cooper (2002) afirmam que previsões *bottom-up* são mais apropriadas para mercados que agem independentes, enquanto que o sistema *top-down* é mais útil para situações em que há mais ações centralizadas como promoções e lançamento de produtos.

Em relação ao período, as previsões podem ser realizadas para curto, médio ou longo prazo. Curto prazo costuma se referir a menos de três meses; médio prazo, de três meses a dois anos; e longo prazo, mais de dois anos. Em geral, os modelos de curto prazo compensam a variação aleatória e se ajustam às mudanças recentes (reações de clientes a um novo produto, por exemplo). As previsões de médio prazo são úteis para efeitos sazonais; os modelos de longo prazo detectam tendências gerais de uma organização e são especialmente úteis na identificação de grandes *turning points* (pontos de inflexão) (CHASE; JACOBS; AQUILANO, 2006).

Um acontecimento comum às empresas é realizar a previsão em níveis mais detalhados (p.ex. nível de produto) para horizontes curtos, em que a acuracidade dos dados operacionais tem prioridade, e alteram para previsões de níveis agregados em horizontes longos (DICKERSBACH, 2006).

A previsão de demanda pode ser obtida por métodos quantitativos, qualitativos, ou a junção de ambos por métodos de integração. Os modelos quantitativos caracterizam-se por utilizarem ferramentas matemáticas para a resolução de problemas. Eles podem ser classificados, de maneira geral, como análise de séries temporais e modelos causais. No primeiro caso, a previsão é obtida através da análise do histórico de uma variável. Os modelos causais, por sua vez, realizam previsões com base em correlações entre variáveis.

Os métodos qualitativos são técnicas que utilizam informações subjetivas (intuições, estimativas, pesquisa de mercado, etc.) provenientes de uma ou diversas fontes para gerar previsões. A integração de previsões associa métodos de previsão quantitativos com julgamentos, associando-os de forma que incorporem informações complementares, como padrões da série histórica com conhecimento de especialistas sobre ações de concorrentes.

Nas próximas seções deste capítulo serão apresentados os principais modelos de previsão quantitativos e qualitativos existentes na literatura atual, juntamente com as formas de mensuração de desempenho.

2.1 MODELOS QUANTITATIVOS DE PREVISÃO DE DEMANDA

A previsão quantitativa é o processo de estimar um evento futuro com base em dados passados (histórico). Esses dados são combinados de forma predeterminada até se obter um resultado desejado. Um bom prognóstico pode auxiliar, entre outras coisas, na redução do lead time e dos níveis de estoque em uma empresa. Por isso, a busca por boas estimativas do futuro é o principal objetivo das previsões (JÚDICE, 2005).

Os modelos quantitativos executam uma lógica que utiliza operações matemáticas para gerar uma previsão estatística. Esta lógica avalia os dados históricos para conhecer o comportamento do sistema e, a partir do pressuposto de que o mesmo é estável, extrapola o conhecimento adquirido para o futuro. Tradicionalmente, as técnicas que realizam estas operações são as séries temporais e os modelos causais.

Uma série temporal é uma sequência ordenada no tempo de observações de uma variável. Santos (2006) descreve que as séries temporais podem ser contínuas, quando são medidas sem interrupções no tempo, ou discretas quando mensuradas em intervalos sucessivos de tempo, em geral, em períodos igualmente espaçados.

Xavier et. al (2009) descrevem a análise de séries temporais como a identificação das propriedades estatísticas e comportamentais do histórico. A partir desses dados, sugere-se um modelo matemático que descreva o sistema e, assim, cada parâmetro pode ser facilmente interpretado, tornando possível as predições.

Modelos causais que utilizam séries temporais exploram a relação entre a série de tempo de interesse e uma ou mais séries temporais diferentes. Se estas outras variáveis são correlacionadas com a variável de interesse e se há alguma causa para esta correlação, um modelo estatístico descrevendo esta relação pode ser construído (CAVALHEIRO, 2003).

Um caso a parte é a previsão de demanda baseada em redes neurais artificiais, que pode ser utilizada tanto para métodos causais, quanto para métodos de séries temporais, porém sem que ocorra a aderência a um método matemático explícito (ANSUJ et al., 1996). Pela particularidade das redes neurais, ela será apresentada em uma seção separada, não sendo relacionada com métodos de séries temporais nem causais.

Pela diversidade de técnicas é muito importante que a empresa saiba utilizar as ferramentas matemáticas disponíveis para antecipar a demanda futura com alguma precisão. Isso envolve formar e manter uma base de dados históricos de vendas que expliquem suas variações e comportamento no passado, assim como compreender as variáveis internas (promoções, por exemplo) e externas (clima, condições econômicas) da organização (CORRÊA et. al, 1997 *apud* CAVALHEIRO, 2003).

Atualmente existem diversos programas no mercado para auxiliarem as empresas na realização de previsões. Segundo Dias (2004), a grande maioria dos softwares de previsão de demanda não inovou as metodologias de previsão de demanda, ou seja, não foram criados novos métodos de previsão. Há a implementação das técnicas existentes e ferramentas para análise de forma a obter uma previsão mais acurada. Assim, o maior benefício de um *software* comercial é que os erros das previsões foram minimizados. Para auxiliar na escolha do melhor produto, as empresas interessadas em adquirir um sistema de previsão de demanda precisam inicialmente conhecer as suas necessidades e objetivos, para então avaliar qual programa oferece os melhores resultados para a sua realidade.

2.1.1 Métodos de análise de séries temporais

Os métodos de análise de séries temporais são os mais difundidos no meio empresarial principalmente pelo fácil equacionamento matemático. Normalmente são utilizados em situações em que o número de previsões é alto, ou seja, existem muitos itens que precisam ser monitorados. Cada método é formulado para atender a demanda com características específicas.

Apesar das inúmeras técnicas de previsão qualitativas e causais, a maioria das previsões desenvolvidas na logística e na cadeia de suprimento utilizam métodos de séries temporais (BOWERSOX; CLOSS; COOPER, 2002).

Wanke e Julianelli (2006) classificam as previsões com séries temporais em técnicas de Modelo Fixo e técnicas de Modelo Aberto. No primeiro caso as equações já são pré-definidas considerando a existência de determinados componentes nos dados históricos. Os Modelos Abertos, em contrapartida, primeiro analisam e identificam os componentes presentes, para então criar um modelo único que projete tais elementos, prevendo valores futuros.

Bowersox, Closs e Cooper (2002) descrevem os componentes de uma série temporal por seis elementos: nível de demanda, tendência,

sazonalidade, ciclo, fatores promocionais e irregularidades. Mesmo que todos os fatores não sejam utilizados para realizar a previsão, é útil entender o comportamento de cada um para que possam ser incorporados apropriadamente.

Para Peinado e Graeml (2007) o nível da demanda é um patamar do volume de vendas, desconsiderando variações sazonais e aleatórias. Uma boa estimativa para o nível é a média de um longo período histórico. Bowersox, Closs e Cooper (2002) definem a tendência como um movimento de longo prazo em vendas periódicas. Ela pode ser positiva, negativa ou neutra.

Uma série temporal com sazonalidade possui um padrão de mudança que se repete ano após ano (sazonalidade trimestral, semestral, etc.) (MILESKI JÚNIOR, 2007). Já o ciclo ocorre em períodos maiores que os sazonais, representando as variações de médio e longo prazo na série, causadas principalmente por fatores econômicos (WANKE; JULIANELLI, 2006).

O componente promocional caracteriza-se por variações na demanda ocasionadas por atividades de marketing da empresa, como propaganda, acordos ou promoções. Ele deve ser rastreado principalmente nos casos em que é uma das maiores influências na variação das vendas. O componente promocional é diferente dos outros fatores de previsão no sentido de que seu período e magnitude são controlados pela empresa (BOWERSOX; CLOSS; COOPER, 2002). Os autores ainda definem a irregularidade como quantidades aleatórias, sem causa específica e que não se encaixam em nenhuma das outras categorias. Devido a sua natureza aleatória, é impossível prevê-la.

Entre os principais métodos de previsão de modelo fixo está a suavização exponencial. Chase, Jacobs e Aquilano (2006) descrevem os seis principais motivos que levam essa técnica a ser a mais utilizada:

1. Os modelos exponenciais são surpreendentemente exatos;
2. A formulação de um modelo exponencial é relativamente fácil;
3. O usuário consegue entender como o modelo funciona;
4. O modelo não requer muitos cálculos para ser usado;
5. As especificações de capacidade de armazenagem dos computadores são baixas em razão do uso minimizado de dados históricos;
6. Os testes de exatidão para verificar o desempenho do modelo são fáceis de calcular.

Samohyl, Souza e Miranda (2007) classificam os métodos de suavização de acordo com as componentes encontradas na série: tipo de

tendência (nenhuma, aditiva, multiplicativa, aditiva amortecida ou multiplicativa amortecida) e tipo de sazonalidade (nenhuma, aditiva ou multiplicativa). A nomenclatura dos métodos pode ser visualizada na Tabela 2-1. De acordo com os autores, para interpretar a tabela, a primeira letra corresponde à tendência e a segunda à sazonalidade. Por exemplo, NN significa um método sem tendência nem sazonalidade, que é o caso da suavização exponencial. Existem ainda outros métodos na tabela que serão apresentados nas próximas seções: AN é o método de Holt (tendência aditiva e sem sazonalidade), AA é o método de Holt–Winters Aditivo (tendência e sazonalidade aditiva) e AM é o Holt–Winters Multiplicativo (tendência aditiva com sazonalidade multiplicativa). Os métodos diferentes dos tradicionais, que não serão abordados neste trabalho, são os que possuem tendência amortecida, identificados na tabela pela letra *a*. A tendência amortecida corrige o problema da série quando a tendência é não linear através de um parâmetro ϕ .

Tabela 2-1 Classificação dos métodos exponenciais.

Tendência	Sazonalidade		
	Nenhuma (N)	Aditiva (A)	Multiplicativa (M)
Nenhuma (N)	NN	NA	NM
Aditiva (A)	AN	AA	AM
Aditiva Amortecida (Aa)	AaN	AaA	AaM
Multiplicativa (M)	MN	MA	MM
Multiplicativa Amortecida (Ma)	MaN	MaA	MaM

Fonte: Hyndman et al. (2002) *apud* Samohyl, Souza e Miranda (2007).

Estudos já mostraram que determinadas técnicas mais sofisticadas, além de precisarem de uma grande quantidade de dados, na grande maioria dos casos não garantem resultados significativamente melhores que os atingidos com métodos mais simples. Além disso, existem várias técnicas que utilizam a mesma abordagem e apresentam o mesmo grau de efetividade (WANKE; JULIANELLI, 2006).

As séries temporais produzem bons resultados por trabalharem bem em ambientes estáveis, porém elas não reagem a mudanças nos fatores industriais ou economia nacional (SHAFER; MEREDITH; 1998 *apud* CAVALHEIRO, 2003).

As próximas seções apresentarão as principais técnicas baseadas em séries temporais. Dentre os modelos fixos estão: médias, suavização

exponencial, Holt e Holt-Winters. Já no modelo aberto serão demonstradas as técnicas de decomposição clássica e Box-Jenkins.

2.1.1.1 Previsão ingênua, Média simples, Média móvel

Os métodos de previsão ingênua, média simples e média móvel são os modelos mais simples para realizar uma previsão de demanda, por não requererem grande quantidade de dados e pela trivialidade dos cálculos.

Na previsão ingênua o valor estimado para o próximo período é o valor ocorrido no período atual. Samohyl, Souza e Miranda (2007) observam que não é considerada na previsão qualquer outra característica da série, o que desconsidera dados passados. Desta forma, as previsões sempre acompanham as oscilações que ocorrem na demanda defasada por um período. Assim:

$$P_{t+1} = O_t \quad (2.1)$$

Em que:

P_{t+1} : previsão para o período $t+1$

O_t : valor observado no período t (atual)

t : índice do período ($t= 1, 2, 3, \dots$)

Este procedimento torna-se indicado em casos onde a série histórica apresenta uma caminhada aleatória, que pode ser observada, por exemplo, em indicadores de uma conjuntura econômica (SAMOHYL; SOUZA; MIRANDA, 2007).

A média simples, ao contrário da previsão ingênua, utiliza toda a série histórica para realizar a previsão. Neste caso, todos os dados possuem a mesma importância para encontrar o valor futuro. Isto acarreta uma grande suavização dos dados maiores e menores, além de desconsiderar possíveis tendências e sazonalidades. Seu cálculo consiste em somar os valores de todos os períodos (t) e dividir pelo número total de ocorrências (n) conforme a equação 2.2:

$$P_{t+1} = \frac{\sum_{t=1}^n O_t}{n} \quad (2.2)$$

Samohyl, Souza e Miranda (2007) destacam que o método de média simples é considerado um dos piores, apesar de ser muito utilizado. Isto porque ele se adequa melhor a séries que não possuam características de tendência, sazonalidade ou ciclo. Mas como esses aspectos são muito encontrados, não é difícil verificar que outros métodos apresentam melhores resultados.

A média móvel, por sua vez, considera somente um determinado número de períodos recentes para realizar a previsão, descartando os antigos. Assim como a média simples, o cálculo pondera todos os dados do histórico escolhido com o mesmo peso. O número de períodos utilizados determina se a suavização da curva prevista será maior, ou seja, os valores máximos e mínimos são atenuados, ou menor, em que as oscilações ocorridas na demanda são repetidas na previsão. Quanto maior a quantidade de períodos utilizados (termo ‘*m*’ da equação (2.3)), mais as previsões irão se aproximar da média. A cada novo período substitui-se o valor do período mais antigo observado pelo mais recente como demonstra a equação (2.3):

$$P_{t+1} = MM_t = \frac{(O_t + O_{t-1} + O_{t-2} + \dots + O_{t-m+1})}{m} \quad (2.3)$$

Em que:

m: número de períodos contidos na média.

Usualmente, os valores de ‘*m*’ variam de quatro a sete períodos. Se houver tendência nos dados – seja de elevação ou diminuição – quanto mais longo for o período considerado, mais a média móvel apresentará a característica desfavorável de defasar a tendência (CHASE; JACOBS; AQUILANO, 2006).

2.1.1.2 Média móvel ponderada e Suavização exponencial

Apesar da média simples e móvel também suavizarem os dados, nesta seção serão tratados especificamente os casos em que são designados pesos em diferentes períodos do histórico de dados. Serão apresentados os cálculos da média móvel ponderada e a suavização exponencial.

A média móvel ponderada difere da simples por permitir que cada componente da série seja ponderado individualmente, desde que a soma de todos os pesos seja igual a 1 (equação (2.5)). Como os valores

vão se alterando a cada período, relacionam-se os pesos à posição do dado histórico, conforme equação (2.4):

$$P_{t+1} = \frac{w_t O_t + w_{t-1} O_{t-1} + \dots + w_{t-m} O_{t-m}}{m} \quad (2.4)$$

$$w_t + w_{t-1} + \dots + w_{t-m} = 1 \quad (2.5)$$

Em que:

w_t : peso designado ao dado observado do período t.

O_t : valor observado no período atual (t).

O índice ‘m’ corresponde ao número de períodos da média móvel, conforme descrito para a equação (2.3).

A média móvel ponderada tem uma grande vantagem sobre a média móvel simples em ser capaz de variar os efeitos entre os dados antigos e os mais recentes. A desvantagem da média móvel ponderada é a necessidade de determinar os pesos a serem utilizados (CAVALHEIRO, 2003).

No método de suavização exponencial, cada nova previsão é obtida com base na previsão anterior, acrescida do erro cometido na previsão anterior corrigido por um coeficiente. Por isso, apenas três dados são necessários para prever o futuro: a previsão mais recente (P_t), a demanda real que ocorreu nesse período de previsão (O_t) e a constante de suavização alfa (α), que pode variar entre zero e um. A equação (2.6) demonstra matematicamente o exposto:

$$P_{t+1} = \alpha O_t + (1 - \alpha) P_t \quad (2.6)$$

Conforme Slack et. al (1997), o valor de α determina o equilíbrio entre a sensibilidade das previsões às mudanças na demanda e a estabilidade das previsões. Quanto mais próximo de um, maior a velocidade de reação. Para Samohyl, Souza e Miranda (2007), séries que variam mais ao longo do tempo recebem métodos com α maior, enquanto que menor variabilidade implica em α menor. Além disso, os autores afirmam que na prática o coeficiente de amortização deve ser restringido ao intervalo 0,01 e 0,99 pelo fato dos extremos apresentarem resultados iguais a outros métodos ($\alpha=1$ transforma-se em Previsão Ingênua).

Para conhecer o valor adequado de α , define-se algum critério que minimize os erros de previsão. Uma alternativa é utilizar a série histórica de dados para mensurar as discrepâncias para diversos valores de α . Aquele que obtiver os menores erros será o escolhido para prever os períodos futuros. Contudo, Wanke e Julianelli (2006) alertam que é importante definir limites de controle para esses erros e recalculá-los caso esses limites sejam ultrapassados. Dickersbach (2006) afirma que valores comuns para α estão entre 0,1 e 0,3.

Os modelos de suavização exponencial simples requerem uma estimativa inicial para P_t . Quando dados históricos estão disponíveis, adota-se como valor inicial da previsão (P_0) a média dos períodos anteriores ao primeiro valor observado (O_0). Caso não existam valores anteriores para realizar a média, pode-se assumir que $P_0=O_0$, ou fazer uma estimativa subjetiva (PELLEGRINI; FOGLIATTO, 2000).

De acordo com Ballou (1993) as vantagens da técnica de suavização exponencial são a facilidade para aplicação/utilização, necessidade de poucos dados acumulados e, principalmente, ela é adaptável, ou seja, ela se auto corrige conforme haja alterações no comportamento das vendas.

Verifica-se através da equação (2.6) que quanto maior o valor de α , mais importância terá o último período observado. Isto significa que a previsão do período seguinte se comportará de forma muito similar ao valor observado no período atual. Quanto mais α se aproxima de zero, tanto mais as previsões futuras serão amortecidas pelas previsões anteriores, suavizadas pela média dos valores de vendas muito elevados ou muito baixos, que não representam a tendência de longo prazo dos dados.

2.1.1.3 Média móvel dupla

Este método de previsão apresenta bons resultados em séries que possuem tendência. Para calcular o valor da previsão (equação (2.8)) é necessário ter mensurado anteriormente as médias móveis, conforme equação (2.3), e a média móvel dupla. As médias móveis são calculadas com o mesmo número de períodos (m) da média móvel dupla (equação (2.7)):

$$MMD_t = \frac{(MM_t + MM_{t-1} + \dots + MM_{t-m+1})}{m} \quad (2.7)$$

$$P_{t+k} = 2MM_t - MMD_t + k\left[\left(\frac{2}{m-1}\right)(MM_t - MMD_t)\right] \quad (2.8)$$

Em que:

MM_t : média móvel observada no período t ;

MMD_t : média móvel dupla no período t ;

m : número de períodos considerados na média móvel e média móvel dupla.

k : número de períodos futuros a serem previstos.

Wanke e Julianelli (2006) afirmam que o método da média móvel dupla pode ser considerado mais completo quando comparado à média móvel simples, por ser aderente a séries com tendência. No entanto, ambos os métodos assumem que os valores mais recentes são tão importantes quanto os mais antigos para definir o valor futuro, fato que contraria diversas situações práticas.

2.1.1.4 Método de Brown

O método de Brown também é indicado para séries com tendência, como a média móvel dupla. O seu modelo, entretanto, atribui pesos diferentes para os valores históricos utilizados através de um coeficiente de amortecimento (α).

$$A_t = \alpha O_t + (1 - \alpha)A_{t-1} \quad (2.9)$$

$$A'_t = \alpha A_t + (1 - \alpha)A'_{t-1} \quad (2.10)$$

$$P_{t+k} = 2A_t - A'_t + k\left[\left(\frac{\alpha}{1 - \alpha}\right)(A_t - A'_t)\right] \quad (2.11)$$

Em que:

A_t : primeiro amortecimento;

A'_t : segundo amortecimento;

O_t : valor observado no período t .

Para obter os valores iniciais do primeiro e segundo amortecimento, utilizam-se as equações (2.12) e (2.13). Desta forma, a tendência contida na série não é subestimada.

$$A_0 = a_0 - \frac{1-\alpha}{\alpha} b_0 \quad (2.12)$$

$$A'_0 = a_0 - 2 \frac{(1-\alpha)}{\alpha} b_0 \quad (2.13)$$

Em que:

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

b_0 : coeficiente angular da regressão dos valores da série pelo número de períodos.

Caso não sejam utilizadas as equações descritas para o cálculo dos valores iniciais, mas sim a primeira observação da série, não estará sendo considerada a tendência pré-existente (WANKE; JULIANELLI, 2006).

2.1.1.5 Método de Holt

Em 1957 Holt expandiu a suavização exponencial simples para o problema de dados com tendência linear (SAMOHYL; SOUZA; MIRANDA, 2007). O método de Holt realiza o amortecimento exponencial de uma série de dados utilizando dois coeficientes de suavização, α e β , sendo que o primeiro representa o nível e o segundo o crescimento da série.

Os valores dos coeficientes de amortização (α , β) podem variar entre 0 e 1 cada. A equação (2.14) resulta da adição do termo relativo à estimativa da tendência à formulação do amortecimento exponencial simples. A equação (2.15) ajusta a estimativa da tendência, ponderando a estimativa anterior e a mais recente a partir do coeficiente β .

$$N_t = \alpha O_t + (1-\alpha)(N_{t-1} + T_{t-1}) \quad (2.14)$$

$$T_t = \beta(N_t - N_{t-1}) + (1-\beta)T_{t-1} \quad (2.15)$$

$$P_{t+k} = N_t + kT_t \quad (2.16)$$

Em que,

N_t : componente nível;

T_t : componente tendência;

α : coeficiente de amortecimento;

β : coeficiente de amortecimento para a estimativa da tendência;

O_t : valor observado no período t ;
 k : número de períodos futuros a serem previstos.

A equação (2.16) calcula a previsão da demanda para os próximos k períodos. A precisão obtida pela previsão está diretamente relacionada à seleção dos coeficientes de amortização α e β .

2.1.1.6 Método de Holt-Winters

O método de suavização exponencial de Holt-Winters representa apropriadamente dados da demanda em que se verifica a ocorrência de tendência linear, além de um componente de sazonalidade.

Demanda de tipo sazonal caracteriza alguns ramos da indústria alimentícia (refrigerantes e sorvetes), de cosméticos (bronzeadores) e de serviços (intensidade de atendimento de um banco ao longo do dia) (PELLEGRINI; FOGLIATTO, 2000).

O modelo visa suavizar a série através da determinação de seu nível N_t ; da taxa de crescimento e/ou decrescimento da série T_t e dos fatores sazonais S_t (MILESKI JÚNIOR, 2007). O método possui duas formas, uma com sazonalidade aditiva e outra multiplicativa. De acordo com Pellegrini e Fogliatto (2000) no modelo aditivo, a amplitude da variação sazonal é constante ao longo do tempo; ou seja, a diferença entre o maior e menor valor de demanda dentro das estações permanece relativamente constante no tempo. No modelo multiplicativo, a amplitude da variação sazonal aumenta ou diminui como função do tempo. As equações a seguir demonstram o método aditivo:

$$N_t = \alpha(O_t - S_{t-c}) + (1 - \alpha)(N_{t-1} + T_{t-1}) \quad (2.17)$$

$$T_t = \beta(N_t - N_{t-1}) + (1 - \beta)T_{t-1} \quad (2.18)$$

$$S_t = \gamma(O_t - N_t) + (1 - \gamma)S_{t-c} \quad (2.19)$$

$$P_{t+k} = N_t + kT_t + S_{t-c+k} \quad (2.20)$$

Em que,

N_t : componente nível;

T_t : componente tendência;

S_t : componente sazonalidade;

α : coeficiente de amortecimento;

β : coeficiente de amortecimento para a estimativa da tendência;

γ : coeficiente de amortecimento para a estimativa da sazonalidade;

O_t : valor observado no período t ;
 k : número de períodos futuros a serem previstos;
 c : período sazonal.

A equação (2.20) representa a previsão para k períodos à frente, em que c é o ciclo sazonal (se os dados forem mensais, $c=12$, se forem trimestrais, $c=4$). Para o método multiplicativo, as equações diferenciam-se das anteriores por dividir e multiplicar ao invés de somar e subtrair. As equações são demonstradas a seguir:

$$N_t = \alpha \left(\frac{O_t}{S_{t-c}} \right) + (1 - \alpha)(N_{t-1} + T_{t-1}) \quad (2.21)$$

$$T_t = \beta(N_t - N_{t-1}) + (1 - \beta)T_{t-1} \quad (2.22)$$

$$S_t = \gamma \left(\frac{O_t}{N_t} \right) + (1 - \gamma)S_{t-c} \quad (2.23)$$

$$P_{t+k} = (N_t + kT_t)S_{t-c+k} \quad (2.24)$$

Como todos os métodos de suavização exponencial, os modelos de Winters necessitam valores iniciais de componentes (neste caso, nível, tendência e sazonalidade) para dar início aos cálculos. Para a estimativa da componente sazonal, necessita-se de no mínimo uma estação completa de observações, ou seja, c períodos. As estimativas iniciais do nível e da tendência são feitas, então, no período c definido para o componente sazonal (PELLEGRINI; FOGLIATTO, 2000).

Samohyl, Souza e Miranda (2007) recomendam que as previsões realizadas com este método não ultrapassem o ciclo sazonal da série, pois as previsões com um horizonte maior tendem a ser muito ruins.

2.1.1.7 Método de decomposição

A decomposição clássica de séries históricas é uma técnica que se caracteriza por isolar os componentes da série de vendas, analisar o efeito de cada elemento individualmente e, posteriormente, calcular a previsão através da reunificação dos dados.

A decomposição clássica pode gerar previsões através do método aditivo ou multiplicativo. O emprego do método aditivo é melhor nas situações em que as flutuações das componentes não variam com o nível da série, oscilando em torno da média e, o método multiplicativo quando

sua variação em torno da média não é constante, crescendo ou decrescendo no tempo (SAMOHYL; SOUZA; MIRANDA, 2007).

As previsões para o método multiplicativo e aditivo são demonstradas nas equações (2.25) e (2.26), respectivamente.

$$P = T \times S \times C \quad (2.25)$$

$$P = T + S + C \quad (2.26)$$

Em que T refere-se à tendência da série, S a sazonalidade e C o ciclo. Quanto à componente aleatória, esta não é incorporada à previsão final pelo fato de que, ao se tentar prevê-la, os índices apresentam discrepâncias maiores ainda. O nível não foi inserido às fórmulas por se entender que ele é obtido através dos parâmetros (no caso, o coeficiente linear) da linha de tendência.

O primeiro passo para a decomposição de uma série consiste no cálculo da tendência. Segundo Samohyl, Souza e Miranda (2007) a tendência é uma componente de fácil visualização, pois sua presença é percebida quando os valores da série aumentam ou diminuem no intervalo de tempo. Contudo, o comportamento cíclico de uma série temporal também representa crescimentos e quedas, porém, não ocorrem em períodos fixos de tempo. Pela dificuldade de se afirmar a fronteira entre as duas componentes, o ciclo é sempre mensurado juntamente com a tendência.

Chase, Jacobs e Aquilano (2006) afirmam que fatores cíclicos são mais difíceis de determinar porque o período pode ser desconhecido ou a causa do ciclo pode não ser considerada. Barbosa e Wanke (2010) reforçam a afirmação anterior relatando que devido à dificuldade em trabalhar com ciclos, que podem ser confundidos com tendência, alguns autores simplificam a equação, não os considerando como um item da equação.

Para iniciar os cálculos, deve-se avaliar o período em que o padrão sazonal se repete. Considerando que a sazonalidade seja anual ($n=12$) e os dados mensais, o cálculo da tendência e ciclo é realizado através da média móvel centrada (MMC), apresentada na equação (2.27) :

$$MMC = \frac{MM_1 + MM_2}{2} \quad (2.27)$$

Em que MM_1 é a média aritmética das doze primeiras observações e MM_2 das doze seguintes, conforme (2.28) e (2.29):

$$MM_1 = \frac{1}{n} \sum_{t=1}^{12} O_t \quad (2.28)$$

$$MM_2 = \frac{1}{n} \sum_{t=2}^{13} O_t \quad (2.29)$$

A série de médias móveis expurga o efeito sazonal e grande parte das variações aleatórias, mantendo tanto a tendência quanto o movimento cíclico (WANKE; JULIANELLI, 2006). O nome média móvel centrada ocorre por tratar-se de uma medida em que o período assumido por ela localiza-se no ponto médio do número de observações da série. Quando o número de observações for par, o ponto médio estará sempre entre dois dados. Para centrar a média, realiza-se a média das médias móveis correspondentes conforme equação (2.27) (SAMOHYL; SOUZA; MIRANDA, 2007).

Após a mensuração da tendência e do ciclo, os índices sazonais devem ser calculados. Estes são obtidos de forma indireta, retirando a tendência e o ciclo dos dados observados, restando a sazonalidade e os resíduos. O método aditivo obtém os dados a partir da subtração dos fatores (equação (2.30)); o método multiplicativo, a partir da divisão (equação (2.31)).

$$O - MMC = T + C + S + R - (T + C) = S + R \quad (2.30)$$

$$\frac{O}{MMC} = \frac{T \times C \times S \times R}{T \times C} = S \times R \quad (2.31)$$

Os resultados das equações acima são inúmeros fatores sazonais para cada período, adicionados dos resíduos (R). Os resíduos contribuem para que o fator sazonal de um período seja diferente do calculado n períodos atrás, em que n é a duração do padrão sazonal. De acordo com Wanke e Julianelli (2006), para contornar essa situação, calculam-se os índices sazonais (IS) através da média de todos os fatores sazonais (FS) obtidos para o período. Por exemplo, se a sazonalidade for mensal haverá doze índices sazonais.

$$IS_{janeiro} = \frac{\sum_{k=1}^n FS_{janeiro_k}}{n} \quad (2.32)$$

Na equação (2.32) n corresponde ao número de fatores sazonais para cada mês do ano (considerando sazonalidade anual). Conforme Wanke e Julianelli (2006), caso a série histórica seja longa o suficiente, podem-se calcular os índices sazonais a partir da média ajustada, ou seja, expurgando o maior e o menor fator sazonal em cada mês.

O cálculo dos índices pode ser feito em planilha Excel[®], uma das grandes vantagens do método. Além disso, embora a amostra deva ter tamanho considerável, no mínimo 50 observações, é feita para apenas uma variável, o que simplifica os cálculos (BARBOSA; WANKE, 2010).

Para realizar as previsões propriamente ditas, deve-se projetar individualmente cada componente da série e unificá-las de acordo com o método escolhido (aditivo ou multiplicativo), equações (2.25) e (2.26).

As projeções de tendência e da sazonalidade são realizadas conforme segue. A primeira provém da equação da curva que melhor se ajustou à série de médias móveis (MMC) conforme equação (2.27), e a segunda decorre dos valores calculados para os índices sazonais (IS) (equação (2.32)) (WANKE; JULIANELLI, 2006).

2.1.1.8 Método de Box-Jenkins

A metodologia Box-Jenkins recebe este nome pela pesquisa, aprimoramento e popularização do método pelos pesquisadores George Box e Gwilym Jenkins no início dos anos 70. De acordo com Mileski Júnior (2007) ela foi desenvolvida para séries que tem suas observações anotadas em intervalos de tempo iguais (modelos univariados). Dentre os métodos existentes, encontram-se os processos AR (auto-regressivo), MA (médias móveis), ARMA (auto-regressivo médias móveis), ARIMA (auto-regressivo médias móveis integrado), SARIMA (auto-regressivo médias móveis integrado sazonal) e outras variações.

Normalmente os valores de uma série são autocorrelacionados, ou seja, a variação de um valor impacta os vizinhos. Portanto, a autocorrelação é uma medida de dependência entre observações da mesma série separadas por um intervalo chamado retardo. Essa dependência produz um padrão de variabilidade que pode ser usado para prever valores futuros e ajudar na gestão de operações comerciais

(Hanke e Wichern, 2005). Os métodos de Box-Jenkins são modelos matemáticos que visam captar o comportamento da correlação seriada ou autocorrelação entre os valores da série temporal, e com base nesse comportamento realizar previsões futuras (WERNER, 2004). A mesma autora ressalta que o fundamento teórico do modelo de Box-Jenkins baseia-se na teoria geral de sistemas lineares que diz que a passagem de um ruído branco por um filtro linear de memória infinita gera um processo estacionário de segunda ordem (com média e variância constantes).

Observar se a série é estacionária trata-se do primeiro passo para aplicação da metodologia, isto é, verificar que não há tendência presente ou que ela já foi removida anteriormente. Caso não seja estacionária, é necessário tomar uma ou duas diferenças para que a série se torne estacionária. O número de diferenças (d) necessárias para tornar a série estacionária é denominado ordem de integração (WERNER, 2004).

Para realizar as previsões devem ser realizados os seguintes passos: o processo auto-regressivo (p), que representa a ordem de relacionamento com seus valores passados; o processo de integração ou diferenciação (d), que representa a ordem do processo integrado não-estacionário, ou seja, o número de “ d ” vezes que o processo deve ser submetido a diferenças para que se torne estacionário. E, por fim, o processo de média móvel (q), isto é, da ordem de defasagem dos erros, que representa o número de defasagens dos ruídos não autocorrelacionados que terá Y_t como função linear (SOUZA, 2005).

Os processos ARIMA e SARIMA aceitam séries temporais discretas não estacionárias, porém homogêneas e em equilíbrio estatístico. Entende-se por isso séries que não contenham grandes saltos, “degraus” ou “explosões” nos valores observados. ARIMA e SARIMA são os mais utilizados já que na prática, em geral, as séries são não estacionárias (WERNER, 2004).

Um modelo ARIMA (pdq) pode ser escrito pela equação (2.33), em que δ é um parâmetro intercepto relacionado com a média de Y_t , os θ são os parâmetros auto-regressivos desconhecidos, os α são constantes desconhecidas que descrevem a relação existente entre os ruídos e Y_t ; e_t são os resíduos aleatórios, não correlacionados, com média zero e variância constante (SOUZA, 2005).

$$Y_t = \delta + \theta_1 Y_{t-1} + \dots + \theta_p Y_{t-p} + e_t + \alpha_1 e_{t-1} + \dots + \alpha_q e_{t-q} \quad (2.33)$$

Para que o modelo seja estacionário é importante que a relação $|\alpha| < 1$ seja satisfeita e que as autocovariâncias (Y) sejam independentes. Um bom ajuste do modelo de Box-Jenkins requer a utilização de técnicas para que a estrutura residual seja um ruído branco, isto é, que os resíduos sejam variáveis aleatórias independentes e identicamente distribuídas. Em outras palavras, que o modelo seja tão bem ajustado que somente resta a aleatoriedade dos dados que não pode ser explicada matematicamente (MILESKI JÚNIOR, 2007).

Segundo Pellegrini (2000), necessita-se um mínimo de 50 observações para identificar satisfatoriamente o modelo que melhor descreve a série temporal. As principais ferramentas usadas no processo de identificação do modelo são a função de autocorrelação (FAC) e a função de autocorrelação parcial (FACP).

O método de Box-Jenkins possui a vantagem de escolher o modelo através do comportamento dos dados, o que o torna muito eficiente. O diagnóstico dos resíduos, que avalia qual modelo testado melhor se ajusta aos dados, também fornece os parâmetros estimados que apresentam o erro quadrático mínimo. Contudo, apesar de fornecer bons resultados, é uma ferramenta custosa que requer maior tempo e aptidão dos especialistas para a análise, além de uma grande quantidade de dados.

2.1.2 Métodos causais

Os métodos causais que utilizam dados históricos como variáveis dependentes e independentes procuram relações causais entre fatores que influenciam a demanda de um produto, tais como: campanhas promocionais, condições econômicas e ações de concorrentes. As relações entre o fator a ser previsto e outros fatores são expressas por funções matemáticas, tais como, a regressão linear ou outras regressões. A análise da série temporal se baseia em dados históricos da demanda, reconhecendo tendências e padrões sazonais, que, ao serem extrapolados, auxiliam a projetar o futuro (RITZMAN; KRAJEWSKI, 2004 *apud* ZAN; SELITO, 2007).

Métodos causais são usados quando dados históricos estão disponíveis e a relação entre o fator a ser previsto e outros fatores, externos ou internos (por exemplo, ações do governo ou promoções) podem ser identificados. A forma mais simples e mais amplamente utilizada de regressão envolve uma relação linear entre duas variáveis (regressão linear) (JÚDICE, 2005).

De acordo com Chase, Jacobs e Aquilano (2006) a regressão linear é muito útil para a previsão de longo prazo de eventos principais e

planejamento agregado (família de produtos). Ela pode ser usada tanto para previsão de séries temporais como para previsão de relações causais. Quando a variável dependente (geralmente o eixo vertical de um gráfico) muda como consequência do tempo (representado pelo eixo horizontal), trata-se de uma análise de séries temporais. Caso ela mude em virtude da alteração de outra variável, trata-se de uma relação causal.

As desvantagens dos métodos causais estão na grande quantidade de dados solicitados e na complexidade matemática que exigem a utilização de softwares especializados. A regressão linear simples é a única que difere dos padrões apresentados, sendo possível implementá-la em planilha Excel[®]. Contudo, Tabachnick e Fidell (2001) ressaltam que para gerar uma boa previsão, a amostra deve ser considerável, com no mínimo 50 observações.

O presente trabalho não utiliza os modelos causais para gerar previsões devido a escassez de dados na empresa foco do estudo de caso, apresentada no capítulo 5. Por este motivo, são demonstradas as formulações das previsões de forma simplificada. Os métodos apresentados são regressão linear e múltipla.

2.1.2.1 Regressão linear simples

O termo regressão pode ser definido como uma relação funcional entre duas ou mais variáveis correlacionadas, de forma que uma é usada para prever a outra. A regressão linear simples se refere à categoria especial de regressão que contém um único regressor e o vínculo entre as variáveis forma uma linha reta. A relação, em geral, é desenvolvida a partir de dados observados que assumem uma forma linear ou pelo menos parte deles são lineares (CHASE; JACOBS; AQUILANO, 2006). Para auxiliar na identificação desta linearidade, Wanke e Julianelli (2006) sugerem utilizar o diagrama de dispersão que fornece uma avaliação visual preliminar da relação entre a variável resposta e variável regressora.

Conforme Devore (2006) existe o modelo probabilístico e o determinístico de regressão linear. No determinístico, (equação (2.34)), o valor real observado de y (variável dependente) é uma função linear de x (variável independente). A generalização apropriada dessa característica para um modelo probabilístico (equação (2.35)) pressupõe que o valor esperado de y é uma função linear de x , mas que, para um x fixo, a variável y difere de seu valor esperado de uma quantidade aleatória ε .

$$y = b_0 + b_1x \quad (2.34)$$

$$y = b_0 + b_1x + \varepsilon \quad (2.35)$$

A variável ε normalmente é chamada de desvio aleatório ou erro aleatório do modelo, sendo considerada normalmente distribuída com média zero e variância igual ao desvio padrão ao quadrado (σ^2). Os coeficientes b_0 e b_1 correspondem, respectivamente, aos coeficientes linear e angular da reta. O coeficiente angular b_1 é a mudança esperada em y associada com um aumento de uma unidade no valor de x .

Uma forma de estimar os coeficientes b_0 e b_1 é através do método dos mínimos quadrados. A partir da equação (2.34) o método dos mínimos quadrados ajusta a linha aos dados de maneira a minimizar a soma dos quadrados da distância vertical ($y_1 - Y_1, y_2 - Y_2, \dots, y_n - Y_n$) entre cada ponto de dados (y_1, y_2, \dots, y_n) e seu ponto correspondente na linha (Y_1, Y_2, \dots, Y_n).

$$(y_1 - Y_1)^2 + (y_2 - Y_2)^2 + \dots + (y_n - Y_n)^2 \quad (2.36)$$

Minimizando a equação (2.36) encontram-se as equações que definem os valores de b_0 e b_1 :

$$b_0 = \bar{y} + b_1 \bar{x} \quad (2.37)$$

$$b_1 = \frac{\sum xy - n\bar{x}\bar{y}}{\sum x^2 - n\bar{x}^2} \quad (2.38)$$

Em que x são os valores da variável em cada ponto de dados, sendo \bar{x} a média dos seus valores; de maneira semelhante y é o valor da variável em cada ponto de dados e \bar{y} é a média de todos os valores de y ; n é o número de observações.

Análises de regressão também geram medidas de acurácia da previsão, que indicam a qualidade da regressão. As três medidas mais comumente utilizadas são o coeficiente de correlação, o coeficiente de determinação e o erro padrão da estimativa (JÚDICE, 2005).

O coeficiente de correlação r mostra a relação entre as variáveis dependentes e independentes. Valores positivos indicam variação no mesmo sentido das variáveis. Valores negativos indicam variáveis inversamente relacionadas. Um valor nulo significa que não existe

relação. Quanto mais próximo r estiver de $\pm 1,00$, maior a correlação (ZAN; SELITO, 2007). O coeficiente de determinação (r^2) é interpretado como a proporção da variação de y observada que pode ser explicada pelo modelo de regressão linear simples e varia de zero a um. Quanto mais alto o valor de r^2 , mais o modelo consegue explicar a variação de y . O erro padrão da estimativa s_{yx} , mede a proximidade dos valores da variável dependente, ao redor da linha de regressão como mostra a equação (2.39) (CHASE; JACOBS; AQUILANO, 2006).

$$s_{yx} = \sqrt{\frac{\sum_{i=1}^n (y_i - Y_i)^2}{n - 2}} \quad (2.39)$$

2.1.2.2 Regressão linear múltipla

A regressão múltipla é útil nas situações em que há uma variável y para ser prevista, diversas variáveis explanatórias (x_1, x_2, \dots, x_n), e o objetivo é encontrar uma função que relacione y com as demais variáveis (LEMOS, 2006).

O modelo de regressão linear múltipla é particularmente útil quando o processo de mensuração da variável de interesse (y) é caro, demorado, trabalhoso etc., e é possível identificar um elenco de variáveis x_1, \dots, x_n cuja mensuração é bem mais simples, e que, por estarem muito relacionadas com y , podem ser usadas para que y seja medido de forma indireta (WANKE; JULIANELLI, 2006).

O método da regressão múltipla parte da hipótese da formulação do relacionamento entre uma variável dependente com diferentes variáveis independentes. A partir desta hipótese, necessita-se obter dados para cada variável independente, preferencialmente na forma de séries temporais. Para o desenvolvimento do modelo de regressão, inicialmente relaciona-se uma lista de variáveis que influenciam y , baseada: (i) na experiência de especialistas, (ii) na disponibilidade dos dados e (iii) em restrições de tempo e custo. Esta lista deve ser filtrada usando procedimentos formais como regressões de subconjuntos de variáveis, análise de componentes principais de todas as variáveis (incluindo y) para decidir quais são as variáveis importantes e se obter a lista final de variáveis explanatórias (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998).

Vale destacar que dentre as variáveis explicativas escolhidas, é necessário que elas sejam independentes (pouco relacionadas) para que

o modelo obtenha bons resultados. Conforme Wanke e Julianelli (2006) o grande perigo entre os regressores é a instabilidade que esta relação provoca na matriz utilizada no cálculo dos estimadores de mínimos quadrados dos parâmetros do modelo. A equação (2.40) representa o modelo de regressão linear para múltiplas variáveis:

$$y = b_0 + b_1x_1 + b_2x_2 + \dots + b_nx_n + \varepsilon \quad (2.40)$$

Em que y é a variável resposta, x_1 a x_n são as variáveis preditoras, b_0 a b_n são os coeficientes de regressão; e ε é um erro aleatório. O valor do coeficiente b_1 representa a variação esperada na resposta y resultante do acréscimo de uma unidade no regressor x_1 , quando todos os regressores restantes (x_2 a x_n) são considerados constantes (WANKE; JULIANELLI, 2006). Os parâmetros b (b_0 a b_n) podem ser estimados aplicando o método dos mínimos quadrados ordinários, que busca encontrar os coeficientes que minimizem a soma dos quadrados dos erros (LEMOS, 2006).

Para obter uma previsão com o modelo de regressão múltipla um conjunto de valores futuros das variáveis explanatórias deve ser determinado (\hat{X}_n). Estes valores são utilizados na equação de regressão e um valor \hat{Y}_0 é obtido pela equação (2.41). Esta considera que as variáveis explanatórias são medidas sem erros. Quando previsões de Y são feitas, elas dependem dos valores futuros de variáveis explanatórias, ($\hat{X}_1, \hat{X}_2, \dots, \hat{X}_n$), sendo importante obter previsões precisas destas variáveis (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998)

$$\hat{y} = b_0 + b_1 \hat{x}_1 + b_2 \hat{x}_2 + \dots + b_n \hat{x}_n \quad (2.41)$$

Após encontrar o valor dos coeficientes pelo método de mínimos quadrados, deve-se verificar se a equação ajusta bem os dados, se o modelo sugerido pode ser usado como preditor, se as hipóteses iniciais estão sendo respeitadas (p. ex. o princípio da normalidade, variância constante e erros não correlacionados). Todas esses aspectos devem ser investigados antes do modelo ser adotado para o uso. Maiores detalhes sobre a validação do método podem ser encontrados em Wanke e Julianelli (2006).

2.1.3 Redes neurais

Uma rede neural artificial imita a estrutura do cérebro humano. É composta de uma série de nós interligados, numa alusão à organização dos neurônios no cérebro. Representa o conhecimento armazenado e o raciocínio para processar as informações. Cada neurônio recebe um sinal de entrada, processa-o através de equações matemáticas e transmite o resultado ao próximo neurônio até que se obtenha uma saída desejada (DIAS, 2004). As redes neurais estão dispostas em unidades de processamento (ou neurônios artificiais), as quais se interconectam umas com as outras, formando redes capazes de armazenar e transmitir informações provenientes do meio externo (PELLEGRINI, 2000).

O objetivo das redes neurais é reconhecer regularidades e padrões nos dados apresentados com o intuito de entender o comportamento complexo de sistemas. Segundo Allemão (2004), as redes neurais são aplicadas, em sua maioria, nos problemas envolvendo *clusterização*, previsão e reconhecimento.

De um modo geral, cada neurônio artificial recebe um conjunto de entradas ou sinais x_i , calcula uma média ponderada entre eles, n_k , e utiliza alguma função, $f(n_k)$, que determinará sua ativação ou não, para produzir uma saída, y_k , que será a entrada para os outros neurônios. A saída final realimenta a rede calculando o erro que vai atualizar os valores de pesos e funções e, assim, treinar a rede (OLIVA; CYBIS; PRETTO, 2001 *apud* ALLEMÃO, 2004).

Em redes do tipo *feedforward* (ver Allemão, 2004), a mais utilizada atualmente, os neurônios estão altamente interconectados e dispostos em camadas, usualmente duas camadas ativas, e somente a camada de entrada não realiza qualquer processamento sobre os dados (ALLEMÃO, 2004). Quanto maior for o número de neurônios na rede, maior será seu processo de aprendizagem e, conseqüentemente, melhor será seu desempenho.

Para Mileski Júnior (2007), a resolução de problemas utilizando redes neurais necessita de pares de dados de entrada-saída já conhecidos. Mesmo nos casos em que a quantidade de pares disponíveis não é muito grande, deve-se separar esses dados em um conjunto de treinamento e outro de teste. O treinamento da rede é realizado utilizando o conjunto de treinamento e a medição do desempenho usando os pares de entrada-saída do conjunto de teste.

De acordo com Pellegrini (2000), a propriedade mais importante das redes neurais é a sua capacidade de “aprender”, ou seja, reconhecer padrões e regularidades nos dados. Uma vez feito o aprendizado, a rede

está apta a melhorar seu desempenho e, então, extrapolar quanto a um comportamento futuro.

2.2 MODELOS QUALITATIVOS DE PREVISÃO DE DEMANDA

Os métodos qualitativos são, essencialmente, subjetivos ou arbitrários e baseiam-se em estimativas e opiniões. São ideais para situações em que não há séries históricas disponíveis para a formulação matemática e/ou o julgamento humano é necessário. Contudo, devem ser realizadas através de um processo estruturado a fim de obter resultados satisfatórios.

Devido a sua natureza subjetiva, os métodos qualitativos são usados para formulação de estratégias, desenvolvimento de novos produtos e tecnologias com taxa de penetração e aceitação de mercado incertas e desenvolvimento de planos de longo prazo (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998).

Os procedimentos formais para obtenção de previsões desta forma variam desde a consolidação de estimativas de vendas pessoais ao uso de métodos tipo Delphi para obter um consenso de opinião de um painel de responsáveis pela previsão (CAVALHEIRO, 2003). Para elaborar as previsões, diversos tipos de informações podem ser utilizados, como testes de marketing, pesquisa com consumidores, estimativas da força de vendas e dados históricos.

Contudo, apesar dos diversos processos estruturados para realizar a previsão, as estimativas dos especialistas são baseadas no julgamento, intuição, técnicas comparativas, conhecimento técnico, conhecimento sobre análise de dados e procedimentos de previsão e/ou no conhecimento de relações de causa e efeito entre variáveis adquirido com a experiência em processos preditivos nas organizações (BALLOU, 2001).

2.2.1 Métodos de previsão puramente qualitativos

Opinião da Força de Vendas

A empresa reúne informações da sua força de vendas para realizar suas projeções. A suposição, nesse caso, é que a pessoa mais próxima do cliente/mercado conhece bem suas necessidades futuras. As previsões de cada vendedor são agrupadas para formar as estimativas totais da empresa. Contudo, estas informações podem estar condicionadas aos interesses pessoais dos vendedores e a visão de curto prazo sempre presente na atividade da venda. Esta técnica tem maior utilidade nos casos em que a venda é seqüencial ou repetida para os mesmos clientes (LIN, 2000).

Consenso de painel

Intercâmbio de ideias em reuniões com a crença de que a discussão realizada em grupo produz previsões melhores do que individualmente. Os participantes podem ser executivos, vendedores ou clientes. As previsões são desenvolvidas por meio de reuniões abertas com a troca livre de idéias de todos os níveis de gerenciamento e posições. A dificuldade encontrada nesse estilo mais informal é que os funcionários de níveis hierárquicos mais baixos se sentem intimidados pelos que ocupam cargos de alta gerência. O método Delphi foi desenvolvido para tentar corrigir esta questão. Uma variação deste método chama-se júri de executivos, sendo este utilizado para lançar novos produtos e traçar diretrizes estratégicas sendo restrita a alta gerência (CHASE; JACOBS; AQUILANO, 2006).

Júri de executivos

Tem-se que o grupo de executivos da empresa, pela sua experiência, qualificação e relacionamento, pode fornecer uma visão sobre o “estado de consumo” dos segmentos que interessam à empresa. Segundo Lin (2000), através do júri de opiniões de executivos ou julgamento dos gerentes de produto, as opiniões individuais de cada executivo-chefe ou gerente são avaliadas e discutidas em grupo até se chegar a um consenso comum. Na maioria das vezes este conhecimento é intuitivo, sem comprovação científica, mas de suma importância.

Este método é simples e usado com frequência, mas pode induzir a erros, decorrentes da subjetividade da análise. As previsões podem estar contaminadas por desejos e interesses pessoais ou por conflitos com outras áreas.

Método Delphi

O método Delphi possui a premissa básica de que o julgamento coletivo, quando organizado adequadamente, apresenta melhores resultados que a opinião de um só indivíduo (WANKE, JULIANELLI, 2006). Em linhas gerais, a técnica Delphi consiste em estruturar o uso do conhecimento e da experiência dos especialistas de forma que o resultado seja um consenso confiável da opinião da maioria das pessoas.

O procedimento pode ser descrito da seguinte forma: um grupo de especialistas responde a um questionário. Um moderador reúne os resultados e realiza análises estatísticas das respostas e uma compilação das justificativas descritas. Formula-se um novo questionário que apresenta os resultados dessa análise e esse é novamente encaminhado ao grupo. Assim, há um processo de aprendizagem entre os membros à medida que eles recebem novas informações e não há influência da pressão do grupo ou de indivíduos com perfil mais dominante. O

processo de aplicação de novas rodadas ocorre até que a coordenação do estudo verifique uma convergência satisfatória das respostas. A técnica Delphi geralmente consegue alcançar bons resultados em três rodadas. O tempo necessário depende do número de participantes, da quantidade de trabalho necessário para que desenvolvam as suas previsões e de sua agilidade para oferecer as respostas (CHASE; JACOBS; AQUILANO, 2006; WANKE; JULIANELLI, 2006).

Rowe e Wright (1999) *apud* Souza (2008) destacam a necessidade de quatro características para que o procedimento possa ser definido como Delphi: (a) o anonimato; (b) as repetidas interações, que se resume a todos terem acesso pelo menos às opiniões divergentes e às mais mencionadas; (c) o *feedback* controlado, que nada mais é do que o fornecimento de um retorno apenas com questões pertinentes aos objetivos da pesquisa, para possíveis refinamentos nas opiniões do grupo e (d) a agregação estatística às respostas do grupo.

Contraditoriamente, um dos principais pontos fortes e vantagens da técnica Delphi, como a utilização do anonimato e do *feedback*, que levam à melhoria da precisão, podem se converter em desvantagens, caso induza a priorização de interesses pessoais em detrimento de um esforço espontâneo no sentido do consenso. Ou ainda, se a participação dos menos experientes, eficientes e confiáveis for capaz de influenciar os mais preparados devido a forma como o *feedback* estiver sendo construído (SOUZA, 2008).

Pelos motivos apresentados, fica claro que a habilidade para se obter a cooperação irrestrita e imparcial de todos os participantes é tão crucial quanto a competência técnica da equipe coordenadora para alcançar o sucesso do método.

Analogia histórica

Este método normalmente é utilizado no planejamento de novos produtos, visto que conecta o que está sendo previsto a um item semelhante. Desta forma, a previsão é gerada utilizando o histórico de um produto semelhante como produtos suplementares, substituíveis ou concorrentes (CHASE; JACOBS; AQUILANO, 2006).

Pesquisa de Mercado

A pesquisa de mercado e a análise do comportamento de consumidores são técnicas sofisticadas e valiosas para se prever a demanda do mercado. Levam em conta os resultados de pesquisas realizadas por órgãos ou empresas especializadas ou mesmo por meios de pesquisas conduzidas pela própria empresa. De forma geral, envolvem o uso de questionários e testes de novos produtos e serviços (DIAS, 2004).

O método reúne diversos tipos de dados (pesquisas, entrevistas, etc.) para testar hipóteses sobre o comportamento de clientes. Analisam-se padrões que podem descrever as preferências dos consumidores e a probabilidade de eles comprarem um produto/serviço, servindo de informação relevante para a previsão de demanda e tomada de decisão (LEMOS, 2006).

Contudo, de acordo com Lin (2000), uma dificuldade do método é a obtenção de informações conclusivas acerca das intenções de compra. Outra desvantagem está no fato de que, em economias instáveis, fica difícil qualquer previsão futura, mesmo para bens industriais como máquinas e equipamentos. Segundo Armstrong (1985) *apud* Lemos (2006), o horizonte de previsão também influencia na qualidade do resultado da aplicação do método, pois para médio e longo prazo pode haver mudanças na intenção de consumo dos respondentes, enquanto que no curto prazo estas mudanças são menos prováveis.

Análise de Cenários

É uma representação de como o presente irá evoluir para o futuro, identificando um conjunto de possíveis ocorrências. A partir dos cenários construídos para simular a situação futura, planos de ação são desenvolvidos e colocados em prática de acordo com o que realmente acontece (DIAS, 2004).

A técnica de elaboração de cenários para previsão de vendas pode variar de análises subjetivas das variáveis até modelos dinâmicos complexos. Em linhas gerais, o modelo identifica as variáveis que podem impactar as vendas futuras, quantifica este impacto e, posteriormente, elabora projeções. A análise de cenários é utilizada, sobretudo, no planejamento de longo prazo, que irá impactar as decisões estratégicas da empresa (WANKE; JULIANELLI, 2006).

2.3 ERROS DE PREVISÃO

A previsão, após ser determinada, deve ser monitorada para garantir seu bom funcionamento. Os fatores usados para monitorar e controlar as previsões são ao mesmo tempo usados pelos gerentes como indicadores na hora de decidir o melhor método de previsão a ser adotado (JÚDICE, 2005).

Para o gestor de uma empresa conhecer o quão eficaz é sua previsão de demanda, existe a necessidade de indicadores que mensurem o seu desempenho. A acuracidade da previsão é obtida através dos erros de previsão. Segundo Wanke e Julianelli (2006), existem diversas medidas de acuracidade, entretanto, todas descrevem a

diferença entre os valores reais e os valores previstos, conhecida como erro ou resíduo.

Segundo Cavalheiro (2003) a palavra acurácia refere-se ao “melhor ajuste”, o qual representa quão bem o modelo de previsão é capaz de reproduzir os dados que já são conhecidos.

Para Júdice (2005) este monitoramento pode ser feito comparando-se os erros de previsão com valores predeterminados ou limites de ação. Os erros que estiverem dentro dos limites pré-estabelecidos são considerados aceitáveis, contudo, os que situarem-se fora do padrão indicam que uma ação corretiva deve ser empregada.

As medidas de erros são bastante úteis no sentido de melhoria continuada do processo de previsão, tendo em vista que as discrepâncias estarão sempre presentes e a identificação e correção desta imprecisão pode melhorar os resultados (SAMOHYL; SOUZA; MIRANDA, 2007).

A escolha de uma medida de erro varia de acordo com a situação de uso (seleção de métodos ou calibração de um dado modelo) e do número de séries temporais analisadas. A utilização de diferentes medidas de acurácia é uma alternativa para compensar os defeitos das diferentes medidas (ARMSTRONG; COLLOPY, 1992 *apud* LEMOS 2006).

A próxima seção detalhará os principais métodos de mensuração de erro.

2.3.1 Medidas de Erros

O erro de previsão consiste na diferença entre o valor previsto, (P_t), e o valor observado (O_t) ou demanda atual. Matematicamente, o erro, ou discrepância, no período de tempo t pode ser expresso conforme equação (2.42):

$$Erro = P_t - O_t \quad (2.42)$$

De acordo com a equação (2.42), P_t representa a previsão no período t e O_t o valor observado no mesmo período. Um erro positivo indica que a previsão está acima do real, assim como um valor negativo mostra que está abaixo. A partir da mensuração do erro para n períodos de tempo, têm-se várias maneiras de calcular o erro total, ou seja, a acurácia da previsão.

Erro médio (*Mean Error* - ME)

Uma medida de acurácia que pode ser calculada é o erro médio de previsão, na qual se adicionam os valores dos erros para os n períodos de tempo e calcula-se a média segundo (2.43):

$$ME = \frac{1}{n} \sum_{t=1}^n (P_t - O_t) \quad (2.43)$$

Como os erros possuem valores positivos e negativos que se cancelam, o resultado obtido é próximo de zero. Por este motivo esta medida não é muito útil para avaliar diferentes métodos. Em contrapartida, a mensuração do erro médio traz informações sobre possíveis vieses, ou seja, tendências das previsões para mais ou para menos.

Segundo Devore (2006) a média demonstra a localização (centro) de uma amostra, porém, tem a deficiência de ser influenciada por *outliers* (observações incomuns; muito grandes ou pequenas).

Erro médio absoluto (*Mean Absolut Deviation* – MAD)

Esta medida é simplesmente a média dos erros absolutos. Ela é freqüentemente preferida ao erro médio, visto que trata o erro como uma distância entre o previsto e o observado. A equação do erro é dada por:

$$MAD = \frac{1}{n} \sum_{t=1}^n |P_t - O_t| \quad (2.44)$$

O erro médio absoluto é uma medida da qualidade da previsão apropriada para analisar as previsões de um único produto (SAMOHYL; SOUZA; MIRANDA, 2007).

Erro médio quadrado (*Mean Squared Error* – MSE)

Esta medida segue a mesma lógica do MAD ao neutralizar o efeito de erros positivos e negativos se anularem. Contudo, ao invés de trabalhar com as discrepâncias em valores absolutos, aplica-se o quadrado dos erros, conforme a equação (2.45):

$$MSE = \frac{1}{n} \sum_{t=1}^n (P_t - O_t)^2 \quad (2.45)$$

O erro médio quadrado é uma medida que penaliza a previsão muito mais para os desvios extremos do que para pequenos desvios. Desta forma, adotar o critério de minimizar o *MSE* implica em se obter vários pequenos desvios do valor de previsão ao invés de um grande desvio (CAVALHEIRO, 2003).

Erro percentual absoluto médio (*Mean Absolut Percentage Error – MAPE*)

O erro percentual absoluto médio segue a linha dos critérios que neutralizam o sinal dos valores individuais. Nas engenharias e administração, este é o critério mais utilizado pela facilidade de interpretação do erro em valores percentuais. Além disso, a medida pode ser empregada para a comparação de métodos de previsão, visto que não depende da unidade dos dados (controle de escala) (SAMOHYL; SOUZA; MIRANDA, 2007). A equação (2.46) demonstra o seu cálculo:

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{P_t - O_t}{O_t} \right| \quad \text{para } O_t \neq 0 \quad (2.46)$$

Contudo, como pode ser observado na equação (2.46), o ponto fraco da medida ocorre quando a série temporal contém valores iguais a zero, provocando o crescimento do erro ao infinito. Portanto, nos casos de demanda intermitente outras medidas de acuracidade devem ser utilizadas.

U de Theil

O U de Theil é também comumente chamado de coeficiente de desigualdade, pois trata-se de uma medida relativa, em que se tem ideia, em termos percentuais, das discrepâncias cometidas um passo a frente. Espera-se que esta medida varie de zero a um, sendo este o universo de oscilação para as técnicas consideradas aceitáveis (SAMOHYL; SOUZA; MIRANDA, 2007). O cálculo desta medida de erro pode ser visualizado na equação a seguir:

$$U = \sqrt{\frac{\sum_{t=1}^{n-1} \left\{ \left(\frac{P_{t+1} - O_t}{O_t} \right) - \left(\frac{O_{t+1} - O_t}{O_t} \right) \right\}^2}{\sum_{t=1}^{n-1} \left(\frac{O_{t+1} - O_t}{O_t} \right)^2}} \quad \text{para } O_t \neq 0 \quad (2.47)$$

Analisando a equação (2.47), verifica-se que, na melhor situação possível, quando a previsão iguala-se ao valor observado ($P_{t+1} = O_{t+1}$), o numerador fica nulo. Isto indica que o U de Theil igual a zero é a melhor situação possível. No caso da previsão ingênua, o valor previsto P_{t+1} é igual ao observado no período anterior (O_t). Isto elimina a primeira razão do numerador e resulta em U de Theil igual a um. A partir dessas observações, conclui-se que a medida U de Theil deve ser menor do que um para que o método de previsão em análise seja mais eficiente que a previsão ingênua.

2.4 CONSIDERAÇÕES FINAIS

Este capítulo apresentou os métodos de previsão quantitativos e qualitativos com as respectivas mensurações de erro. Contudo, diferentes métodos de previsão podem utilizar informações de base de dados distintas. Nestes casos, ao invés de escolher um único método de previsão deve-se ponderar a agregação de modelos a fim de abranger o maior número de variáveis e conseqüentemente obter ganhos de acuracidade.

O próximo capítulo abordará este assunto demonstrando formas de integração de previsões quantitativas e qualitativas. A integração de previsões une dados quantitativos e julgamentos de especialistas de diversas formas. Serão apresentados nove métodos de integração de previsões, além de descrever as principais ineficiências associadas ao julgamento de especialistas e formas de contornar os problemas através da estruturação do julgamento.

3 INTEGRAÇÃO DE MÉTODOS QUANTITATIVOS E QUALITATIVOS

O estabelecimento de um processo preditivo em uma organização possui inúmeras etapas. Segundo Bunn e Wright (1991), a formulação de uma previsão estatística necessita de diversas entradas provenientes de julgamentos. Algumas tarefas intrínsecas à atividade de previsão são a definição das variáveis de interesse, a avaliação da série temporal para ajuste de eventualidades encontradas, a seleção dos tipos de métodos de previsão que serão avaliados e o grau de acurácia desejada para alcançar os objetivos da empresa. Olhando por este prisma, pode-se concluir que todos os processos de previsão envolvem algum tipo de julgamento humano (GOODWIN, 2002), podendo ser mais ou menos utilizado dependendo dos recursos disponíveis na empresa e da sua necessidade.

Portanto, verifica-se que a atividade de previsão é uma função crítica da gerência que não se resume apenas a um exercício de seleção de uma técnica ou de um software de apoio, mas sim ao planejamento de um processo em que é necessário levar em conta o ambiente externo com todas as suas ameaças, oportunidades e desafios (MOON et al., 2003).

Os julgamentos podem predominar em muitas organizações por falta de pessoal qualificado que elabore as previsões estatísticas. Contudo, mesmo quando há uma equipe disponível, alguns fatores comportamentais favorecem o julgamento. Segundo Webby e O'Connor (1996), os gerentes optam pelo julgamento por temerem ou não entenderem os métodos estatísticos, ou talvez por acreditarem que estes métodos não trazem domínio do conhecimento suficientemente importante para produzir a previsão.

Pesquisas em métodos de previsão de negócios e governos têm mostrado repetidamente que o papel do julgamento normalmente vai muito além do que a sua aplicação direta na quantidade a ser prevista. Na maioria das organizações, as previsões são inteiramente baseadas em julgamento ou então ajustes utilizando julgamento de especialistas são aplicados à saída de métodos estatísticos (GOODWIN, 2002).

Samohyl, Souza e Miranda (2007) confirmam que os julgamentos são largamente utilizados. Os autores afirmam que poucas empresas utilizam métodos matemáticos de previsão, pois consideram que o ambiente competitivo seja tão complicado e instável que nenhuma metodologia aplicada para elaborar previsões será melhor que as suposições intuitivas dos especialistas mais experientes.

Uma pesquisa recente realizada por Fildes e Goodwin (2007) com 144 executivos demonstrou que as previsões realizadas nas empresas utilizam base estatística em 75% dos casos. Contudo, somente 25% das previsões são exclusivamente quantitativas, o que significa que o julgamento também é utilizado em 75% das situações. A maioria das previsões, portanto, origina-se da associação de previsão estatística e julgamento, através da combinação entre previsões (16%) ou pelo ajuste de previsões quantitativas (34%).

Enquanto o julgamento sempre teve um importante papel nas previsões das empresas, na década de 80 as opiniões da comunidade científica eram divididas a respeito da função do julgamento, alguns até mesmo sugerindo que ele não era confiável (MAKRIDAKIS, 1988 *apud* WEBBY; O'CONNOR, 1996). Contudo, este conceito passou por profundas transformações e atualmente há uma aceitação de sua função e um desejo de aprender como unir julgamento com métodos estatísticos para alcançar previsões mais acuradas (LAWRENCE et al., 2006).

Várias premissas foram constatadas sobre o uso do julgamento através de comprovações empíricas e simuladas. Padrões consistentes e componentes estruturados da previsão parecem ser mais bem capturados 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, 2001). Análises subjetivas devem ser integradas ao processo preditivo quando é importante evitar grandes erros nas previsões e em situações dinâmicas, em que os métodos quantitativos não conseguem agregar aos modelos matemáticos mudanças internas e externas ao ambiente organizacional. Citam-se como exemplos, situações novas para a empresa, sistemas com dados heterogêneos, previsões de longo prazo e situações em que há dúvida sobre qual método é mais preciso (ARMSTRONG, 2001).

Pode-se concluir desta análise que cada abordagem de previsão (quantitativa e qualitativa) possui pontos fortes e fracos. Sanders e Ritzman (2001) comentam que as previsões provenientes de julgamento são adaptáveis a mudanças no ambiente pelo fato dos especialistas possuírem conhecimento atualizado, mas podem conter inconsistências e tendências. Já os métodos quantitativos são objetivos e sempre produzem a mesma previsão para os mesmos dados e podem trabalhar com um grande volume de dados. Por outro lado, não conseguem se adaptar a mudanças dinâmicas e estruturais nos dados das séries temporais, além do desempenho do modelo estar vinculado à qualidade dos dados obtidos.

Além disso, dados históricos normalmente contêm os efeitos de eventos incomuns, como greves, que precisam ser retirados antes dos métodos estatísticos serem aplicados. Isto pode ser um processo difícil nos casos em que um grande número de previsões precisam ser realizadas. Adicionalmente, os métodos estatísticos têm dificuldades de considerar eventos especiais que acontecerão no futuro, apesar dos pacotes computacionais mais avançados possuírem melhorias nesta área (GOODWIN, 2002).

A partir da constatação de que as previsões quantitativas e qualitativas analisam diferentes informações e que ambas contribuem para o aumento da acuracidade, torna-se interessante a união das características positivas de cada método. As vantagens declaradas tanto dos métodos de previsão estatísticos quanto dos de previsão por julgamento tem conduzido para a integração das metodologias na tentativa de aperfeiçoar as previsões (VONDOURIS et al., 2008).

Para Makridakis e Winkler (1983) *apud* Werner (2004), previsões geradas por 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. Webby e 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.

A integração de métodos baseia-se em duas decisões (MACKAY; METCALFE, 2002): (i) a escolha dos métodos de previsão que serão integrados (métodos quantitativos, qualitativos ou ambos); e (ii) a seleção do método de integração (integração subjetiva ou matemática).

Diversos estudos apresentam evidências de que a integração, de métodos qualitativos e quantitativos em especial, é a melhor abordagem para a obtenção de previsões mais acuradas (ARMSTRONG, COLLOPY, 1998; GOODWIN, 2002; WERNER, 2004; LEMOS, 2006) pela incorporação do conhecimento contextual nos processos matemáticos de previsão (WRIGHT; LAWRENCE; COLLOPY, 1996).

A vantagem da integração de métodos quantitativos com qualitativos é a incorporação do domínio de conhecimento (conhecimento sobre a natureza e comportamento das variáveis de interesse) no processo preditivo, aliado às informações contextuais. Especialistas com domínio de conhecimento entendem quais informações são importantes para o processo preditivo. A informação contextual pode ser obtida de séries temporais, de fontes de informações

públicas e/ou de fontes internas da organização (WEBBY; O'CONNOR, 2001)

Entretanto, o julgamento humano é facilmente influenciável. Um aumento substancial nas vendas pode ser visto como um indicativo de um período de crescimento, que pode não se confirmar. Um viés se caracteriza quando os especialistas realizam julgamentos influenciados por algum motivo particular (meta pessoal, motivação) ou por uma pressão externa (do chefe ou empresa) de alcançar determinados resultados. Além dos numerosos vieses, as pessoas têm uma capacidade de processamento limitada e por estes motivos é necessário satisfazer duas condições para realizar a integração de julgamentos com previsões estatísticas conforme Armstrong e Collopy (1998):

- A empresa deve estar habilitada para produzir previsões estatísticas, o que significa que devem estar disponíveis dados quantitativos que possuam relevância para o futuro;
- Os julgamentos devem incorporar informações que não são capturadas pela previsão estatística, como o conhecimento de alterações substanciais no preço de um item ou a decisão de retirar determinado produto do mercado.

Conclui-se que a chamada “cultura do ajuste” que é vigente no meio empresarial não se trata necessariamente de um problema, na medida em que cria a possibilidade para melhorias e aperfeiçoamentos do processo. Porém, traz consigo a necessidade de uma análise posterior de suas discrepâncias, pois pode-se piorar os resultados em termos de precisão ao se utilizar o ajuste por julgamento sem critérios e estrutura prévia, mesmo quando ele não está sendo utilizado para composição de metas (SAMOHYL, 2006).

Considerando que as condições colocadas por Armstrong, Collopy (1998) e Samohyl (2006) são satisfeitas, a empresa deve se preocupar em estruturar o processo de integração das previsões para evitar interpretações equivocadas dos dados estatísticos e a introdução de tendências pelos previsores. Existe uma variedade de procedimentos que podem ser usados para estruturar julgamentos e os principais métodos serão abordados neste capítulo, com ênfase na integração de julgamentos e previsões estatísticas de séries temporais.

3.1 MÉTODOS DE INTEGRAÇÃO DE PREVISÕES

Boas previsões requerem uma implementação efetiva de sistemas de previsão e, além disso, que o julgamento seja gerenciado (LAWRENCE et al., 2006).

Conforme apresentado na introdução do capítulo, os julgamentos têm um importante papel porque os especialistas da área normalmente tem conhecimento de eventos recentes em que seus efeitos ainda não foram observados na série temporal, de eventos que ocorreram no passado, mas não são esperados no futuro, ou então eventos que não ocorreram no passado, mas são esperados no futuro (ARMSTRONG; COLLOPY, 1998).

Portanto, se estes eventos atuais estão disponíveis aos previsores e ainda não estão incorporados aos dados históricos, estas informações devem ser usadas, integrando na previsão métodos estatísticos e julgamentos.

Webby e O'Connor (2001) definem três situações nas quais o julgamento deve ser utilizado: a) quando existe uma grande quantidade de informações relevantes; b) quando se supõe que os previsores possuem estas informações; c) quando os especialistas não possuem valores predeterminados de previsão (vieses).

Os métodos de integração de previsões quantitativas com julgamentos são categorizados na literatura de acordo com a natureza dos dados e do tipo de previsão obtida. Em relação aos dados, eles podem ser classificados como séries temporais, informações causais e informações cruzadas (do inglês "*cross-sectional data*"). As previsões podem ser do tipo: previsão pontual, previsão probabilística ou previsão de intervalos.

A previsão pontual consiste em prever um período à frente para os dados apresentados ao especialista. Esta é a abordagem mais utilizada na literatura para a confecção de previsões no meio empresarial. Lawrence et al. (2006) afirma que especialmente em áreas como economia e finanças, os usuários das previsões podem demandar informações sobre as incertezas que cercam as predições dadas pelos especialistas. A previsão probabilística e a previsão de intervalos são dois formatos que podem explicar estas incertezas, não permitindo, assim, falsas suposições.

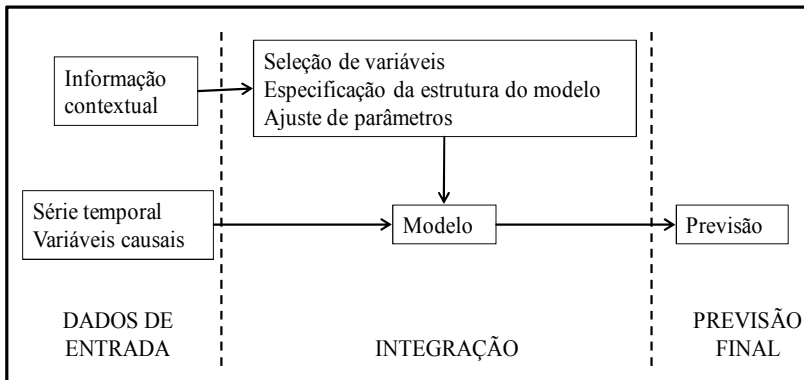
A previsão probabilística oferece um novo formato em que probabilidades subjetivas fornecem meios de comunicação para facilitar a compreensão dos usuários sobre as incertezas que cercam as previsões apresentadas. Faz-se isso permitindo que o fornecedor da previsão dê uma descrição do seu julgamento de maneira mais completa. Já a previsão de intervalos consiste na previsão de fronteiras que especificam os limites superiores e inferiores dentro dos quais é esperado que o valor futuro da variável predita esteja localizado com base em uma probabilidade especificada. Este método é mais utilizado em previsões

do tempo, previsões econômicas e financeiras (LAWRENCE et al., 2006).

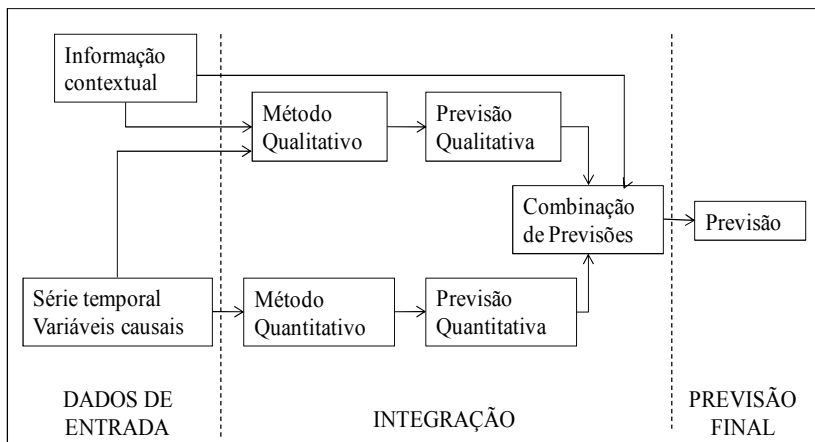
Neste trabalho será dada ênfase à realização de previsões pontuais integrando métodos estatísticos com julgamentos, que utilizam dados de séries temporais e informações causais. De forma geral, Armstrong e Collopy (1998) apresentam três caminhos nos quais o julgamento pode ser incorporado à previsão de séries temporais:

- 1) O julgamento pode informar quais dados são relevantes para a tarefa de previsão;
- 2) O julgamento pode influenciar sobre o método estatístico de previsão a utilizar;
- 3) O julgamento pode ser incorporado diretamente na previsão.

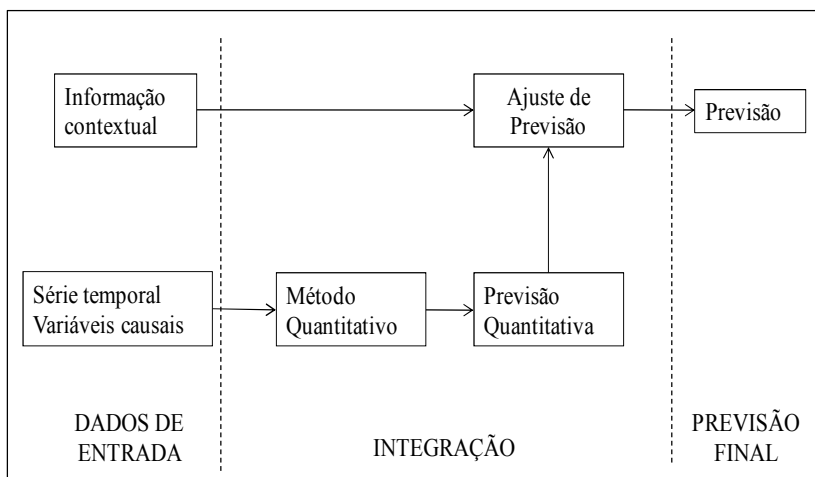
Destas associações de dados e julgamentos surgem inúmeras formas de integrar previsões. Os métodos de integração apresentados nesta seção serão explanados detalhadamente no decorrer do capítulo. Webby e O'Connor (1996) demonstram quatro maneiras para integrar previsões conforme a figura 3-1 (a, b, c, d).



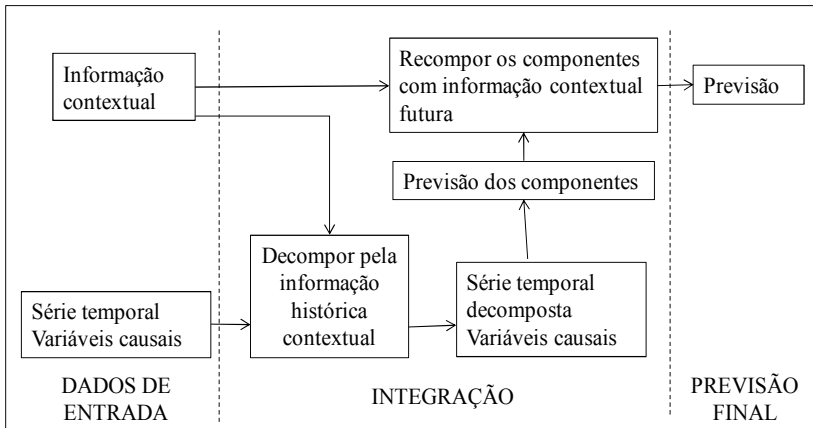
(a) Construção do Modelo.



(b) Combinação de previsão objetiva e subjetiva.



(c) Ajuste por julgamento de previsões estatísticas.



(d) Decomposição baseada no julgamento.

Figura 3-1 Integração de previsões subjetivas e objetivas – abordagem Webby e O’Connor (1996).

Fonte: Adaptado de Webby e O’Connor (1996).

Pode-se verificar que todas as formas de integração propostas na figura 3-1 possuem como dados de entrada a série temporal, variáveis causais e informações contextuais. A série temporal e as variáveis causais são dados utilizados por modelos quantitativos para originar extrapolações matemáticas. No trabalho de Webby e O’Connor (1996) a informação contextual foi definida como a informação que auxilia na explicação, interpretação e antecipação do comportamento da série temporal, sendo diferente dos dados da série temporal e da experiência do especialista. A exclusão da experiência do previsor da definição de informação contextual ocorreu porque a experiência está relacionada com o conhecimento do previsor sobre as relações entre as variáveis causais, algo que não está disponível no ambiente.

Entretanto, os mesmos autores (Webby e O’Connor), em um livro publicado em 2001, generalizam a definição de informação contextual afirmando que ela se refere ao montante de informações disponíveis no ambiente da previsão. Esta será a definição empregada neste trabalho.

A informação contextual pode ser dividida como quantitativa e qualitativa, variando de acordo com a origem da informação. O contexto quantitativo refere-se a variáveis causalmente relacionadas com as vendas (por exemplo, como a temperatura pode estar relacionada às vendas de sorvete). Já o contexto qualitativo pode estar relacionado com eventos especiais, sendo subdividido de acordo com a origem da informação. Informações de “quebrar as pernas” (do inglês, “*broken-leg*”

cues”) ou eventos inesperados, que será o termo utilizado neste trabalho, descrevem informações inusitadas ou inesperadas fornecidas aos especialistas. Estas informações não podem ser capturadas em um modelo formal. O outro tipo de informação contextual qualitativa é a denominada neste trabalho por informações informais (do inglês, “*soft information*”) que descreve informações processadas pelos gerentes de maneira informal e verbal. Esta informação normalmente vem na forma de rumores e é particularmente preferida pelos gerentes a uma análise pura contida em relatórios. De acordo com as definições apresentadas os autores concluem que a maior parte das informações contextuais tem origem das informações informais (WEBBY; O’CONNOR, 1996, 2001).

Armstrong (2001) apresentou maneiras alternativas de integração de previsões como pode ser visualizado na figura 3-2.

Nela verifica-se que a fonte de recursos para todas as formas de integração provém do domínio do conhecimento. Segundo Webby e O’Connor (2001) o domínio do conhecimento é o resultado da aplicação de interpretação humana em informações contextuais no âmbito da previsão. Armstrong e Collopy (1998) exemplificam o uso do domínio do conhecimento afirmando que os especialistas da área realizam julgamentos baseados no seu conhecimento sobre o produto/mercado e nas suas expectativas sobre os padrões dos dados.

Para Sanders e Ritzman (2001), assim que os profissionais estão familiarizados com o ambiente, eles ficam sintonizados com inúmeras relações de causa-efeito e sinais do ambiente. Desta forma, a qualidade do domínio de conhecimento depende da habilidade do especialista em avaliar o significado da informação contextual de forma apropriada. Vale destacar que o domínio do conhecimento provém da informação contextual, porém nem sempre a informação contextual produz um domínio de conhecimento adequado.

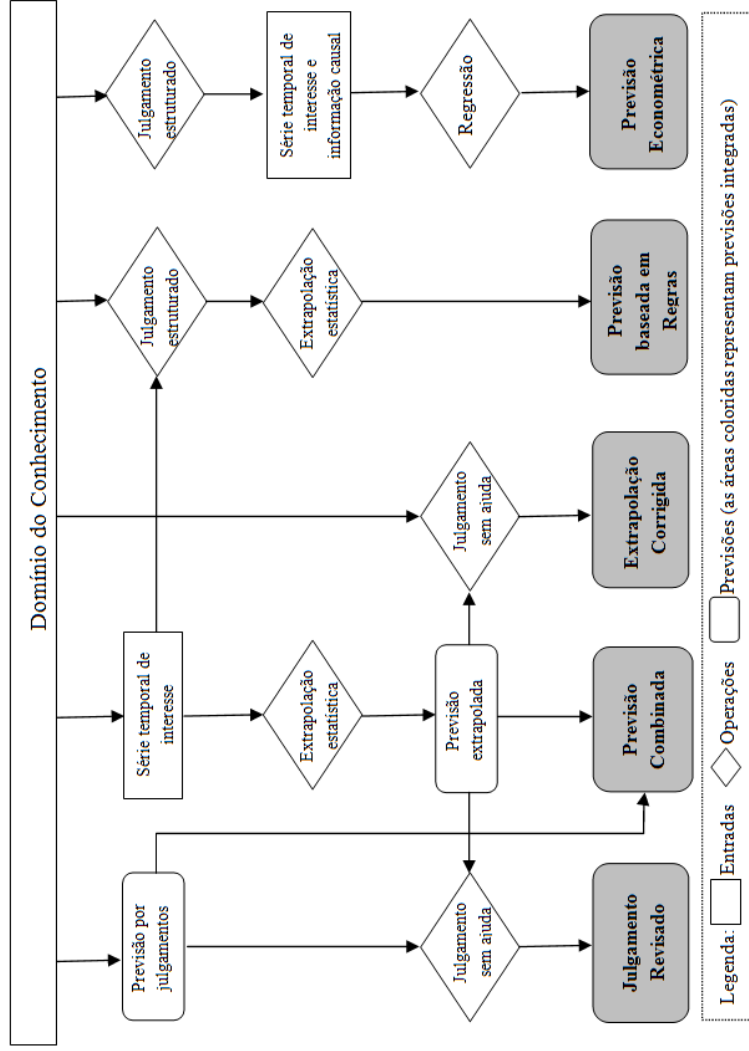


Figura 3-2 Métodos de integração de julgamentos e métodos estatísticos – abordagem Armstrong (2001).
 Fonte: Adaptado de Armstrong (2001).

Lawrence et al. (2006) apresentam dois benefícios principais do domínio do conhecimento que auxiliam no aumento da acuracidade da previsão. A primeira vantagem é em relação ao tempo, pois o conhecimento das informações mais atuais é o que produz as melhores previsões. A segunda vantagem é o conhecimento ser um fator não modelado pelos métodos estatísticos, como campanhas de marketing, ações de competidores, etc.

As características consideradas essenciais para o bom desempenho dos especialistas incluem a motivação dos previsores para a função e a sua experiência, que é adquirida com o entendimento do contexto ou natureza da série. A experiência do especialista pode ser subdividida em dois grandes aspectos: o conhecimento técnico e o conhecimento causal. O primeiro corresponde ao conhecimento sobre a análise de dados e procedimentos formais de previsão. O segundo faz parte do entendimento das relações de causa-efeito envolvidas. Já a motivação refere-se à característica do ambiente que induz rigor na aplicação de uma estratégia selecionada pelo previsor (WEBBY; O'CONNOR, 1996).

Para utilizar as qualidades apresentadas pelos especialistas (motivação e experiência) deve-se estruturar a maneira como o julgamento é realizado. Ahlburg (2001) afirma que a forma na qual o conhecimento dos especialistas for empregado pode afetar sua utilidade, sendo que o julgamento estruturado apresenta melhores resultados que o julgamento ou o modelo estatístico sozinhos. De acordo com Armstrong (2001), o julgamento estruturado é uma tentativa de ir além da intuição ao se fazer previsões por julgamento. Isto é realizado através de diversas abordagens, algumas serão apresentadas na seção 3.3.

Lawrence et al. (2006) realizaram uma revisão dos estudos sobre previsão de vendas e identificaram dois principais grupos em que é incorporado o domínio do conhecimento. O primeiro são as previsões produzidas sem nenhuma outra entrada de modelos de previsão estatísticos, em que a previsão é simplesmente o produto de um julgamento individual ou de um grupo. O segundo grupo de estudos remete à junção do domínio do conhecimento com a previsão estatística, sendo chamados por “estudos de ajuste por julgamento”.

Dois exemplos de estudos sobre ajuste por julgamento são as formas de integração abordadas na figura 3-1 e figura 3-2. Observa-se na figura 3-1 que o modelo de Webby e O'Connor (1996) é mais generalizado, em que algumas abordagens podem se desdobrar em diversos métodos. Além disso, segundo os autores, as abordagens não

são mutuamente exclusivas, elas podem e devem interagir. Enquanto isso, na figura 3-2, o modelo de Armstrong (2001) remete a cinco métodos de integração específicos. Armstrong e Collopy (1998) também apresentam o mesmo esquema de Armstrong (2001) e afirmam que a estrutura e complexidade dos métodos aumentam da esquerda para a direita. Logo, o julgamento revisado é o método mais simples e a previsão econométrica a mais estruturada.

Sobre formas de integração de previsões quantitativas com julgamentos, Goodwin (2002) divide a integração de previsões em duas abordagens: a integração voluntária e a mecânica. O seu trabalho trata de métodos de previsão pontuais de curto prazo, e cada uma das duas abordagens (voluntária e mecânica) contém seus respectivos métodos conforme pode ser observado na figura 3-3.




Figura 3-3 Integração de julgamentos e métodos estatísticos – abordagem Goodwin (2002).

Fonte: Adaptado de Goodwin (2002).

A integração voluntária ocorre quando o previsor é suprido de previsão estatística e decide como usá-la na formação de seu julgamento. O especialista pode ignorar a previsão quantitativa ou aceitá-la completamente, caso em que não se realiza ajuste. A integração voluntária que envolve a aplicação de julgamento à saída de previsões estatísticas corresponde ao método de ajuste por julgamento de previsão estatística da figura 3-3. Porém, o especialista pode também utilizar a informação da previsão estatística para ajustar sua previsão por julgamento inicial, resultando no método julgamento revisado (GOODWIN, 2002).

Na integração mecânica a previsão “integrada” é obtida através da aplicação de métodos estatísticos na previsão por julgamento. Dentre os métodos inseridos na integração mecânica constam (conforme figura 3-3) os métodos de previsão combinada, *bootstrapping* subjetivo e correção de vieses. Segundo Goodwin (2002), das três abordagens de integração mecânica a previsão combinada é a mais discutida.

Como foram apresentadas na Figura 3-1, Figura 3-2 e Figura 3-3, existem inúmeras formas de integração de previsões. Segundo Goodwin (2002), a escolha do método de integração mais apropriado irá depender das condições específicas aplicadas em um contexto específico. Porém, os inúmeros estudos empíricos existentes na literatura sugerem a utilização de determinados métodos em alguns tipos específicos de situações.

Por exemplo, quando está disponível para os métodos quantitativos e para os especialistas somente a informação das séries temporais e, além disso, as previsões estatísticas são próximas do ótimo, o ajuste subjetivo tem pouco efeito na acuracidade (GOODWIN, 2002). Já em situações em que os dados são imprecisos e o ambiente sofre mudanças, o ajuste por julgamento baseado em domínio do conhecimento melhora a acuracidade de previsões estatísticas (SANDERS; RITZMAN, 2001).

Na sequencia do capítulo serão apresentados os métodos de integração de previsão expostos nos esquemas de Webby e O'Connor (1996), Armstrong (2001) e Goodwin (2002). Posteriormente, serão abordados os principais problemas associados à incorporação de julgamento em previsões e as formas de estruturar o julgamento para que as ineficiências sejam suprimidas.

3.1.1 Construção do modelo

Uma abordagem de integração de métodos quantitativos e julgamentos pode ser visualizada na figura 3-1 (a). Bunn e Wright (1991) identificam quatro áreas em que o julgamento pode exercer um papel na construção de um modelo quantitativo: na seleção de variáveis, na especificação do modelo, na estimação de parâmetros e na análise de dados.

A seleção e a análise de variáveis compreendem, respectivamente, a definição do que está causalmente relacionado à previsão da série de interesse e identificação de distúrbios nos dados que demandem ajuste. Segundo Webby e O'Connor (1996), apesar de existir diagnósticos estatísticos que auxiliam o especialista a encontrar as variáveis causais, há uma crença no meio empresarial que “a sabedoria convencional de seleção da variável deve ser essencialmente por julgamento”.

Durante a especificação do modelo, o conhecimento informal pode ser quantificado e posteriormente incorporado, utilizando, por exemplo, o uso de modelos econométricos. A estimação de parâmetros envolve a transformação de eventos especiais, conhecidos pelos

especialistas, em efeitos quantitativos nas séries temporais. Porém, os especialistas consideram esta estimação difícil por requerer não somente o conhecimento da influência do evento, mas também da base do modelo estatístico (WEBBY; O'CONNOR, 1996).

Através de uma abordagem tão ampla como esta, diversos métodos de integração de previsões podem ser desenvolvidos. Um exemplo está na seção 3.1.2, em que a tarefa de especificar o modelo e estimar parâmetros pode ser automatizada usando a técnica de *bootstrapping*. Já para modelos econométricos (seção 3.1.3), os julgamentos podem incorporar informações extras não existentes nas séries.

3.1.2 *Bootstrapping* subjetivo

Segundo Clemen (1989), nos anos 50, um considerável esforço de pesquisa foi direcionado para o desenvolvimento de modelos que capturassem a opinião de especialistas, que terminou com a criação do método conhecido por *bootstrapping* subjetivo. A tradução da palavra *bootstrapping* significa desenvolver algo sem auxílio externo.

De acordo com Armstrong (2001), o *bootstrapping* subjetivo é um tipo de sistema especialista que traduz as regras dos experientes em um modelo quantitativo de regressão. A regressão conflita as previsões realizadas com as informações utilizadas pelos previsores para gerá-las. Lawrence et al. (2006) afirmam que o uso de um modelo estatístico de como os especialistas chegam às previsões tende a conduzir a resultados mais acurados que os obtidos pelos próprios previsores. Isto porque o modelo filtra as inconsistências do julgamento humano.

A forma usual do modelo é dada pela equação (3.1) (GOODWIN, 2002):

$$F_t = a + b_1x_{1,t} + b_2x_{2,t} + \dots + b_nx_{n,t} \quad (3.1)$$

Em que F_t é a previsão dos especialistas para o período t , $x_{i,t}$ são os valores dos critérios disponíveis no período t , b_i é o peso que o especialista implicitamente aplica ao critério e a é uma constante.

O *bootstrapping* é bem sucedido quando as relações entre as variáveis são lineares e quando as variáveis são bem definidas, mas é vulnerável quando existem inúmeras mudanças bruscas nos dados (WEBBY; O'CONNOR, 1996). O modelo oferece vantagens em relação aos métodos econométricos quando não existem dados disponíveis nos

critérios (variáveis dependentes) e as variáveis causais tem pequena variação histórica (ARMSTRONG, 2001).

O modelo pode ser usado para substituir a pessoa que originalmente realizava a produção da previsão por julgamento. Contudo, existem inúmeras dificuldades de aplicação do método para previsão de séries temporais (GOODWIN, 2002):

- (i) O grande número de possíveis critérios que podem ser avaliados simultaneamente pelo especialista;
- (ii) A possibilidade dos especialistas utilizarem critérios visuais como a “forma” de um gráfico de uma série temporal;
- (iii) A possibilidade dos especialistas terem acesso exclusivo à informação contextual, o que não poderia ser incorporado ao modelo.

3.1.3 Previsão econométrica

A previsão econométrica originalmente une a teoria econômica com medidas concretas, usando como ponte a teoria e as técnicas de inferência estatística (GUJARATI, 2000). De acordo com Werner (2004), quando dados históricos estão disponíveis e é possível explicar detalhadamente a relação entre a variável a ser prevista e outras variáveis, tais como variáveis econômicas, pode-se construir um modelo causal. Assim, os modelos econométricos também podem ser classificados como causais conforme apresentado no capítulo 2.

O objetivo de apresentar a previsão econométrica neste capítulo é explanar a modalidade que integra julgamentos humanos ao modelo. Armstrong (2001) demonstra esta forma de integração conforme a figura 3-2. Dentre as formas de integração apresentadas pelo autor esta é a mais estruturada. Os julgamentos podem ser usados para identificar o modelo, selecionar as variáveis causais e para especificar as direções dos seus efeitos.

Para estimar a previsão econométrica, conforme o esquema de Armstrong (2001), inicialmente os especialistas identificam as variáveis causais que explicam o comportamento da demanda e em seguida a análise de regressão obtém as estimativas para os coeficientes do modelo. Cabe destacar que o ideal para um bom desempenho do modelo é quando entre as diferentes variáveis explicativas não existe correlação (BARBOSA; WANKE, 2010).

Segundo Armstrong e Collopy (1998), quando o julgamento é baseado em um bom domínio do conhecimento os modelos econométricos são tipicamente mais precisos que outros procedimentos na existência de grandes mudanças. Armstrong (2006) realizou um

panorama geral dos trabalhos que tiveram como foco a previsão de longos períodos e ele encontrou uma taxa de 7 trabalhos contra 1 em que os modelos causais tiveram melhor desempenho que os modelos de extrapolação.

Armstrong (2006) destaca que pelo fato do modelo econométrico incluir variáveis políticas (como o preço de um produto, por exemplo), ele é útil para prever os efeitos de decisões em governos e empresas. Isto é particularmente verdade quando o especialista possui um domínio do conhecimento, dados acurados, a variável causal possui forte relação com a variável independente e a variável causal irá mudar substancialmente. O autor avalia também que os grandes esforços despendidos pelos pesquisadores nos últimos 25 anos de pesquisa tem tornado os modelos econométricos mais complexos; contudo, isto não tem se transformado em melhorias da acuracidade.

3.1.4 Previsão combinada

Por combinação de previsões entende-se toda e qualquer forma de atrelamento de previsões de base estatística, julgamental ou ambas, a partir de pesos fixos ou variáveis, de forma objetiva ou subjetiva em cada uma das previsões constituintes (SOUZA, 2008).

Para Barbosa e Wanke (2010), a ideia de combinar previsões geradas por indivíduos com dados e objetivos diferentes dentro da empresa torna-se favorável na medida em que deixa a previsão mais equilibrada, mais próximo da tendência central ao longo do tempo. Neste sentido, Armstrong (2006) afirma que a combinação é mais útil quando os métodos ou dados são substancialmente diferentes, sendo a situação ideal a existência de forte correlação negativa entre os erros de previsão.

Segundo Webby e O'Connor (1996), existe uma grande aceitação e evidências que combinar duas ou mais previsões independentes aumenta significativamente a acuracidade da previsão final. Para Lawrence et al. (2006), isto ocorre porque as previsões combinadas atraem informações de fontes diferentes e portanto aumentam as informações sob as quais a previsão está baseada. Armstrong (2001) afirma que a combinação de previsões é especialmente útil quando não se tem certeza sobre a situação, quando existe incerteza sobre qual método é mais acurado e quando se quer evitar grandes erros.

Werner (2004) apresenta em seu trabalho as diversas formas de combinação de previsões como pode ser visualizado no quadro 3-1. As previsões base são os métodos que serão combinados, podendo ser

compostos somente por métodos objetivos (quantitativos), por métodos subjetivos (qualitativos) ou pela união de ambos.

Previsão base	Método de combinação	
	Objetivo	Subjetivo
Objetiva	A	B
Subjetiva	C	D
Ambas	E	F

Quadro 3-1 – Métodos de combinação de previsões.

Fonte: Werner (2004).

Conforme o quadro 3-1, os métodos de combinação das previsões-base podem ter uma abordagem objetiva ou subjetiva. De acordo com Werner (2004), 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.

A literatura passada concentrou-se predominantemente na combinação de previsões objetivas (WEBBY; O'CONNOR, 1996). Para Mackay e Metcalfe (2002), o foco prioritário dos estudos de combinação de previsões, até 1989, foi o estabelecimento de métodos 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.

Sobre a decisão de quais previsões combinar, na figura 3-1, figura 3-2 e figura 3-3 observa-se que o método de combinação de previsões quantitativas e por julgamento foi abordado como uma forma de integração por todos os autores, sendo, portanto, este o foco desta seção (letras E e F do quadro 3-1).

Armstrong e Collopy (1998) apresentam resultados de inúmeros trabalhos em que a combinação de previsões quantitativas e por julgamento obtiveram melhor desempenho do que combinar somente previsões quantitativas ou somente previsões por julgamento. Lawrence et al. (2006) justificam este desempenho afirmando que as eficiências complementares das previsões estatísticas e julgamentais indicam que a combinação destes métodos é mais valiosa por considerar diversos contextos. Por isso, quando a previsão estatística e por julgamento forem combinadas objetivamente, a previsão por julgamento deve ser

baseada em informação contextual, especialmente quando a série temporal tiver um alto grau de variabilidade.

Sanders e Ritzman (1990) alertam que quando a previsão por julgamento for significativamente mais acurada que a previsão estatística, a previsão combinada será menos acurada que aquela por julgamento. Portanto, quando uma previsão for substancialmente superior à outra, a combinação de uma previsão muito boa com outra muito ruim irá reduzir a acuracidade final.

Os ganhos provenientes da combinação de previsões estatísticas e julgamentais está no fato de se basearem em fontes de informações diferentes. Porém, Herzog e Hertwig (2009) abordam em seu trabalho uma forma de combinar previsões por julgamento utilizando somente o conhecimento de um especialista. Eles propõem explorar o poder da média usando uma abordagem intitulada “*Dialectical Bootstrapping*”. Esta abordagem consiste em obter a média de duas estimativas baseadas em conhecimento não redundante do mesmo especialista. Segundo os autores, neste método o conhecimento de muitas pessoas pode ser simulado por uma única mente através das suas próprias opiniões conflitantes. A técnica induz a pessoa a gerar uma previsão lógica usando conhecimento pelo menos parcialmente diferente daquele usado para gerar a primeira previsão. Neste caso, a previsão lógica tem um erro diferente do que a primeira estimativa por se basear em conhecimento e hipóteses diferentes.

Sobre os métodos de combinação (objetivo e subjetivo) apresentados no quadro 3-1, Armstrong e Collopy (1998) afirmam que a combinação objetiva (letra E do quadro 3-1) tem pelo menos três vantagens em relação à definição dos pesos por especialistas (letra F do quadro 3-1). A primeira é ser imparcial, evitando a entrada de tendências ou manipulação política. A segunda é o processo que produz a previsão poder ser facilmente conhecido. A terceira vantagem do método é ter tendência de ser mais acurado por usar o conhecimento de forma mais efetiva.

Armstrong (2001) destaca, ainda, que se o julgamento é utilizado para combinar as previsões, deve ser utilizado um modelo estruturado e os detalhes do procedimento precisam ser gravados, pois determinar os pesos subjetivamente permite que as pessoas introduzam suas tendências. Apesar disto, este método de combinação fornece bons resultados quando os especialistas têm um bom retorno sobre a acuracidade das previsões iniciais.

Os métodos objetivos mais básicos de combinar previsões são a média simples e média ponderada conforme equação (3.2), em que a

diferença entre os métodos está na escolha do peso w . A média ponderada requer a escolha dos pesos (w) para cada previsão (F_1 e F_2), que pode ser feita através de softwares de otimização que objetivam minimizar os erros de previsão (BARBOSA; WANKE, 2010).

$$F_t = wF_1 + (1 - w)F_2 \quad (3.2)$$

A combinação considerando pesos iguais tem se mostrado efetiva na redução do erro de previsão na maioria das condições, sendo particularmente apropriada quando as séries históricas têm alta incerteza e instabilidade. Apesar disto, pesos diferenciados são ocasionalmente úteis quando o especialista tem um bom domínio do conhecimento ou informações sobre quais métodos são os mais apropriados para a situação (ARMSTRONG, 2006).

Goodwin (2002) destaca que encontrar pesos matematicamente otimizados requer previsões não tendenciosas, um padrão de erros de previsão estacionário ao longo do tempo e dados passados suficientes para estimar os pesos ótimos de forma confiável. Segundo o autor, estas condições normalmente não são verificadas em situações práticas.

De Gooijer e Hyndman (2006) afirmam que inúmeros métodos para seleção de pesos combinados já foram propostos, sendo que a média simples é o método de combinação mais usado. Os autores relatam o trabalho de Stock e Watson (2004) em que foi abordada uma combinação de previsões denominada “puzzle T”, em que associações simples como médias obtiveram desempenhos melhores que outras combinações mais sofisticadas, conhecidas em teoria como melhores.

Mesmo sendo a média aritmética das previsões um razoável ponto de partida para realizar combinações, demonstrando ser relativamente robusto e mais acurado que métodos mais elaborados (ARMSTRONG, 2001), muitos autores continuaram na busca pelo melhor método de combinação. Um exemplo é o trabalho de Constantini e Pappalardo (2010), que propuseram um procedimento hierárquico para melhorar a eficiência da previsão por métodos combinados. Inicialmente eles formaram um ranking de todas as previsões através da medida de erro RMSFE (erro médio de previsão dado pela raiz quadrada dos erros somados ao quadrado e dividido pelo número de erros considerados, em inglês “*Root Mean Square Forecasting Error*”). Os modelos são então selecionados por combinação usando o teste de abrangência (a abrangência está relacionada a combinar modelos que não tenham informações repetidas). Posteriormente, uma metodologia hierárquica

descreve um termo comum entre o modelo selecionado e a sua média. Grandes pesos são designados aos modelos que tem uma alta performance de previsão e que adicionam informações não contidas em outros modelos. As previsões que possuem informações contidas em outros métodos e que não alcançam bons resultados são descartadas. A metodologia proposta pode ser utilizada como um método alternativo para a combinação ótima baseada na matriz de variância-covariância dos erros de previsão.

Goodwin (2002) apresenta em seu trabalho que o fator que influencia o desempenho da previsão combinada é a correlação entre os erros das previsões constituintes. Se as previsões utilizadas não são tendenciosas e a média simples é o método empregado, pode ser demonstrado que o erro médio quadrado (MSE, seção 2.3.1) das previsões combinadas somente serão menores que aquelas da previsão por julgamento quando:

$$\frac{\sigma_j}{\sigma_s} > \frac{r + (r^2 + 3)^{0.5}}{3} \quad (3.3)$$

Na equação (3.3), σ_s e σ_j são, respectivamente, os desvios dos erros das previsões estatísticas e julgamentais e r é a correlação entre esses erros. Esta fórmula implica que a combinação é provavelmente menos efetiva quando a correlação entre os erros das previsões constituintes são altos. A alta correlação ocorre quando a segunda previsão incorpora poucas informações novas na combinação.

Assim, após décadas de estudos, as conclusões sobre a combinação de previsões confirmam as afirmações feitas por Clemen (1989): a acuracidade da previsão pode melhorar substancialmente através da combinação de múltiplas previsões individuais; a combinação mecânica produz melhores resultados que a realizada por julgamento; os métodos de combinação simples (médias) funcionam razoavelmente bem quando comparados aos métodos mais complexos.

3.1.5 Correção por vieses

O método de correção por vieses foi apresentado como uma forma de integração mecânica por Goodwin (2002) conforme a figura 3-3. O procedimento visa aumentar a acuracidade utilizando métodos estatísticos para prever os erros das previsões por julgamento.

De acordo com Lawrence et al. (2006), originalmente este método foi proposto por Theil em 1971. Contudo, somente 30 anos mais tarde foi comprovado ser efetivo no aumento da acuracidade das previsões. O método consiste na regressão de dados passados de previsões por julgamento utilizando o resultado do modelo para corrigir previsões futuras.

Goodwin (2002) afirma que Theil demonstrou como o MSE (erro médio quadrado, seção 2.3.1) de diversas previsões pode ser decomposto para demonstrar dois tipos de tendências, a média e tendência regredida:

$$MSE = (\overline{A} - \overline{F})^2 + (S_F - rS_A)^2 + (1 - r^2)S_A^2 \quad (3.4)$$

Termo 1 Termo 2 Termo 3

Na equação (3.4), \overline{A} e \overline{F} são as médias dos valores reais (A_t) e das previsões (F_t). S_A e S_F são os desvios padrões dos valores reais e das previsões e r é a correlação entre os valores reais e as previsões. Realizando a decomposição da equação (3.4), o Termo 1 representa a tendência média, que é a tendência das previsões de serem muito altas ou baixas. O Termo 2 representa a tendência regredida, que se manifesta em uma falha sistemática das previsões de seguir os padrões visualizados nos valores reais. O terceiro termo demonstra o então chamado erro aleatório das previsões.

Conforme Goodwin (2000), Theil demonstrou que a tendência média e a tendência regredida podem ser eliminadas através da regressão dos valores reais no tempo t (A_t) em relação às previsões (F_t). O intercepto (a) e a inclinação (b) resultantes da regressão são utilizados para encontrar o valor da previsão corrigida (\hat{A}_t), segundo a equação (3.5).

$$A_t = \hat{A}_t = a + bF_t \quad (3.5)$$

Segundo Lawrence et al. (2006), Fildes (1991) descobriu que quando os especialistas em julgamento conseguem acesso à informações contextuais, a correção baseada na regressão de erros de previsões passadas com estas informações gera um aumento de acuracidade. A forma do modelo é demonstrada pela equação (3.6):

$$e_t = a + b_1x_{1,t} + b_2x_{2,t} + \dots + b_nx_{n,t} + i_t \quad (3.6)$$

Segundo a equação (3.6), e_t é o erro de previsão do previsor no período t , $x_{i,t}$ são os valores das informações disponíveis ao previsor no tempo t , i_t é o valor residual no período t e a é uma constante. Portanto, o método proposto por Fildes permite que as tendências das previsões sejam corrigidas utilizando a informação contextual disponível.

Goodwin (2002) afirma que existem problemas potenciais no método de correção quando a natureza da tendência sofre alterações ao longo do tempo. Isso pode ocorrer como o resultado do aprendizado do especialista ou mudanças no quadro de pessoas responsáveis pela previsão. Lawrence et al. (2006) corroboram esta informação concluindo que os métodos de correção são úteis quando as tendências associadas às previsões por julgamento são sistemáticas e mantêm-se ao longo do tempo. Todavia, Goodwin (1997) expandiu o método de Theil utilizando regressão com pesos descontados para permitir ao procedimento de correção se adaptar às mudanças graduais na natureza tendenciosa dos especialistas. Com a inserção de pesos diferenciados na regressão, os coeficientes estimados tendem a levar em consideração o desempenho das previsões mais recentes.

Conforme visto na seção 3.1.4, de combinação de previsões, para que o método obtenha a eficiência desejada a equação (3.3) deve ser satisfeita. Para isso, um dos requisitos é que a previsão por julgamento não possua tendências. Para contornar este problema, Goodwin (2002) apresenta uma alternativa. Quando a previsão possui tendência, considerando a propensão dos especialistas a isto, será benéfico aplicar a correção à previsão por julgamento antes de combiná-la com a previsão estatística, sendo nomeada pelo autor como a estratégia de correção-depois-combinação. Em contrapartida, esta estratégia pode não ser bem sucedida quando a correção elimina totalmente a tendência das previsões futuras, o que reduzirá as chances dos erros médios opostos (da previsão estatística e por julgamento) se cancelarem na combinação.

3.1.6 Decomposição baseada no julgamento

A decomposição é demonstrada na figura 3-1 (d). Para MacGregor (2001) o método apresenta uma forma de tratar um problema através da separação do mesmo em uma série de tópicos menores que são inicialmente estimados, combinando-os posteriormente a fim de produzir a previsão final. Armstrong (2006) destaca que o

método só é relevante em situações onde o especialista conhece mais sobre os componentes do que sobre a variável principal a ser prevista. Webby e O'Connor (1996) afirmam que a decomposição aprimora a quantidade de informações processadas tornando óbvios os sinais difíceis de ver, o que melhora a qualidade da decisão.

A decomposição pode ser realizada de duas formas: a multiplicativa e a segmentada. Na primeira, a divisão das tarefas é multiplicativa, ou seja, as variáveis não interagem diretamente (por exemplo, previsão de vendas = previsão tamanho mercado x previsão fatia de mercado). Na decomposição segmentada os elementos da previsão são adicionados (por exemplo: previsão de vendas = previsão região norte + previsão região sul) (LAWRENCE et al., 2006). Contudo, a decomposição baseada no julgamento tratada nesta seção refere-se à análise multiplicativa do problema.

De acordo com os autores da figura 3-1 (d), Webby e O'Connor (1996), a decomposição por julgamento é um processo de três passos: (i) as séries temporais são decompostas para qualquer dado histórico; (ii) então as séries decompostas são previstas; e, (iii) a previsão é recomposta com as informações sobre eventos futuros. Na decomposição cada componente da série é extrapolado separadamente.

Segundo MacGregor (2001), a decomposição é mais utilizada para a previsão de grandes incertezas, como aquelas onde existe um grande número de valores (por exemplo, milhões ou mais) ou quantidade de alguma métrica incomum.

Lawrence et al. (2006) citam os resultados do trabalho de Webby, O'Connor e Edmundson (2005) afirmando que quando a série temporal contém distúrbios em alguns períodos por vários eventos especiais espontâneos, a acuracidade da previsão aumenta quando é solicitado aos especialistas a estimativa do efeito de cada evento separadamente ao invés de combinar todos os efeitos.

Complementando, Webby e O'Connor (1996) declaram que uma possível explicação para a decomposição baseada no julgamento ser mais acurada que uma técnica estatística está no fato dos especialistas serem aptos a reconhecer e desconsiderar descontinuidades aleatórias que seriam incorporadas no método estatístico. Contudo, se o previsor não está familiarizado com a técnica ou o julgamento é mais complexo que a análise integral da variável o método não será eficiente.

3.1.7 Previsão baseada em regras

O método de previsão baseado em regras (*rule-based forecasts*) foi abordado como uma forma de integração de previsões por

Armstrong (2001) conforme demonstra a figura 3-2. De acordo com o autor, os métodos tradicionais de previsão que utilizam extrapolação possuem duas grandes limitações. Inicialmente, eles não incorporam o conhecimento existente que demonstra qual método de extrapolação é o melhor para diversas situações. Posteriormente, eles ignoram o conhecimento dos previsores sobre o contexto em que se está realizando a previsão. Logo, a previsão baseada em regras é um tipo de sistema especialista que extrapola a série temporal integrando o domínio do conhecimento do especialista sobre o ambiente e os processos de previsão.

O domínio do conhecimento pode auxiliar na identificação da direção das forças causais nas séries de interesse, a forma funcional que a série temporal provavelmente irá seguir e a presença de quaisquer observações e padrões não usuais (ARMSTRONG; COLLOPY, 1998).

O método usa o domínio do conhecimento para combinar previsões de vários métodos de extrapolação. Utilizando regras condicionais se-então (*if-then*), determinam-se os pesos dos métodos simples de previsão. As características do ambiente são identificadas na parte condicional (se ou *if*) das regras e os pesos são ajustados de acordo com as características da série assumidas anteriormente (ARMSTRONG; ADYA; COLLOPY, 2001).

A previsão baseada em regras conduz a melhores resultados quando o especialista apresenta domínio do conhecimento e este conhecimento tem um forte impacto, a série temporal possui um bom comportamento (os padrões podem ser identificados), existe uma grande tendência nos dados da série temporal e o horizonte de previsão é longo. Quando estas condições não ocorrem, o método não melhora nem piora a acuracidade da previsão (ARMSTRONG, 2006).

3.1.8 Julgamento revisado

Neste método os especialistas fazem uma previsão por julgamento inicial e posteriormente a revisa a partir do provimento de extrapolações estatísticas (ARMSTRONG; COLLOPY, 1998). Esta forma de integração foi abordada na figura 3-2 e figura 3-3.

A acuracidade aumenta quando o previsor segue um procedimento estruturado em que uma previsão preliminar é feita, os dados são examinados e então a previsão é revisada. Contudo, os previsores podem ser resistentes às novas informações fornecidas pelas previsões estatísticas, colocando um peso maior na previsão por julgamento inicial ao combinar as duas informações (ARMSTRONG; COLLOPY, 1998).

De acordo com Goodwin (2002), isto pode ocorrer com os gerentes que são respeitados por seu conhecimento sobre os produtos ou mercado e sentirem perda de controle e posse se as previsões são delegadas a modelos estatísticos.

Por ser um método de baixa complexidade e fácil implantação, para se obter bons resultados é necessário que o julgamento seja estruturado. Este assunto será tratado com detalhes na seção 3.3.

3.1.9 Extrapolação corrigida

A extrapolação corrigida era considerada como uma forma de combinação, contudo, este conceito mudou e atualmente é classificada como integração de previsões (WERNER; RIBEIRO, 2006). O método de extrapolação corrigida foi abordada pelos três autores (Webby e O'Connor (1996), Armstrong (2001) e Goodwin (2002)) na seção 3.1. O método recebeu diferentes nomenclaturas. Webby e O'Connor (1996) figura 3-1 item (c) e Goodwin (2002) figura 3-3, denominaram o método por “ajuste por julgamento de previsões estatísticas”, sendo esta a terminologia mais utilizada na literatura internacional (*judgmental adjustment of statistical forecasts*). Já na tradução para o português o método foi nomeado ajuste subjetivo (LUCINI, 2010), ajuste baseado na opinião (WERNER, 2004), ajuste julgamental de previsões (SOUZA, 2008). O termo utilizado neste trabalho, extrapolação corrigida, provém do trabalho de Armstrong e Collopy (1998) e Armstrong (2001), tradução do termo em inglês “*revised extrapolation forecasts*”.

Segundo Armstrong e Collopy (1998) a extrapolação corrigida é a forma mais comum de integrar métodos estatísticos e julgamentos. Os autores apresentaram a pesquisa de Sanders e Manrodt's (1994) com 96 especialistas de corporações dos EUA. Deles, cerca de 45% alegaram que sempre fazem ajustes por julgamento em previsões estatísticas, enquanto 9% disseram que nunca fizeram isto. As principais razões levantadas foram para “incorporar conhecimento do ambiente” (39%), “incorporar conhecimento do produto” (30%) e “incorporar experiências passadas” (26%).

A extrapolação corrigida consiste em realizar uma análise quantitativa dos dados resultando na previsão parcial. Estas informações são levadas aos especialistas que avaliam, de acordo com seu domínio de conhecimento e informações contextuais disponíveis, se esse valor deve ser alterado.

Webby e O'Connor (1996) apresentam três formas de julgamento na saída de uma previsão estatística: ajuste sem contexto; ajuste contextual e ajuste estruturado. O ajuste sem contexto pode ser usado

como uma alternativa quando o previsor sente que a previsão está imprecisa, apesar do previsor não conseguir associar nenhuma informação contextual com a série. O ajuste sem contexto está baseado na intuição, para Armstrong (2001) na compreensão imediata de um assunto sem o uso de qualquer processo de raciocínio. O ajuste contextual ocorre quando informações contextuais estão disponíveis e o especialista ajusta a previsão inicial para incorporar os efeitos da informação extra. Normalmente este tipo de ajuste é efetivo, apesar de ser difícil atribuir o aumento da acuracidade somente pelo contexto, pois a experiência e a motivação do especialista também influenciam. Por fim, o ajuste estruturado consiste na aplicação de métodos para construir um julgamento sem informalidade, visto que a principal crítica do ajuste por julgamento está em ser, na grande maioria das vezes, de natureza empírica. Os métodos mais utilizados para estruturar julgamentos serão abordados na seção 3.3.

Quando a série temporal é a única informação disponível tanto para o método estatístico quanto para o especialista, a maioria dos estudos sugerem que o ajuste por julgamento da previsão quantitativa irá reduzir a acuracidade. Isto ocorre porque as pessoas tendem a encontrar padrões no ruído aleatório da série temporal e fazem ajustes prejudiciais na previsão quantitativa na tentativa de prever o comportamento deste ruído. Em contraste, quando o especialista tem acesso exclusivo a informações contextuais, existe um grande número de evidências que demonstram o ajuste por julgamento melhorando a acuracidade de previsões estatísticas (GOODWIN, 2002).

A efetividade do ajuste pode depender também da acuracidade da previsão estatística inicial. Por exemplo, quando um ajuste sem contexto é realizado, normalmente ele não é benéfico quando a previsão estatística é precisa. Contudo, ele pode trazer bons resultados quando a previsão estatística possui grandes erros ou espaços para melhorias (WEBBY; O'CONNOR, 1996).

Portanto, para ser útil, o julgamento deve incorporar informações que não são visualizadas pela previsão estatística de forma estruturada (ARMSTRONG; COLLOPY, 1998). A utilização de uma estrutura de ajuste visa minimizar a introdução de viés, inerente à tomada de decisão humana (WEBBY & O'CONNOR, 1996).

Syntetos, Nikolopoulos e Boylan (2010) realizam uma incorporação de julgamentos estruturada no âmbito de gerenciamento de estoques. O trabalho discute a influência do desempenho da previsão no controle de estoques da empresa através de medidas de precisão. Dentre as conclusões, demonstrou-se que os ajustes por julgamento

contribuíram para a redução substancial dos níveis de estoque. Isto mostra que investimentos em ajustes por julgamentos inteligentes podem proporcionar retornos financeiros consideráveis.

Sanders e Ritzman (2001) apresentam seis princípios que devem ser utilizados para decidir quando e como usar o julgamento no ajuste de previsões estatísticas: (i) ajustar a previsão estatística quando existe um significativo domínio de conhecimento; (ii) ajustar em situações com alto grau de incerteza; (iii) ajustar quando as mudanças no ambiente são conhecidas; (iv) o processo de ajuste deve ser estruturado; (v) considerar a integração mecânica de previsões estatísticas e por julgamento.

O último item dos princípios relacionados por Sanders e Ritzman (2001) sugere ao previsor utilizar uma integração mecânica de previsões ao invés do ajuste, visto que o ajuste por julgamento é na verdade a forma menos efetiva de integração de previsões estatísticas e por julgamentos. O ajuste por julgamento introduz tendências, mesmo quando ele melhora a acuracidade geral.

Adicionalmente, a variável prevista pode ser parcialmente controlada pelo gerente que está fazendo as previsões. Há uma tendência do previsor em subestimar a previsão estatística em favor do seu próprio julgamento, mesmo quando ele conhece a superioridade da precisão da previsão matemática (GOODWIN, 2002).

3.2 VIESES NA INCORPORAÇÃO DE JULGAMENTO

Apesar do julgamento ser largamente utilizado em previsões, ele possui sérias desvantagens quando comparado a métodos estatísticos. Como os julgamentos são realizados por pessoas, toda a complexidade que cerca o entendimento da mente humana e suas relações com o ambiente podem interferir nos resultados da previsão. A começar pelas limitações intrínsecas das pessoas para avaliar inúmeras informações ao mesmo tempo. Webby, O'Connor e Edmundson (2005) citando outros estudos anteriores afirmam que qualquer número entre três e dez partes de informação (sinais) representam os limites da capacidade humana de processamento de informações. A fonte desta variação está não apenas na tarefa e nas diferenças de personalidade, mas também nas diferentes definições do que constitui os 'sinais'.

Segundo Herzog e Hertwig (2009) uma previsão subjetiva que origina um valor quantitativo pode ser expressa como uma função aditiva de três componentes: a realidade (o valor real da previsão quantitativa), o erro aleatório (flutuações aleatórias no desempenho do especialista) e o erro sistemático (a tendência sistemática do especialista de superestimar ou subestimar o valor real).

Para Werner (2004), o erro aleatório se refere à dispersão das previsões em torno da média. Já o erro sistemático se refere à distância entre o valor da previsão e o valor verdadeiro, sendo este o maior problema do julgamento. Também denominado neste trabalho como tendência ou viés, o erro sistemático representa os desvios do valor real que tendem ir para uma direção. De acordo com Fildes et al. (2009), a tendência pode ser decomposta em dois componentes: tendência média e tendência de regressão. A tendência média é a direção sistemática da previsão de ser menor ou maior que o valor real. Já a tendência de regressão é a medida na qual as previsões sistemáticas falham ao perseguirem as observações reais.

Julianelli (2007) descreve que o processo de incorporação de julgamentos pode estar sujeito à heurísticas de decisão. As heurísticas são regras inconscientes que os previsores utilizam para simplificar o processo de interpretação das informações do mercado, o que pode levá-los a cometerem erros. Para Armstrong (2001), a tendência pode ocorrer em qualquer tipo de método de previsão, mas é especialmente comum em previsões por julgamento. A maneira mais importante para controlar a tendência é utilizar o julgamento estruturado, que será abordado na seção 3.3.

O erro sistemático se ramifica em diversos tipos de comportamentos que podem ser identificados nos previsores como segue:

Inconsistência

Consiste na 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 (WERNER, 2004).

Conservadorismo

O conservadorismo supõe que a variável em estudo poderá continuar se comportando da mesma forma como se comportou no passado. Por isso, o especialista não muda ou muda lentamente o ponto de vista quando novas informações/evidências estão disponíveis (LEMOS, 2006).

Otimismo

Segundo Werner (2004) o otimismo é 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”. Eroglu e Croxton (2010) complementam a descrição de otimismo afirmando ser uma tendência

dos previsores ajustarem as previsões predominantemente no sentido para mais.

Neste sentido, o estudo de Fildes et al. (2009) conclui que os ajustes positivos resultaram em menos aumentos da acuracidade das previsões que os ajustes negativos. Isto porque eles foram feitos frequentemente na direção errada, sugerindo uma tendência geral em direção ao otimismo.

Ancoramento

No ancoramento existe uma relutância do especialista em se desviar de um dado valor “âncora”, que pode ser obtido por previsões estatísticas, pela forma como o problema é apresentado ou por informações aleatórias (EROGLU; CROXTON, 2010). Os vieses causados pelo uso da heurística do ancoramento é que, em situações dúbias, uma informação pouco relevante pode causar um grande efeito na decisão final, caso ela venha a ser utilizada como âncora para ajustes posteriores (JULIANELLI, 2007).

Disponibilidade

A heurística da disponibilidade caracteriza-se pela avaliação de probabilidade de um determinado evento ocorrer pela frequência com que exemplos ou ocorrências deste evento estiverem disponíveis na memória. Os vieses causados estão relacionados a problemas de informações vívidas e recentes, pois um fato que torna um evento mais “disponível” na memória não o torna obrigatoriamente mais provável, o que conduz à exclusão de outras informações pertinentes (JULIANELLI, 2007).

Representatividade

A representatividade (ou correlação ilusória, Werner (2004)) está relacionada à busca de aspectos peculiares em eventos probabilísticos que correspondam a um estereótipo. As falhas na heurística da representatividade ocorrem, principalmente, por problemas com a noção intuitiva da aleatoriedade e insensibilidade ao tamanho da amostra. No planejamento da demanda, estes vieses podem ocasionar falhas na extrapolação como verificar tendências inexistentes na série (JULIANELLI, 2007)

Recência

A recência refere-se aos eventos mais recentes que têm maior domínio sobre a previsão que eventos que ocorreram há mais tempo, sendo esses desprezados ou ignorados (WERNER, 2004).

Reação exagerada

A reação exagerada (do inglês “*overreaction bias*”) acontece quando a direção do ajuste por julgamento é correto, mas a magnitude é

tão grande que o ajuste produz um erro maior na direção oposta (EROGLU; CROXTON, 2010).

Dupla contagem

A dupla contagem da tendência (*double counting bias*) é um problema apontado por Armstrong e Collopy (1998) e Goodwin (2002). Este fato pode ocorrer se existem duas variáveis colineares e uma é considerada no modelo matemático e outra não. Neste caso, o previsor pode incorporar os problemas da outra variável no seu julgamento, realizando uma dupla contagem do problema.

Além das tendências intrínsecas aos especialistas, outros fatores externos também influenciam na acuracidade da previsão. Webby e O'Connor (1996) afirmam que a motivação, uma característica do ambiente, pode influenciar a inflexibilidade do previsor em relação a uma estratégia traçada por ele. Os autores descrevem quatro características motivacionais do ambiente de previsão: (i) o benefício extrínseco de realizar uma previsão acurada; (ii) se a previsão será revisável à luz de mais informações antes da acuracidade ser estimada; (iii) se é percebido que a previsão está com os especialistas da área de competência; (iv) a adequação, confiança e entendimento da informação (a motivação será maior com informação de qualidade, pois não haverá desculpas para a “falta de acuracidade”). Como conclusão, inúmeros estudos empíricos sustentam a relação entre incentivos e desempenho.

Um trabalho que avaliou a influência de fatores internos e externos nos tipos de tendências introduzidas foi o de Eroglu e Croxton (2010). Eles investigaram as tendências introduzidas durante os ajustes por julgamento em relação às diferentes características dos indivíduos que podem contribuir para elas. Eles exploraram os efeitos das particularidades, especificamente ‘personalidade’, ‘orientação motivacional’ e ‘local de trabalho de controle’ nos vieses de previsão otimismo, ancoramento e tendência de reação exagerada. Os resultados indicaram que a personalidade e orientação motivacional dos especialistas tem efeitos significativos nos vieses das previsões, enquanto que o local de trabalho de controle não exerceu nenhum efeito. As definições das características dos indivíduos podem ser encontradas na referência mencionada.

Goodwin (2002) descreve inúmeros trabalhos que não foram bem-sucedidos na tentativa de eliminar os vieses. Dentre as abordagens fracassadas estão: informar aos previsores que estão fazendo ajustes que deixarão a previsão pior; retirar a carga mental dos especialistas de fazer cálculos de médias e pesos; e aumentar o conhecimento técnico do previsor sobre métodos estatísticos e julgamentos tendenciosos.

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 perigosa quanto à 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 (WERNER, 2004).

3.3 ESTRUTURAÇÃO DE JULGAMENTOS

Em um rico ambiente contextual no qual os especialistas operam, o domínio do conhecimento é vitalmente importante. Nenhum outro fator parece contribuir mais para a acuracidade. Contudo, a forma como os previsores incorporam o domínio do conhecimento em suas previsões é o problema mais crucial em previsão de vendas (WEBBY; O'CONNOR, 2001).

O julgamento estruturado vem, portanto, tentar cobrir esta lacuna. Ele consiste no estabelecimento de procedimentos que formalizam o processo de julgamento. De acordo com Armstrong (2001) uma abordagem seria determinar a forma que a questão é colocada, o procedimento de coleta de respostas e o método para resumir as respostas.

Armstrong e Collopy (1998) afirmam que a estruturação de julgamentos no nível mais simples envolve a certeza que os cálculos aritméticos foram feitos corretamente. Outra forma é organizar os dados históricos para apresentar aos especialistas. A conclusão de diversos estudos mostra que os gráficos são melhores para séries com tendências, contudo isto reduz a habilidade de estimar o nível.

Ainda sobre a forma de apresentação dos dados, Lawrence et al. (1985) *apud* Webby e O'Connor (1996) não encontraram diferenças significativas entre a acuracidade de previsões por julgamento feita com a exposição de gráficos ou tabelas, apesar dos autores sugerirem que as previsões realizadas por tabelas foram mais 'robustas'. Por fim, após uma revisão da literatura, Harvey e Bolger (1996) *apud* Sanders e Ritzman (2001) concluíram que os gráficos geram previsões mais acuradas em séries que contém tendências e tabelas aumentam a acuracidade nos outros casos.

Quanto a estruturação do julgamento em si, ele pode ser realizado simplificadaamente através de um procedimento formal conhecido pelos especialistas até a utilização de um sistema de suporte à decisão. Lim e O'Connor (1996) apresentaram o método julgamento revisado (seção 3.1.8) como uma forma de estruturação de previsão. Em uma pesquisa

com universitários, este procedimento aumentou a acuracidade da previsão fictícia de vendas de refrigerantes.

Armstrong e Collopy (1998) apontam uma alternativa para evitar vieses como a dupla contagem. O ajuste por julgamento seria realizado após os previsores decidirem que ajuste seria apropriado para o modelo (por exemplo, adicionar 2% da previsão para cada período) e somente depois terem acesso às previsões estatísticas.

Goodwin (2002) apresenta procedimentos que tiveram êxito na redução dos vieses como: (i) implantar um aviso aos previsores para que só realizem o ajuste quando o erro estatístico for maior que a previsão naïve (ingênua); (ii) determinar aos previsores que primeiramente solicitem o ajuste e depois executem, sendo necessário, além disto, justificar o motivo do ajuste.

Descrever as razões para os ajustes de previsões quantitativas e registrar a acurácia das previsões ajustadas melhoram a precisão das previsões, pois forçam uma sistemática de exploração de fatores pertinentes que influenciam as previsões (GOODWIN, 2000; SANDERS; RITZMAN, 2001).

Arkes (2001) sugere alguns princípios para auxiliar na incorporação do julgamento: (a) listar os motivos pelos quais a previsão pode ser considerada equivocada; (b) obter um *feedback* da previsão realizada; (c) adequar o *feedback* a eventuais novas informações, principalmente se forem consideradas relevantes e; (d) realizar um experimento para testar a estratégia de previsão adotada, quando possível.

Sobre as diversas abordagens pertinentes a um *feedback* aos especialistas, Lawrence et al. (2006) apresenta na sua revisão bibliográfica diversas formas de fornecer um *feedback* aos previsores. O “*outcome feedback*” (informação sobre o resultado) informa ao previsor a última observação da série; “*performance feedback*” (informação do desempenho) informa a acuracidade, ajustes ou tendência do especialista associadas com previsões antigas realizadas por ele; “*cognitive feedback*” (informação cognitiva) fornece ao previsor a estratégia utilizada por ele para realizar as previsões julgamentais e, por fim, “*task properties feedback*” (informação sobre as características da função) fornece ao previsor informações sobre a tarefa de previsão com dados estatísticos (por exemplo, correlação de possíveis variáveis independentes com a variável a ser prevista). De acordo com os autores (Lawrence et al. 2006), o método que informa a última observação da série (“*outcome feedback*”) é o método mais usado, porém o menos efetivo. Isto ocorre pelo último valor da série conter ruídos e isto

dificultar para o previsor a distinção entre os erros sistemáticos do seu julgamento com o erro causado por fatores aleatórios. A forma de fornecer informações ao previsor com dados estatísticos (“*task properties feedback*”) tem sido considerado o mais efetivo entre os métodos, possivelmente porque, ao prover informações estatísticas sobre a tarefa, ajuda o previsor a rejeitar hipóteses erradas que ele estava considerando corretas.

A utilização de um sistema de suporte à decisão para auxiliar na estruturação do julgamento tem como exemplo o trabalho de Edmundson (1990) *apud* Sanders e Ritzman (2001). Nele, os previsores utilizaram um pacote computacional gráfico para decompor a série temporal em gráficos de tendência, sazonais e aleatórios. Os especialistas também usam os pacotes individualmente para identificar os diferentes componentes de dados e o programa automaticamente combina esses componentes para gerar a previsão final deles.

Wolfe e Flores (1990) *apud* Werner (2004) usaram um sistema de apoio a decisão, o método AHP (Analytic Hierarchy Process), para estruturar o processo de fazer o ajuste por julgamento de uma previsão gerada estatisticamente.

Werner e Ribeiro (2006) descrevem uma forma de integração de previsões utilizando combinação e ajuste baseado na opinião. A estruturação do julgamento dos especialistas para a determinação da previsão final seguiu os seguintes passos: a) estabelecimento do percentual máximo e mínimo de ajuste; b) montagem da lista dos fatores que podem influenciar o comportamento da demanda; c) mensuração do impacto de cada um dos fatores identificados; d) mensuração da opinião dos especialistas; e) cálculo das médias ponderadas; f) cálculo do ajuste percentual; g) cálculo da previsão final.

Marmier, Gonzales-Blanch e Cheikhrouhou (2009) desenvolveram uma abordagem para estruturar o julgamento de especialistas utilizando como método de integração a extrapolação corrigida. O objetivo do trabalho foi estruturar o conhecimento implícito e explícito para facilitar a sua total associação à previsão final. Isto foi realizado utilizando a identificação de quatro fatores característicos de eventos específicos que não puderam ser considerados nas previsões iniciais. A abordagem propõe a classificação de fatores baseados em eventos usados na estruturação da informação. Através destes fatores representativos, os previsores estão aptos a estruturar e comunicar seu conhecimento implícito com relação a evolução do mercado, consumidores e contratantes.

Apesar das abordagens que utilizam um sistema de suporte à decisão parecerem alcançar melhores resultados que os métodos mais simples, as empresas devem avaliar a sua necessidade e os recursos disponíveis antes de optar por alguma forma de incorporação de julgamento.

3.4 CONSIDERAÇÕES FINAIS

O ajuste por julgamento é uma forma de incorporar informações no processo de previsão. Quando o julgamento é utilizado, o especialista deve possuir informações contextuais não existentes no modelo estatístico e domínio de conhecimento para interpretar corretamente os eventos inesperados e as informações informais. O processo de incorporação de julgamento deve ser feito de forma estruturada, a fim de que os vieses inerentes aos previsores sejam minimizados.

O principal objetivo deste capítulo foi demonstrar a importância do julgamento no processo preditivo e sua utilização em metodologias tradicionais de implantação de métodos de previsão de demanda. O próximo capítulo apresentará um procedimento para implantação de um método de previsão de demanda que considere a integração de previsões quantitativas com julgamentos.

4 METODOLOGIA PARA IMPLANTAÇÃO DE UM MÉTODO DE PREVISÃO DE DEMANDA

Em um cenário econômico de incertezas, todas as empresas sentem a necessidade de alguma projeção do que acontecerá no futuro para definir suas estratégias. As previsões são, então, utilizadas para este fim e como foi apresentado nos capítulos anteriores, existem inúmeros métodos que geram previsões da demanda de algum produto ou serviço.

Uma vez que as informações de uma previsão serão usadas para apoiar o processo de decisão, é necessário que se conheçam as características do problema de decisão para que o processo de previsão de demanda possa ser definido. Ao se determinar o que vai ser previsto e qual o nível de detalhamento desejado, torna-se possível definir quais são as variáveis que serão analisadas e estimadas. Muitos fatores influenciam o nível de detalhe da previsão, como por exemplo: disponibilidade de dados e informação, custo da análise, exatidão a ser alcançada e necessidades da gerência (DIAS, 2004).

Para definir todos estes fatores, é necessária a implantação de um processo estruturado para realizar a previsão, sob pena de escolher um método de previsão inadequado que gera altos índices de erro, levando ao fracasso do processo preditivo.

Verificada a importância da aplicação de um modelo estruturado de previsão, este capítulo propõe um procedimento para a implantação da previsão de demanda considerando a inclusão de julgamentos de especialistas. Inicialmente será realizada uma revisão bibliográfica das principais metodologias encontradas na literatura, assim como os pré-requisitos para a implantação do processo preditivo. Posteriormente será apresentado o procedimento proposto, detalhando os passos para execução do processo.

4.1 METODOLOGIAS PARA IMPLANTAÇÃO DE MÉTODOS DE PREVISÃO DE DEMANDA

Um sistema de previsão de vendas é o conjunto de procedimentos de coleta, tratamento e análise de informações que visa gerar uma estimativa das vendas futuras, medidas em unidades de produtos (ou famílias de produtos) em cada unidade de tempo (semanas, meses, etc.) (CAVALHEIRO, 2003).

Para implantar um modelo de previsão de demanda em uma empresa, o responsável pela área deve inicialmente identificar os seguintes fatores conforme Chase, Jacobs e Aquilano (2006):

- 1) Horizonte de tempo a ser previsto;
- 2) Disponibilidade de dados;
- 3) Exatidão necessária;
- 4) Volume do orçamento de previsão;
- 5) Disponibilidade de pessoal qualificado.

A partir das informações obtidas pelos itens supracitados, identificam-se os parâmetros balizadores do sistema de previsão. O horizonte de previsão, disponibilidade de dados e exatidão necessária estão associados aos métodos de previsão quantitativos e qualitativos que poderão ser testados e qual a acurácia requerida deles. O volume do orçamento significa os recursos disponíveis para aquisição do pacote computacional que será utilizado para gerar previsões quantitativas. Além disso, o orçamento também deve contemplar a folha de pagamento dos colaboradores que integrarão o departamento responsável da empresa. A disponibilidade de pessoal qualificado envolve tanto conhecimento para implantar e monitorar previsões quantitativas quanto conhecimento de mercado para incorporar ajustes estruturados nas previsões.

A metodologia para implantação de um sistema de previsão de demanda já foi amplamente discutida na literatura. Pellegrini (2000) destaca quatro processos básicos a serem realizados: (i) identificação e definição dos problemas a serem tratados no sistema preditivo; (ii) aplicação dos métodos de previsão; (iii) procedimentos para seleção do método apropriado a situações específicas; e (iv) suporte organizacional para adaptar e usar os métodos de previsão requeridos.

Werner (2004) abrange a estruturação de um sistema de previsão em oito etapas: (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.

De forma geral, os principais passos para a implantação de um modelo de predição é demonstrado na figura 4-1.



Figura 4-1 Passos para implantação de um modelo de previsão.

Fonte: Adaptado de VONDOURIS et al., 2008 p.55.

Bowersox, Closs e Cooper (2002) afirmam que o processo de previsão deve incorporar uma combinação de técnicas, sistema de suporte de previsões e gerenciamento de previsões. Segundo os autores, as técnicas fornecem um valor quantitativo inicial, o suporte de previsões refina os dados para considerar mudanças no mercado, e o gerenciamento de previsões determina o gerenciamento do processo para guiar e monitorar o empenho dos “previsores”.

De todos os passos apresentados para a implantação de métodos de previsão na figura 4-1, a seleção da abordagem de previsão é o assunto mais discutido na literatura. Como pôde ser observado na revisão bibliográfica deste trabalho (capítulos 2 e 3), existem inúmeros métodos quantitativos, qualitativos e a integração de técnicas. Apesar da extensa bibliografia sobre o assunto, pouco tem se tratado de metodologias que estruturam a integração de previsões. No artigo de revisão dos 25 anos de estudos sobre previsão de series temporais, De Gooijer e Hyndman (2006) concluem que ainda existe a necessidade de desenvolver procedimentos para seleção de modelos que tornem efetivo o uso tanto de dados quantitativos quanto conhecimento de especialistas.

Exemplos de trabalhos que propõe metodologias para integração de previsões podem ser encontrados em Dias (2004), Kurrle (2004), Werner (2004), Souza (2008) e Lemos (2006).

Dias (2004) propõe uma adaptação do ajuste proposto por Webby e O'Connor (1996), apresentado na figura 3-1 (c). No método desenvolvido o julgamento é utilizado em dois momentos na elaboração da previsão: (a) a partir dos dados históricos indicam-se os métodos quantitativos mais adequados e suas previsões são posteriormente combinadas e, (b) a previsão resultante é ajustada, com base em um conhecimento dos fatores qualitativos que podem alterar a demanda.

O trabalho de Kurrle (2004) descreve um método para realizar previsão de demanda de novos veículos considerando métodos quantitativos e qualitativos. A proposta compõe-se da análise dos dados e aplicação do método ARIMA para elaboração da previsão quantitativa. Paralelamente, a metodologia Delphi é empregada para gerar a previsão qualitativa. O resultado final provém da combinação das duas previsões através da média aritmética.

Uma proposta de metodologia que considera de maneira complementar a combinação e a integração de previsões pode ser encontrada no trabalho de Werner (2004). A metodologia reúne informações históricas, dados econômicos e informações de especialistas em uma previsão combinada. O resultado desta combinação é então ajustado através do julgamento de um especialista. Os métodos utilizados na combinação foram Box-Jenkins, regressão e opinião de especialistas (obtido através de entrevistas).

Souza (2008) apresenta um modelo estruturado para realizar integrações de previsões objetivas e subjetivas, evitando as possíveis polarizações e limitações do julgamento humano que comprometem o desempenho e a credibilidade das previsões. Para isso utilizou a metodologia Delphi para realizar ajustes julgamentais no resultado da combinação de previsões quantitativas.

Por fim, Lemos (2006) cria uma metodologia para a seleção de métodos de previsão de demanda avaliando tanto métodos quantitativos e qualitativos quanto a integração de previsões. A metodologia proposta baseia-se no levantamento de fatores de decisão pré-definidos para a escolha de métodos de previsão de demanda que integrem fatores qualitativos e quantitativos.

A proposta deste trabalho consiste em apresentar um modelo para implantar previsões considerando o método de integração extrapolação corrigida. O método proposto na próxima seção provém da união das etapas para implantação de uma previsão quantitativa apresentado na

literatura com a forma de incorporação de julgamento do método extrapolação corrigida.

4.2 MÉTODO PROPOSTO PARA IMPLANTAR O MODELO DE PREVISÃO EXTRAPOLAÇÃO CORRIGIDA

Estudos de previsão de demanda em empresas têm revelado que os ajustes nas previsões realizadas por especialistas são feitos mesmo quando softwares estatísticos avançados e caros são empregados para gerar as previsões e mesmo onde há evidências que os ajustes reduzem a acuracidade média (GÖNÜL; ÖNKAL; GOODWIN, 2009).

Por este motivo tornam-se pertinentes os estudos relacionados à incorporação de julgamentos em previsões estatísticas. Apesar da extrapolação corrigida não ser o método preferido pela comunidade científica (Sanders; Ritzman, 2001; Armstrong; Collopy, 1998), a mesma reconhece que os ajustes por julgamentos baseados em domínio de conhecimento aumentam a acuracidade das previsões, apesar dos vieses dos especialistas. Para Syntetos et al. (2009), quando métodos quantitativos de previsão são usados, eles são frequentemente ajustados por julgamento, sendo uma das formas de associação de previsões mais utilizada na prática. Por este motivo o trabalho propõe um modelo que estruture este processo de extrapolação revisada por julgamento como demonstra a figura 4-2.

Na primeira etapa da figura 4-2, definição do problema, determina-se o que será previsto, o nível de detalhamento e o horizonte de previsão.

Na obtenção e tratamento dos dados inicialmente faz-se um levantamento e avaliação dos fatores internos e externos que influenciam as vendas de cada produto ou família de produtos. Vondouris et al. (2008) afirma que dados representativos e suficientes são um pré-requisito para o sucesso de qualquer processo preditivo. Para Pellegrini e 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.

Na forma de dados estatísticos, a série histórica de vendas é a informação mais importante, pois permite identificar padrões de venda do produto que podem se repetir no futuro.

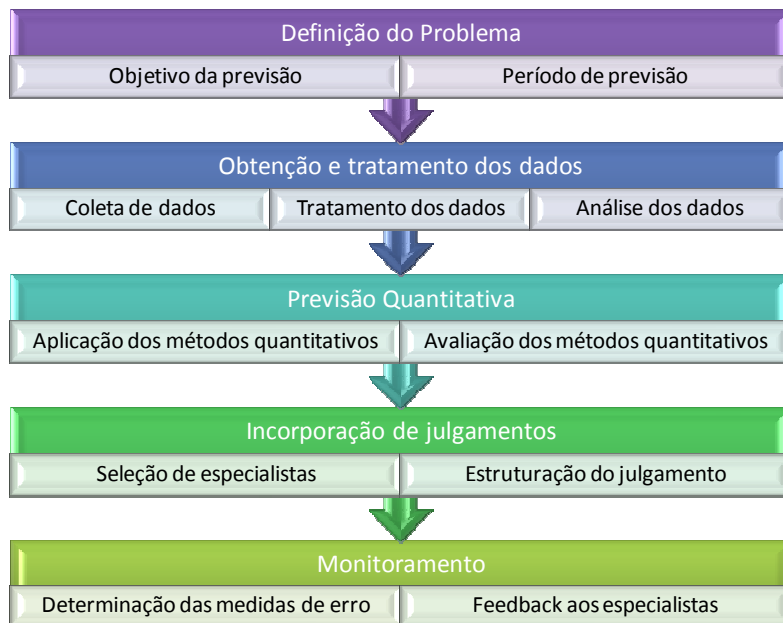


Figura 4-2 Modelo proposto.

Fonte: a autora.

Já as informações contextuais podem ser provenientes de uma série histórica que possa ser relacionada com as vendas do produto (quantitativas), ou de informações que influenciam a demanda, mas não podem ser calculados numericamente, como o conhecimento sobre promoções ou futuros anúncios de concorrentes. Nos casos em que a informação estatística e contextual estão disponíveis e os especialistas tem qualificação para interpretá-las, sugere-se a integração de previsões.

A previsão quantitativa está relacionada com a seleção da técnica de previsão e mensuração do desempenho dos modelos testados. Os métodos que possuem os menores erros, de acordo com as medidas de erro previamente escolhidas, são os candidatos a serem utilizados na elaboração da previsão. Vondouris et al. (2008) explica que em uma situação ideal, o modelo escolhido deve ser testado em dados não incluídos no estágio de desenvolvimento, antes do modelo ser integrado na função de planejamento da demanda.

Após a obtenção da previsão quantitativa deve ser realizada a incorporação de julgamentos. Para isso é necessário escolher os especialistas responsáveis pelos ajustes. Contudo, antes do previsor

realizar o julgamento, deve ser definida uma estrutura que indique a forma como ele deve incorporar a informação contextual.

Para avaliar o desempenho da previsão final são escolhidas medidas de erro que monitoram a acuracidade do modelo. O intuito do monitoramento é avaliar se o método escolhido continua aderente aos dados. Quando isso não condisser com a realidade, deve ser realizada novamente a seleção de técnicas quantitativas que possuam melhor desempenho e/ou rever a forma de incorporação de julgamento.

Nas próximas seções serão discutidos detalhadamente os passos para a execução de cada etapa do processo.

4.2.1 Definição do problema

O primeiro passo na implantação de um sistema de previsão de demanda é a definição do problema. Nesta etapa deve-se identificar quais previsões são necessárias (variável a ser prevista) e avaliar onde e como a previsão se enquadra dentro da organização. Segundo Pellegrini e Fogliatto (2000), a definição do nível de detalhe requerido para o sistema é influenciada por diversos fatores, tais como disponibilidade de dados, acurácia, custo da análise e preferências gerenciais.

O propósito da previsão é fornecer informações para a tomada de decisão, como, por exemplo, para desenvolvimento de produtos, estratégias de marketing, planejamento de capacidade de produção, contratação de recursos humanos, planejamento financeiro, controle de estoques e promoções (LEMOS, 2006).

Os responsáveis pelo processo de previsão devem separá-lo do processo de planejamento para evitar resultados tendenciosos, ou seja, fazer com que metas sejam consideradas previsões. Este princípio é importante e muitas vezes ignorado pelas empresas (ARMSTRONG, 2001).

Uma segunda classe de decisões envolve elementos temporais: o período, horizonte e intervalo de previsão. O período é a unidade básica de tempo em que a previsão é requerida, podendo ser expresso em meses ou semanas. A magnitude do período é o fator que mais influencia na escolha do modelo estatístico a ser utilizado na modelagem das séries. O horizonte é o número de períodos futuros cobertos pela previsão, sendo expresso na mesma unidade temporal do período. Ele está relacionado com a capacidade de resposta da organização. O intervalo é a frequência na qual novas previsões são preparadas, dependendo da estabilidade do processo e das consequências de se estar usando uma previsão obsoleta (PELLEGRINI; FOGLIATTO, 2000).

4.2.2 Obtenção e tratamento dos dados

Para se obter uma previsão de qualidade são necessários dados consistentes e relevantes em relação à variável a ser prevista, pois até bons métodos de previsão falham quando são aplicados dados distantes da realidade.

A aplicação de um método de previsão quantitativo exige dados históricos da variável com um espaço de tempo igual ao período da previsão definido no item anterior. Outras informações relevantes que expliquem comportamentos atípicos das vendas passadas auxiliam na identificação de *outliers*. Além dos dados diretamente relacionados à série temporal, séries históricas e previsões de variáveis correlacionadas são informações importantes para a utilização de métodos causais como a regressão linear.

As informações contextuais também são dados importantes para a implantação do ajuste da previsão estatística. Neste caso, o especialista deve ter acesso a informações como a conjuntura econômica atual, pesquisas sobre comportamento de compra dos clientes, ações de concorrentes, decisões da área comercial como promoções, etc.

Após a obtenção dos dados, a quantidade de informações e séries históricas pode ser muito grande, principalmente em empresas com um grande portfólio de produtos. Portanto, pode ser interessante agregar os produtos em famílias ou utilizando uma classificação, por exemplo, ABC. De acordo com Pellegrini e Fogliatto (2000), a primeira abordagem une os produtos com as mesmas características em uma única série temporal, enquanto a segunda determina a importância do produto, relacionando demanda e seu faturamento. A classificação ABC pode ainda auxiliar na tomada de decisão sobre os investimentos a serem realizados na tarefa de previsão. Para itens compreendidos na classe A, deve-se despendar mais recursos físicos e humanos para aumentar a acuracidade, visto que representam aproximadamente 80% do faturamento da empresa.

Depois dos dados estarem disponíveis é necessário realizar a limpeza dos mesmos, retirando eventos influentes que são de natureza não repetitiva (como promoções), *outliers* e valores faltantes (VONDOURIS et al., 2008).

Ao se plotar um gráfico avaliando o comportamento de uma variável dependente (y) a partir dos dados de uma variável independente (x), observamos que a linha de tendência possui uma distância da maior parte dos pontos de dados. A essa distância denominamos desvio aleatório do modelo. Para identificar possíveis *outliers* avalia-se até

quantos desvios padrões fora da média os dados são normais. O que ultrapassar esse limite e forem identificados como valores que sofreram influência de promoção ou até alguma crise podem ser descartados por fugir da realidade (DEVORE, 2006).

Allemão (2004) utilizou em seu trabalho a curva normal para definir quantos desvios padrões seriam considerados como dados normais. O autor calculou a porcentagem de valores que compreendiam na faixa de um e dois desvios padrões e aquele valor que mais se aproximou do comportamento da curva normal foi considerado como o limite. Para uma distribuição normal é esperado que 68,0% dos dados estejam contidos na faixa $[\bar{x} - s, \bar{x} + s]$ onde \bar{x} corresponde à média e s ao desvio padrão e 95,5% dos pontos estejam contidos na faixa de $[\bar{x} - 2s, \bar{x} + 2s]$. Para exemplificar, no trabalho de Allemão (2004) a porcentagem de valores compreendidos no primeiro desvio padrão foi de 80% e para dois desvios padrões foi de 95%. Portanto, os dados fora do limite de $2s$ foram considerados *outliers*. Outra forma de identificação dos valores espúrios é através da análise gráfica da série. Apesar de ser uma abordagem empírica, ela produz bons resultados.

Os outliers também podem ser denominados como dados espúrios, ruídos ou exceções (ALLEMÃO, 2004). De acordo com Pellegrini e Fogliatto (2001) eles podem surgir de “erros de digitação, falta de produtos, promoções esporádicas e variações no mercado financeiro, entre outras causas”.

Allemão (2004) sugere três alternativas para o tratamento dos valores espúrios: (i) excluir os *outliers*; (ii) interpolar os dados; (iii) nivelar pelo teto (transformar os dados no valor máximo permitido pelos desvios padrões considerados). Armstrong (2001) sugere a substituição dos *outliers* pelo dado confiável mais alto ou mais baixo do histórico. Pellegrini e Fogliatto (2000) apresentam duas técnicas para tratamento dos valores espúrios:

- a. Quando o valor espúrio encontra-se no final da série temporal e existem valores suficientes para gerar um modelo de previsão, substitui-se o valor espúrio pela previsão relativa ao período correspondente ao dado excluído.
- b. Quando o valor espúrio encontra-se no início da série temporal, o procedimento descrito anteriormente torna-se inviável. Uma sugestão para tal situação é fazer a substituição do valor espúrio pela média das observações imediatamente adjacentes a ele, e gerar um modelo de

previsão. Uma vez feita a previsão, o valor espúrio é substituído pela previsão relativa ao período correspondente.

Posteriormente a obtenção das séries de dados sem a influência de valores espúrios, deve-se verificar possíveis padrões existentes na série que auxiliem na escolha do método de previsão quantitativo, como tendências e sazonalidades. Contudo, deve-se observar que muitos itens agregados podem apresentar certa estabilidade nas vendas na forma agrupada, mas quando desagregados demonstram diferentes tipos de demanda. Nesta fase podem-se realizar testes com as informações externas ou dados causais em relação à série temporal da variável.

4.2.3 Previsão Quantitativa

O bom emprego de métodos quantitativos caracteriza-se por ajustar os dados coletados a um modelo de previsão, de modo a minimizar os erros da previsão (WANKE; JULIANELLI, 2006).

A aplicabilidade de um sistema de previsão quantitativo depende de algumas condições. Inicialmente as características da série temporal (como tendências e sazonalidades) podem restringir determinados tipos de métodos que não consideram tais situações. A agregação temporal dos dados também influencia na seleção do modelo, pois, de maneira geral, a aleatoriedade diminui com o agrupamento dos dados. Em situações onde o intervalo de previsões é curto (por exemplo, diários), devem ser evitados modelos complexos, por serem muito trabalhosos e por poderem, potencialmente, tornar o sistema dispendioso. (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998).

Além dos fatores apresentados, o grau de exatidão é muito importante e pode ser analisado sob dois aspectos. Um deles é o desempenho histórico dos erros de um modelo de previsão e o outro é o grau de sensibilidade da previsão em relação a mudanças (JÚDICE, 2005).

Sobre as diversas formas de seleção do método de previsão, De Gooijer e Hyndman (2006) em sua revisão dos 25 anos de previsão de séries temporais apresentam o trabalho de “Gardner e McKenzie (1988), os quais forneceram algumas regras simples baseadas na variância de diferentes séries temporais para escolher o método de suavização exponencial apropriado, além de Tashman e Kruk (1996) que compararam estas regras com outras propostas por Armstrong e Collopy (1992) e uma abordagem baseada no BIC (critério de informação bayesiano)”. Além destes, Santos (2006) utiliza meta aprendizado para escolher o método de previsão e Dias (2004) elabora um sistema especialista. Apesar das diversas abordagens, as medidas de erro de

previsão são as formas mais simples e difundidas para seleção de métodos estatísticos.

Segundo Armstrong (2001), para selecionar um método quantitativo deve ser considerado o nível de conhecimento sobre as relações entre variáveis, a quantidade de mudanças envolvidas, o tipo de dados, a necessidade de análises políticas e a quantidade de domínio de conhecimento. Quando a seleção é difícil, deve-se combinar previsões de diferentes métodos.

A partir da dificuldade de se selecionar um único método surge como alternativa a abordagem *Focus forecasting*. Através dela realiza-se a previsão com diversos métodos e o que obtiver o menor erro médio será usado na previsão da demanda do próximo período (DIAS, 2004). A suposição em fazer este tipo de seleção é a de que o método mais bem sucedido recentemente será o melhor para o período a ser previsto (WILD, 1997).

Porém, como será discutido na seção 4.2.5, nenhuma medida de erro consegue fornecer a verdadeira realidade do desempenho do modelo, sugerindo a mensuração da acuracidade da previsão com diferentes métricas.

4.2.4 Incorporação de Julgamentos

Armstrong e Collopy (1998) apresentam três condições sob as quais a integração de julgamentos e métodos estatísticos devem ser considerados: (i) haver dados quantitativos relevantes; (ii) a introdução de julgamentos que concedem informações diferentes; (iii) julgamentos sem vieses.

Para a introdução de julgamentos enriquecer a previsão é necessário que os especialistas possuam domínio de conhecimento e que haja um conjunto de regras a fim de minimizar os vieses introduzidos por eles. O objetivo, segundo Souza (2008), é o de incluir pessoas no processo que realmente sejam capazes não só de identificar as informações contextuais relevantes, mas também de mensurar seus impactos na série que se deseja prever.

Armstrong e Collopy (1998) afirmam que é comum a crença de que quanto mais informações os especialistas tiverem sobre uma série, melhores ajustes nas previsões eles estarão aptos a realizar. Porém, estudos de laboratório têm concluído que informação adicional pode diminuir a acuracidade. Adicionalmente, em algumas situações no mínimo, a confiança aumenta assim como a acuracidade diminui. Para fugir disto, sistemas de suporte à decisão podem ser usados para estruturar o conhecimento existente.

Algumas formas de estruturação de julgamentos foram apresentadas na seção 3.3 do capítulo 3. Dentre elas, existem métodos simples como: determinar a forma de apresentação dos dados (tabela x gráficos), garantir que os cálculos numéricos estejam corretos, realizar ajuste somente quando o erro for maior que a previsão ingênua, registrar as razões para o ajuste e a acurácia das previsões, listar motivos pelos quais a previsão pode estar errada, realizar feedback aos especialistas. Os modelos mais complexos geralmente utilizam algum sistema de suporte à decisão.

Portanto, cada empresa deve adequar-se à sua realidade, sempre com o objetivo de eliminar as tendências normalmente associadas ao julgamento humano. Os especialistas responsáveis pelos julgamentos, entretanto, tem um papel crucial na aceitação e cumprimento das regras. Por isso, tão importante quanto estruturar o julgamento é definir as pessoas que irão fazê-lo.

Quando se busca realizar ajustes julgamentais de previsão, é amplamente comprovado o poder de contribuição das pessoas que conhecem aspectos relativos tanto do comportamento do mercado quanto da área de negócio ou dos clientes da organização em estudo (WERNER, 2004).

Para assegurar a qualidade do julgamento Webby e O'Connor (1996) concluem que conhecimento contextual é particularmente importante para se fazer boas previsões julgamentais, enquanto que conhecimento técnico tem pouco valor. Isto porque, segundo Sanders e Ritzman (2001), previsões realizadas sem domínio de conhecimento normalmente demonstram que os ajustes deterioram a acuracidade, o que ratifica a sua importância.

Em relação à experiência dos previsores, Gönül, Önkal e Goodwin (2009) afirmam que a senioridade e a experiência dos usuários têm pouco efeito nas suas atitudes ou inclinação a realizar ajustes. Além disso, quanto a qualidade destes ajustes realizados, Webby e O'Connor (2001) afirmam que os especialistas não possuem desempenho melhor que iniciantes somente em situações onde existe pouca informação contextual, que limitam os previsores no uso de suas especialidades.

A seleção dos especialistas pode compreender somente colaboradores da empresa ou também pessoas externas como de universidades, outras empresas públicas ou privadas, instituições. Okoli e Pawlowski (2004) *apud* Souza (2008) descrevem um procedimento para auxiliar na escolha: (i) identificar as habilidades e os conhecimentos considerados relevantes à melhoria da acuracidade das previsões; (ii) identificar “nomenclaturas” das áreas de conhecimento,

para associar pessoas nas quais essas habilidades e conhecimentos estejam contidos, permitindo a construção de uma pré-lista de participantes em potencial; (iii) realizar contato com essas pessoas para que indiquem outros possíveis participantes; (iv) formar um ranking segundo as qualificações destas pessoas, formando a lista final de participantes; (v) convidar as pessoas da lista em ordem decrescente de importância/conhecimento até que o número de participantes seja atingido.

Diversas estruturas organizacionais públicas ou privadas não encaram positivamente a idéia de selecionar e convidar pessoas externas ao quadro de funcionários para contribuir e opinar sobre questões que envolvem decisões estratégicas. Nestes casos, sugere-se que se inicie a busca considerando uma diversidade de cargos e de setores de origem dos participantes. Isso possibilitaria incluir no processo pessoas com diferentes experiências obtendo um grupo com uma visão ampla sobre o problema de estudo, uma vez que ele contaria com diferentes pontos de vista relativos ao aspecto técnico. (OKOLI; PAWLOWSKI, 2004 *apud* SOUZA, 2008).

4.2.5 Monitoramento

Após a implantação do sistema de previsão na empresa é necessário realizar o monitoramento para que os padrões estipulados no modelo sejam mantidos. Segundo Pellegrini (2000), a manutenção do sistema consiste na incorporação de novas informações sobre as variáveis de interesse, obtidas após cada período, e revalidação dos modelos estatísticos inicialmente selecionados para sua previsão futura.

Esse monitoramento é realizado através do cálculo das medidas de erro, abordadas na seção 2.3.1 do capítulo 2. Vondouris et al. (2008) e Armstrong (2001) afirmam que nenhuma medida de erro consegue fornecer a verdadeira realidade do desempenho do modelo; portanto, a acuracidade da previsão precisa ser mensurada com diferentes métricas.

O contínuo monitoramento do sistema de previsão justifica-se, também, por proporcionar um *feedback* a respeito da sensibilidade do previsor. Ainda, ao comparar a previsão do método estatístico e a previsão ajustada pelo previsor com as vendas reais, é possível determinar se o especialista incorre em vieses (WANKE; JULIANELLI, 2006).

Segundo Webby e O'Connor (1996), tem-se descoberto que o *feedback* tem efeitos benéficos no desempenho da tarefa na maioria dos processos de estimação. As diversas formas de *feedback* foram apresentadas na seção 3.3 do capítulo 3. Segundo Lawrence et al.

(2006), o “*outcome feedback*” é o procedimento mais utilizado, por ser o mais simples, porém é o menos efetivo. Como conclusão, Webby e O’Connor (1996) afirmam que apresentar o valor real é menos eficiente do que apresentar um resumo das medidas de erro. Isto porque o último valor verificado não acrescenta aprendizado ao especialista. Como este é o intuito do *feedback*, desta forma ele não alcança seu propósito.

Adicionalmente às medidas de erro, vários vieses da previsão podem ser mensurados e relatados aos previsores. Este tipo de *feedback* detalhado concede aos especialistas um melhor entendimento de sua própria performance (EROGLU; CROXTON, 2010). Para mais informações consultar a bibliografia.

4.3 CONSIDERAÇÕES FINAIS

Neste capítulo apresentou-se um modelo para implantar um método de previsão de demanda em uma empresa. O modelo integra a incorporação de julgamento à saída de previsões estatísticas, baseando-se no método extrapolação corrigida. Devido a sua larga utilização no meio empresarial, delinear-se detalhadamente os passos para a implantação do modelo, considerando assuntos como o tratamento dos dados e desenvolvimento da previsão estatística até formas de estruturar o julgamento do especialista.

No próximo capítulo o modelo proposto será utilizado para implantar um sistema de previsão de demanda em uma pequena empresa.

5 ESTUDO DE CASO

5.1 A EMPRESA EM ESTUDO

O procedimento de previsão sugerido no capítulo anterior será aplicado em uma indústria madeireira de pequeno porte do norte do estado de Santa Catarina. O ramo madeireiro possui um complexo sistema de obtenção e transporte de seu produto, pois a matéria-prima que abastece a empresa provém do estado do Mato Grosso. O maior problema enfrentado é o transporte da madeira no período das chuvas, que é de 150 a 180 dias do ano, já que em determinadas regiões de trajetória dos caminhões as estradas não são devidamente pavimentadas. No ano de 2010, foi implantado o sistema da “piracema da madeira” válido para todos os anos. Nela, o corte, derrubada, extração, arraste e transporte da madeira nas florestas mato-grossenses são proibidos por um período de 60 dias (de 1 de fevereiro a 1 de abril) . A Sema, Secretaria de Estado de Meio Ambiente, está estudando a possibilidade de aumentar este período em mais 30 dias a partir de 2011. Esse sistema foi implantado com base na resolução 406/2009 do Conselho Nacional de Meio Ambiente (Conama) (fonte: <http://www.mma.gov.br/port/conama/legiabre.cfm?codlegi=597>) e tem a preocupação de evitar a degradação do solo no período sazonal de chuvas. As vias abertas dentro da floresta, muitas vezes não-pavimentadas, são mais suscetíveis aos efeitos mecânicos com o trânsito de máquinas e caminhões, fato que justifica a necessidade de proibir a utilização destes maquinários para extração da madeira nesse período.

Esta determinação força os fornecedores de madeira a armazenarem uma grande quantidade de insumos para suprir o mercado nos meses em que a piracema ocorre. Alguns madeireiros possuem manejos aprovados para poderem trabalhar normalmente nesse período restritivo das águas. Nestes casos, estas empresas possuem uma esplanada declarada na Sema que autoriza o transporte da madeira após a efetiva implantação da estrutura viária (estradas cascalhadas) prevista nos projetos de manejo.

As matérias-primas são transportadas via terrestre por caminhões que carregam de 34 a 53 toneladas por viagem. A medida padrão utilizada para compra e venda de madeira é metros cúbicos (m^3). A relação de quilogramas e metros cúbicos (kg/m^3) para madeira seca corresponde a $900 kg/m^3$ e para madeira verde de 1200 a $1400 kg/m^3$.

As matérias-primas adquiridas pela empresa para industrialização são pranchas, tábuas e vigas de madeira, recebidas com diferentes

dimensões de largura, espessura e comprimento. Elas são transformadas em inúmeros itens industrializados na madeireira, como: rodapés, tabeiras, batentes de portas, assoalhos, forros, decks e outros. O tempo de produção é de dois a três dias, dependendo da quantidade. Em virtude da rotatividade normal dos produtos e do estoque regulador que a empresa tem, são realizados pedidos de reabastecimento conforme a necessidade. Após a realização de um pedido ao fornecedor, a entrega ocorre em até 8 dias para cada espécie de madeira ou essência. Já quando o consumidor final faz um pedido de produto especial, levam-se em média 20 dias para atendê-lo.

A empresa não possui um sistema de previsão de demanda nem de gestão de estoques estruturado, apenas um cronograma de fluxo de produtos, atualizado diariamente, que informa as necessidades ao fornecedor. Este cronograma provém de uma avaliação empírica dos níveis de estoque e vendas realizadas a clientes. Quando ocorre uma tendência de crescimento repentino nas vendas, aumentam-se os níveis de estoque para a empresa ganhar com a disponibilidade de produtos. Caso a tendência não se confirme, o resultado é uma grande quantidade de estoque parado.

Na continuidade do capítulo, serão realizados os passos do procedimento proposto para implantação de um método de previsão de demanda na empresa.

5.2 DEFINIÇÃO DO PROBLEMA

Em função do contexto da empresa e de suas necessidades, o estudo de caso fará a previsão de vendas das principais matérias-primas comercializadas. Esta decisão foi embasada na seguinte conjuntura:

- A empresa possui um estoque maior de insumos pelo *lead time* produtivo ser menor que o tempo de reabastecimento de produtos;
- Existe uma variedade de itens finais produzidos a partir da mesma matéria-prima;
- A empresa demonstrou maior interesse na previsão de matérias-primas por ter dificuldade nesta área.

As previsões serão realizadas mensalmente devido a disponibilidade dos dados e adequação com a realidade da empresa. Um período menor que o proposto inviabiliza futuramente a manutenção das previsões pela empresa. Além disso, segundo Pellegrini e Fogliatto (2000) a aleatoriedade diminui com o agrupamento dos dados. O

horizonte de previsão também será mensal, pois um intervalo maior dificulta a incorporação de julgamentos realizada pelo especialista.

5.3 OBTENÇÃO E TRATAMENTO DOS DADOS

5.3.1 Coleta de dados

A aquisição dos dados foi realizada através de um relatório mensal de faturamento no período de janeiro de 2005 a agosto de 2010. A descrição dos dados acontece em R\$/tipo de madeira. Obteve-se o preço médio anual de venda para cada classe de madeira em cada ano do período avaliado. A divisão da quantidade faturada (em R\$) pelo preço médio de venda (R\$/m³) originou as quantidades vendidas de cada matéria-prima em metros cúbicos. Cada espécie de madeira possui bitolas padrões de compra, e, a partir delas, são formados inúmeros itens de produtos finais. Contudo, o estudo focará somente a previsão de demanda das matérias-primas de maior giro, visto que uma vez existindo o insumo em estoque, a madeira pode ser desdobrada em diversos itens finais com *lead time* menor que o de entrega de matéria-prima.

5.3.2 Curva ABC

Após a obtenção dos dados de vendas mensais no período de 2005 a 2009, foi realizada a classificação ABC dos produtos. Esta ação separou as espécies de madeira com maior giro, para as quais foram realizadas as previsões mensais. O quadro 5-1 demonstra o resultado para a quantidade vendida em metros cúbicos (unidade padrão para as previsões neste estudo).

Madeira	Venda (m ³ /mês)	% Venda/mês	Curva ABC	Classificação	% Produtos
Peroba	3.420,12	31,6%	31,6%	A	27%
Itaúba	2.961,42	27,4%	59,0%	A	
Cambará	2.597,96	24,0%	83,0%	A	
Garapeira	643,78	6,0%	89,0%	B	27%
Pinus	598,97	5,5%	94,5%	B	
Cedrinho	444,06	4,1%	98,6%	B	
Angelim	69,31	0,6%	99,3%	C	45%
Ipê	38,23	0,4%	99,6%	C	
Canelão	25,06	0,2%	99,8%	C	
Jatobá	10,39	0,1%	99,9%	C	
Sucupira	7,11	0,1%	100,0%	C	
TOTAL	10.816,42	100,0%			

Quadro 5-1 Classificação ABC das matérias primas (em m³/mês).

Conforme exposto no quadro 5-1, a peroba, itaúba e cambará compõe o grupo de produtos de maior giro, identificados pela metodologia como classe A. Eles correspondem a 83% do faturamento da empresa (coluna ‘curva ABC’) e a 27% do total de matérias-primas comercializadas (coluna ‘% Produtos’).

As madeiras classificadas no grupo B e C correspondem a 17% da quantidade comercializada pela empresa. Como o giro é pequeno, no histórico de vendas ocorrem diversos meses em que a sua venda é nula. Além disso, normalmente os pedidos destes itens entram na classificação de “pedidos especiais”, que são feitos sob encomenda, com prazos negociados com clientes. Como a previsão de produtos intermitentes (de demanda nula) requer a análise de métodos de previsão específicos, estas matérias-primas não são avaliadas neste trabalho. Portanto, as espécies de madeira foco deste estudo são peroba, itaúba e cambará.

5.3.3 Tratamento dos dados

Após a classificação dos produtos, avaliou-se a existência de *outliers* para a série histórica de cada uma das três matérias-primas. Realizou-se, inicialmente, uma pré-análise dos dados coletados com o gerente da empresa a fim de eliminar possíveis ruídos advindos de erros de digitação ou falhas de sistema. Identificou-se um mês (janeiro/2009) onde ocorreu um erro no sistema e os valores vendidos ficaram distorcidos. Contudo, o gerente possuía os valores originais e os dados foram corrigidos.

Depois da série histórica conter somente informações que condizem com a realidade da empresa (sem erros do sistema), produziu-se gráficos com as séries temporais (vendas $m^3/mês$) dos produtos escolhidos conforme demonstra a figura 5-1, figura 5-2 e figura 5-3. Adicionaram-se as linhas de um, dois e três desvios padrões com o intuito de simplificar a identificação de outros dados espúrios.

Pode-se observar nas três séries temporais uma grande irregularidade na demanda. Segundo o gerente da empresa, as variações do mercado ocorrem constantemente ao longo dos meses, causando algumas vezes falta de determinados produtos e excesso de outros. Apesar de alguns picos e declives da demanda poderem ser vistos como atípicos, originando *outliers*, a empresa vê isto com naturalidade, afirmando ser a forma como se comporta o mercado em que atua.

Para determinar o limite máximo e mínimo para a série de dados será utilizada a adequação do percentual de valores históricos em relação ao número de desvios padrões da curva normal, conforme o

trabalho de Allemão (2004) descrito na seção 4.2.2. Para uma distribuição normal espera-se que 68,26% dos dados estejam no intervalo $[\bar{x} - s, \bar{x} + s]$; 95,44% estejam contidos no intervalo $[\bar{x} - 2s, \bar{x} + 2s]$ e 99,74% no intervalo $[\bar{x} - 3s, \bar{x} + 3s]$, em que \bar{x} corresponde à média e s ao desvio padrão.

O percentual de valores contidos na faixa de dois desvios padrões da madeira itaúba foi de 98,3%, para a peroba 97,7% e para o cambará foi de 95%. Caso fosse escolhido o limite de um desvio padrão muitos dados seriam considerados como *outliers*, o que distorceria a série. Já considerando os limites dos dados três desvios padrões permitir-se-ia uma grande variabilidade dos dados, dificultando a utilização de métodos de previsão quantitativos. Além disso, poucos dados ficaram concentrados no intervalo de dois e três desvios padrões. Conforme Wanke e Julianelli (2006) valores muito diferentes em módulo que os outros pontos, de três a quatro desvios padrões da média, são *outliers* em potencial.

Por estes motivos, os dados de vendas que ultrapassaram (para mais ou para menos) o valor de dois desvios padrões foram identificados como espúrios e tratados antes de serem utilizados.




Figura 5-1 Gráfico do histórico de demanda com desvios padrões – madeira Itaúba.

Como pode ser observada na série temporal da itaúba, figura 5-1, somente em março de 2008 ocorreu uma venda de $92,48\text{m}^3$, acima dos dois desvios padrões ($89,63\text{m}^3$) estabelecidos como limite. Existem ao longo da série variações abruptas da demanda. Por este motivo, foram utilizadas abordagens para o tratamento de *outliers* que pouco alteraram o comportamento da série. Por exemplo, o procedimento de Pellegrini e Fogliatto (2000) descrito no capítulo 4, seção 4.2.2, substituiu o valor

discrepante pela média dos meses adjacentes. Porém, para o caso da itaúba (assim como para a peroba e o camarã), esta média irá alterar substancialmente o valor ocorrido. Além disso, como serão testados diversos métodos quantitativos todos os meses (método *Focus Forecasting*), fica difícil substituir a média pela previsão encontrada.

Portanto, para os valores identificados como *outliers* em todas as séries utilizou-se a abordagem de Allemão (2004), substituindo o valor pelo teto (máximo ou mínimo) estabelecido, neste estudo de caso, dois desvios padrões para as três madeiras estudadas. O valor do pico da itaúba foi substituído por $92,48 \text{ m}^3$, valor relativo a dois desvios padrões.



Figura 5-2 Gráfico do histórico de demanda com desvios padrões – madeira Peroba.

Na série histórica da madeira peroba, figura 5-2, encontram-se dois picos de venda nos meses de abril e junho de 2007. Nestes casos, os dois valores foram alterados para $114,92 \text{ m}^3$.




Figura 5-3 Gráfico do histórico de demanda com desvios padrões – madeira Camará.

No histórico de vendas do camará, figura 5-3, ocorrem exceções em três momentos: julho de 2005, janeiro de 2009 e abril de 2009. Como o primeiro *outlier* ocorreu no início da série, o dado foi excluído para os métodos de previsão que não dependiam deste valor conforme Allemão (2004), (seção 4.2.2). Como testou-se inúmeros métodos quantitativos, para aqueles que necessitaram deste dado, como decomposição aditiva e multiplicativa, substituiu-se pelo teto de dois desvios padrões, $85,05m^3$. O mesmo tratamento foi aplicado aos valores de janeiro e abril de 2009.

5.3.4 Análise dos dados e informações causais

Em discussões assistemáticas com o gerente da empresa, procurou-se conhecer os fatores externos (causais) que influenciam o comportamento das vendas e pudessem auxiliar no processo de previsão. O mesmo manifestou a crença de que após um período de chuvas (uma semana, por exemplo) as vendas do período seguinte (próxima semana) ficam comprometidas, visto que as obras civis não conseguem dar continuidade aos trabalhos externos nestes dias.

Portanto, realizou-se uma avaliação comparativa da quantidade de chuvas (mm de chuva/semana(t)) com a venda no período seguinte (t+1) através de uma regressão linear. Pretendeu-se, desta forma, conhecer qual o percentual de redução nas vendas provocada pela chuva, para posteriormente utilizar esta informação na previsão de períodos futuros.

Para plotar o gráfico de regressão obteve-se o histórico de chuvas da região semanalmente no período de setembro de 2009 a fevereiro de 2010 através do site do INMET (Instituto Nacional de Meteorologia) www.inmet.gov.br com link direto www.inmet.gov.br/sim/sonabra. Adicionalmente, a empresa em estudo forneceu relatórios semanais de vendas, no mesmo período levantado para as chuvas.

A figura 5-4 demonstra o resultado da relação entre as chuvas no período (t) com as vendas das três madeiras (itaúba, peroba e camará) no período (t+1). Como se pode observar, o R^2 é muito baixo, caracterizando a inexistência de relação entre as variáveis. Outra análise foi realizada considerando-se as mesmas variáveis para o período mensal. A figura 5-5 demonstra o resultado, confirmando a conclusão anterior.




Figura 5-4 Regressão linear (mm de chuva na semana (t) x quantidade vendida semana (t+1)).




Figura 5-5 Regressão linear (mm de chuva no mês (t) x quantidade vendida no mês (t+1)).

Outras tentativas foram analisadas, como a chuva *versus* as vendas para cada tipo de madeira separadamente; os dados de chuva e venda com os mesmos períodos de tempo (ex: chuva (t) x venda(t)); a chuva *versus* as vendas totais da empresa; chuva no mês j para os anos do histórico *versus* vendas no mês j para os anos do histórico (estas tentativas estão no apêndice A).

Um exemplo da última tentativa descrita no parágrafo anterior está demonstrado na figura 5-6. Este gráfico relaciona as chuvas do mês de agosto nos anos de 2005 a 2009 com as respectivas vendas do mês de agosto nos anos de 2005 a 2009. Assim como na figura 5-6, foram realizados testes para todos os meses do ano buscando encontrar resultados adequados de R^2 . Por fim, de todas as simulações a única relação encontrada entre chuvas e vendas foi no mês de agosto, conforme mostra a figura 5-6. No gráfico pode-se verificar que nos anos onde ocorreu grandes quantidades de chuva (aprox. 225 mm) as vendas caem pela metade (100 m^3) quando comparados a anos com pouca chuva (por exemplo, para aprox. 75 mm de chuva as vendas giram em torno de 200 m^3).




Figura 5-6 Regressão linear (chuva no mês de agosto nos anos 2005 a 2009 x vendas no mesmo período).

Como o fator de correlação indica que existe impacto das chuvas nas vendas do mês de agosto, essa informação será levada ao previsor juntamente com a previsão de chuvas para o mês. Será avaliado como estas informações contextuais influenciam o previsor no seu ajuste por julgamento. Contudo, pode-se concluir que as chuvas não influenciam as vendas na grande maioria dos casos.

Além da conexão entre chuvas e vendas, de acordo com a percepção do gerente, a venda dos três tipos de madeiras tem relação inversamente proporcional. Ou seja, quando ocorre aumento nas vendas de uma matéria-prima, conseqüentemente, outras espécies decaem. Porém, o gerente não soube afirmar em quais tipos de madeira este fato ocorria.

Para avaliar se existe matematicamente uma relação inversamente proporcional entre as vendas dos tipos de madeira, confeccionaram-se

gráficos confrontando o histórico de vendas das espécies para o mesmo período de tempo. A figura 5-7 demonstra um exemplo entre as vendas da peroba e do camarã, concluindo a inexistência de relação matemática entre as vendas das madeiras. Os resultados foram idênticos para as regressões lineares formuladas para as outras madeiras. Os gráficos são encontrados no apêndice A deste trabalho.




Figura 5-7 Avaliação relação vendas peroba x vendas camarã.

Após a classificação ABC e adequação dos *outliers*, analisaram-se os dados das séries. As figuras figura 5-8, figura 5-9 e figura 5-10 demonstram o histórico de vendas de 2005 a 2009 das três madeiras selecionadas: itaúba, peroba e camarã. Incluiu-se uma linha de tendência em cada gráfico para avaliar a existência da mesma ao longo do tempo, sugerindo algum método de previsão específico. Verifica-se que para o camarã e a peroba existe uma leve tendência de crescimento, ao contrário da itaúba que possui tendência de decréscimo nas vendas. Portanto, métodos de previsão com incorporação da variável de tendência devem ser utilizados para elaborar as previsões.

Após uma análise visual dos gráficos constata-se que a demanda dos três tipos de madeira possuem grande variabilidade, não sendo possível concluir inicialmente a existência de padrões de sazonalidade.




Figura 5-8 Série histórica Cambará sem *outliers*.




Figura 5-9 Série histórica Peroba sem *outliers*.




Figura 5-10 Série histórica Itaúba sem *outliers*.

5.4 PREVISÃO QUANTITATIVA

5.4.1 Aplicação dos métodos quantitativos

Uma planilha Excel[®] foi criada para cada madeira agregando-se diversos métodos quantitativos, tais como: previsão ingênua, média simples, média móvel dois períodos, média móvel quatro períodos, média móvel seis períodos, média móvel dupla, média móvel ponderada, decomposição aditiva, decomposição multiplicativa, suavização exponencial simples, método de Brown, método de Holt. Utilizou-se a planilha eletrônica para a elaboração das previsões por ser uma ferramenta existente na empresa. O objetivo de aplicar métodos simples de previsão foi visando uma continuidade, por parte da empresa, na utilização das previsões após o término deste trabalho. Por não possuir uma estrutura ampla, torna-se importante utilizar modelos de fácil entendimento e de baixo custo de manutenção.

Todos estes métodos implantados nas planilhas foram apresentados no capítulo 2. As previsões de demanda foram realizadas mensalmente de dezembro de 2009 a agosto de 2010, sendo avaliadas através de medidas de erro. Os erros foram mensurados através da média móvel dos quatro meses anteriores. A forma de avaliação das previsões será tratada na próxima seção.

Para os métodos que possuem índices de suavização (média móvel ponderada, suavização exponencial, Brown e Holt) utilizou-se a ferramenta Solver do programa Excel[®] para encontrar os valores dos índices de forma que o erro percentual absoluto médio (MAPE) fosse minimizado. Repetiu-se este procedimento todos os meses, a cada nova previsão mensal.

Contudo, a ferramenta Solver converge para ótimos locais de acordo com os valores iniciais dos coeficientes de amortização, não sendo possível garantir o ótimo global. Para tentar minimizar a possibilidade de convergência em ótimos locais indesejados, realizou-se no trabalho uma combinação de valores iniciais para as variáveis de interesse a fim de escolher os melhores resultados com os menores erros de previsão. A escolha dos valores iniciais teve como objetivo abranger a maior quantidade de pontos da função, avaliando, portanto, valores extremos e médios.

A quantidade de valores iniciais testados depende do número de coeficientes de amortização. Como pode ser visto no quadro 5-2, para os métodos com somente um coeficiente (Brown e suavização exponencial), apenas três valores iniciais foram testados (0,1; 0,5; 0,9). A linha destacada para o mês de julho no quadro 5-2 refere-se à

simulação de coeficientes com o menor erro (10,3%). Já para o mês de agosto as respostas convergiram para o mesmo coeficiente (alfa igual a 0,27). Não foram realizados mais testes para obter um melhor ajuste próximo do melhor valor de alfa (no exemplo do quadro 5-2 alfa é 0,1) para não tornar o processo muito oneroso com poucas melhorias de acurácia.

	Valores iniciais	Convergência	
	alfa	alfa	Erro %
Julho	0,1	0,073	10,3%
	0,5	0,296	13,5%
	0,9	0,296	13,5%
Agosto	0,1	0,27	13,8%
	0,5	0,27	13,8%
	0,9	0,27	13,8%

Quadro 5-2 Valores iniciais e de convergência dos coeficientes de amortização do método Brown – madeira peroba.

Para os métodos com dois e três coeficientes de amortização (Holt e média móvel ponderada, respectivamente) são necessários mais testes devido a combinação possível entre os valores iniciais. O quadro 5-3 e quadro 5-4 demonstram o exposto, sendo as duas primeiras colunas as combinações realizadas. Os valores dos coeficientes de amortização em todas as previsões deste trabalho (menos para média móvel ponderada) foram limitados ao intervalo $0,01 \leq \alpha \leq 0,99$ conforme Samohyl, Souza e Miranda (2007). A média móvel ponderada não possui estes limites por ser interessante um resultado que ignore um dos meses analisados (o mês não considerado no cálculo possui coeficiente igual a zero).

O resultado dos testes realizados mostra qual coeficiente resulta no menor erro percentual (menor valor da coluna ‘Erro %’ na parte ‘Convergência’). Por exemplo, no quadro 5-3, para o método de Holt, o menor erro alcançado é 11,1% (linha destacada), obtido em somente uma simulação. Já no quadro 5-4, para o método média móvel ponderada, o menor erro (39,4%) apareceu como resultado da maioria dos testes. Estes coeficientes que correspondem aos menores erros são utilizados para realizar a previsão do mês.

Madeira Peroba - Mês de Março - Método: HOLT				
Valores iniciais		Convergência		
alfa	beta	alfa	beta	Erro %
0,1	0,1	0,085	0,126	11,6%
0,1	0,5	0,070	0,999	15,6%
0,1	0,9	0,070	0,999	15,6%
0,5	0,1	0,187	0,001	15,7%
0,5	0,5	0,187	0,001	15,7%
0,5	0,9	0,421	0,999	29,4%
0,9	0,1	0,187	0,001	15,7%
0,9	0,5	0,065	0,160	11,1%
0,9	0,9	0,070	0,999	15,6%

Quadro 5-3 Valores iniciais e de convergência dos coeficientes de amortização do método Holt – madeira peroba.

Madeira Cambará - Mês de Agosto - Método: Média Móvel Ponderada							
Valores iniciais				Convergência			
alfa	beta	gama	Erro %	alfa	beta	gama	Erro %
0,1	0,1	0,8	46,8%	0,364	0,636	0	39,4%
0,1	0,8	0,1	41,8%	0,364	0,636	0	39,4%
0,8	0,1	0,1	56,4%	0,364	0,636	0	39,4%
0,5	0,2	0,3	45,9%	0,364	0,636	0	39,4%
0,5	0,3	0,2	44,5%	0,364	0,636	0	39,4%
0,3	0,5	0,2	41,2%	0,364	0,636	0	39,4%
0,3	0,2	0,5	45,6%	0,006	0,466	0,527	41,3%
0,2	0,3	0,5	44,0%	0,0106	0,4682	0,521	41,3%
0,2	0,5	0,3	41,1%	0,364	0,636	0	39,4%
0	0	1	57,1%	0,364	0,636	0	39,4%
0	1	0	43,3%	0,364	0,636	0	39,4%
1	0	0	64,8%	0,364	0,636	0	39,4%

Quadro 5-4 Valores iniciais e de convergência dos coeficientes de amortização do método Média móvel ponderada – madeira cambará.

5.4.2 Avaliação dos métodos quantitativos

A escolha do modelo quantitativo pode ser realizada de duas formas. A primeira delas é através da utilização de um histórico que avalia com qual método e quais coeficientes de amortização (nos métodos que possuem) obtêm-se o menor erro. A partir desta decisão monitora-se somente os erros para avaliar o desempenho do processo, o método e os parâmetros permanecem fixos. A segunda abordagem está baseada na teoria do *Focus Forecasting*. Nela, a escolha do método de

previsão e a determinação dos parâmetros é dinâmica, ocorrendo a cada período. Desta forma, ao invés de monitorar os erros de previsão a cada período avalia-se o método e os coeficientes que fornecem a previsão.

Devido a variabilidade dos dados observados na seção 5.3.4, optou-se utilizar durante o trabalho o modelo dinâmico, por se acreditar que os modelos clássicos implantados não teriam aderência adequada aos dados.

Para a aplicação do *Focus Forecasting*, as previsões são elaboradas no primeiro dia de cada mês, após o recebimento do relatório mensal de faturamento. Todas as planilhas com os métodos quantitativos são atualizadas gerando as previsões. O resultado é o quadro 5-5, onde se define o melhor método de previsão para o mês. Os métodos de previsão são avaliados em cada período a partir de quatro medidas de erro, quais são: erro médio absoluto (MAD), erro quadrado médio (MSE), erro percentual absoluto médio (MAPE) e U de Theil. Utilizou-se a média móvel dos últimos quatro meses para mensurar os erros de cada método quantitativo.

Nas colunas do quadro 5-5 estão dispostos os erros de previsão, cada sigla correspondendo a um erro de previsão conforme demonstrado no parágrafo anterior. As linhas identificam os métodos de previsão avaliados e as siglas correspondem, respectivamente: ‘Ingênua’- Previsão ingênua; ‘MSimples’- Média simples; ‘MM2P’- Média móvel dois períodos; ‘MM4P’- Média móvel quatro períodos; ‘MM6P’- Média móvel seis períodos; ‘MMDupla’- Média móvel dupla; ‘Decomp. Adit.’- Decomposição aditiva; ‘Decomp. Mult.’- Decomposição multiplicativa; ‘MMPond’- Média móvel ponderada três períodos; ‘SExpon.’- Suavização exponencial simples; ‘Brown’- método de Brown; ‘Holt’- método de Holt.

Método / Erro	MAD	MSE	MAPE	U de Theil
Ingênua	25,27	779,0	53,4%	1,00
MSimples	15,39	318,1	26,6%	0,56
MM2P	23,91	702,1	47,3%	0,86
MM4P	18,07	467,1	31,9%	0,71
MM6P	17,89	414,7	31,5%	0,69
MMDupla	20,58	563,2	38,0%	0,86
Decomp. Adit.	15,29	266,6	30,1%	0,48
Decomp. Mult.	14,91	256,1	27,6%	0,55
MMPond	16,80	450,7	25,6%	0,79
SExpon.	15,16	309,6	26,6%	0,55
Brown	14,05	254,8	27,5%	0,43
Holt	9,94	173,3	20,7%	0,28

Quadro 5-5 Planilha de avaliação mensal dos métodos de previsão Cambará - junho.

O critério para escolha do melhor método está naquele que possuir os menores valores na maioria das medidas de erro. Para isso, são escolhidos os quatro menores valores para cada medida de erro (estão em negrito na tabela). No exemplo do quadro 5-5, o método de Holt (linha destacada) possui os menores valores de erro nas quatro medidas. Portanto, este é o método escolhido para o mês. Os métodos que ficam em segundo e terceiro lugar na classificação (no exemplo do quadro 5-5, Brown e Decomp. Mult.) também são apresentados ao gerente como alternativas de bons resultados.

Nos casos em que o último valor de erro a ser incluído ocorrer mais de uma vez escolhem-se cinco valores de erro ao invés de quatro. Por exemplo, a medida MAPE no quadro 5-6 possui como último valor escolhido 7,8%. Porém, como este valor ocorre em dois métodos de previsão, selecionou-se cinco medidas ao invés de quatro.

Como mostra o quadro 5-6 podem ocorrer situações onde mais de um método possui a pontuação máxima: menores erros nas quatro medidas. No exemplo, a média móvel quatro períodos, o método de Holt e suavização exponencial estão empatados. Nestes casos, o desempate ocorre no modelo que possui o menor erro percentual absoluto médio (MAPE). Adotou-se este padrão por esta medida ser a mais utilizada na avaliação de métodos quantitativos. Portanto, o método de Holt foi escolhido para a previsão de agosto da madeira itaúba e os métodos MM4P e SExpon (2º e 3º lugares) são apresentados como alternativas ao especialista.

Método / Erro	MAD	MSE	MAPE	U de Theil
Ingênua	4,22	39,0	15,3%	1,00
MSimples	21,86	482,5	78,2%	4,51
MM2P	3,76	16,8	13,5%	0,87
MM4P	0,72	0,9	2,6%	0,21
MM6P	2,31	6,2	8,2%	0,47
MMDupla	3,13	11,9	11,0%	0,67
Decomp. Adit.	38,41	1494,3	137,3%	8,07
Decomp. Mult.	39,23	1561,8	140,2%	8,27
MMPond	2,31	10,5	7,8%	0,72
SExpon.	2,18	6,5	7,8%	0,49
Brown	2,04	7,7	6,9%	0,60
Holt	0,70	1,0	2,4%	0,22

Quadro 5-6 Planilha de avaliação método de previsão – mês de agosto – Itaúba.

Utilizando o método exposto determinaram-se todos os meses os métodos de previsão quantitativos. Pode-se visualizar na figura 5-11, figura 5-12 e figura 5-13 a comparação da previsão quantitativa e o valor real de vendas ocorrido nos meses da pesquisa. Verifica-se que para todas as madeiras houve situações em que a previsão quantitativa não conseguiu acompanhar as oscilações da demanda, gerando grandes erros.

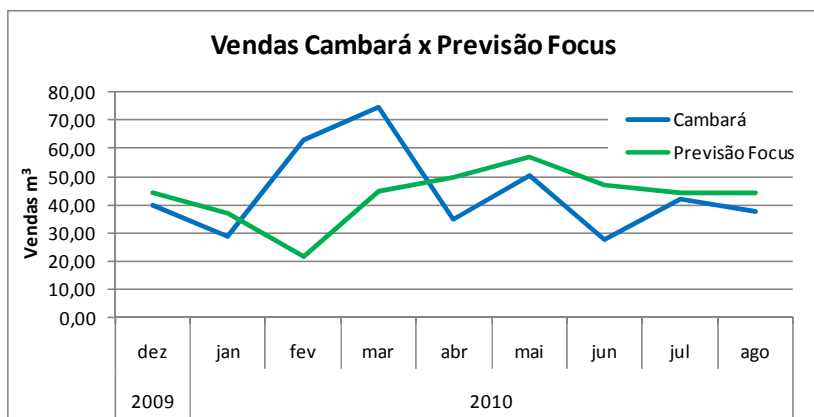


Figura 5-11 Comparativo da previsão quantitativa e as vendas mensais do Cambará.




Figura 5-12 Comparativo da previsão quantitativa e as vendas mensais da Peroba.




Figura 5-13 Comparativo da previsão quantitativa e as vendas mensais da Itaúba.

No quadro 5-7 demonstram-se os métodos selecionados a cada mês. Verifica-se que diversos métodos foram escolhidos mais de uma vez durante o estudo. Esta constatação incitou um comparativo entre o desempenho do modelo dinâmico implantado e a utilização de um modelo único, demonstrando que alguns métodos de previsão sobressaíram-se em relação ao modelo dinâmico proposto nesta dissertação. O resultado desta análise pode ser visto no apêndice B.

Mês	Método de previsão quantitativo escolhido		
	Itaúba	Cambará	Peroba
dez/09	Holt	SExpon.	MMDupla
jan/10	Brown	Holt	MMDupla
fev/10	MM6P	Holt	MMPond
mar/10	Holt	MM6P	Holt
abr/10	MMDupla	Decomp. Mult.	MMPond
mai/10	Holt	Decomp. Adit.	Holt
jun/10	MMDupla	Holt	MMPond
jul/10	MM6P	SExpon.	Holt
ago/10	Holt	Holt	MMPond

Quadro 5-7 Métodos de previsão selecionados mensalmente.

O quadro 5-8 apresenta os erros de previsão mensais para cada tipo de madeira. A madeira cambará foi a pior de ser prevista, com média de erro 32,7%. A seguir, serão realizados os ajustes destas previsões com o intuito de incorporar fatores ainda não considerados que melhorem seu desempenho.

Mês	MAPE - Previsão Quantitativa		
	Itaúba	Cambará	Peroba
dez/09	44%	11%	18%
jan/10	3%	30%	39%
fev/10	33%	66%	7%
mar/10	53%	40%	32%
abr/10	17%	42%	15%
mai/10	4%	13%	13%
jun/10	13%	69%	12%
jul/10	9%	5%	25%
ago/10	57%	18%	61%
Média	25,9%	32,7%	24,7%

Quadro 5-8 Erros de previsão dos métodos quantitativos.

5.5 INCORPORAÇÃO DE JULGAMENTOS

5.5.1 Estruturação do julgamento

A análise quantitativa da série demonstrou que os dados em estudo possuem alta variabilidade, o que dificulta a identificação de padrões como tendências e sazonalidades. Adicionalmente, torna-se árdua a determinação de um método que consiga captar estas

instabilidades e promova boas previsões. Dentro deste contexto a incorporação de julgamentos de especialistas torna-se essencial para avaliar e traduzir informações externas em alterações no comportamento da demanda. Em função do exposto, Armstrong e Collopy (1998) afirmam que diversos estudos encontraram melhorias quando o ajuste por julgamento foi realizado em séries que possuíam alta variabilidade. Um exemplo destes estudos é o de Sanders e Ritzman (1992) *apud* Webby e O'Connor (1996), no qual concluem que julgamento contextual do especialista é mais eficiente para as séries com alta variabilidade, visto que identificaram um significativo efeito de iteração entre o conhecimento contextual e a variabilidade dos dados.

Verificada a necessidade da introdução do julgamento determinou-se a maneira de realizá-lo. Inicialmente, o especialista incorpora o julgamento à saída da previsão quantitativa, conforme apresentado no modelo proposto do capítulo 4. Estes ajustes podem ser realizados aumentando ou diminuindo o valor da previsão, de acordo com as informações obtidas e a percepção do especialista sobre o mercado.

Os dados mensais foram apresentados em tabelas, demonstrando o histórico de vendas dos últimos meses, a previsão quantitativa selecionada no mês e o ajuste realizado pelo próprio especialista nos meses anteriores juntamente com o seu desempenho mensurado através do erro percentual absoluto médio (MAPE). Na seção 5.5.3 será apresentado com mais detalhes este assunto.

Além de registrar e dar *feedback* sobre a acurácia das previsões, sempre que ajustes são realizados solicita-se ao especialista que justifique o valor alterado nos casos em que há um motivo.

5.5.2 Escolha de especialistas

A escolha da pessoa para realizar os julgamentos foi uma tarefa de baixa complexidade. Visto que a empresa em estudo poucos funcionários por ser de pequeno porte, é comum verificar o acúmulo de funções em um só cargo, não havendo uma disseminação de tarefas. No caso, o gerente da empresa é o responsável por avaliar os níveis de estoque e, conseqüentemente, a necessidade de pedidos de matéria-prima, além de verificar se as vendas estão ocorrendo dentro do esperado. Portanto, ele será o especialista que realizará a incorporação de julgamentos nas previsões quantitativas.

5.5.3 Aplicação dos ajustes por julgamento

As previsões quantitativas foram elaboradas no início de cada mês e levadas ao especialista para que realizasse, ou não, ajustes. A figura 5-14 mostra as informações apresentadas ao gerente para a madeira cambará. Cada mês foram apresentadas três planilhas como esta, uma para cada espécie de madeira. Nesta seção serão demonstrados os ajustes realizados para a madeira Cambará. A descrição dos ajustes por mês para a itaúba e peroba estão no Apêndice C deste trabalho.

O primeiro mês da aplicação dos ajustes foi dezembro de 2009 como mostra a figura 5-14. Por ser o primeiro mês da previsão, não havia informações sobre ajustes realizados e por isso a coluna ‘Previsão Ajustada (2)’ está em branco. Para disponibilizar dados que pudessem auxiliar na confiabilidade do método apresentado agregou-se as vendas da madeira cambará do mês de maio até novembro e as respectivas previsões com os erros associados (colunas ‘Venda Cambará m³’, ‘Previsão SExpon. (1) e MAPE (1)'). Nos meses seguintes o erro foi associado à previsão ajustada, alterando-se a nomenclatura para MAPE (2). A numeração dos títulos das colunas serve para identificar a partir de que valor de previsão está sendo calculado o erro.

Além da tabela principal com o valor da previsão do método quantitativo escolhido, incluiu-se o valor da previsão dos métodos que ficaram em segundo e terceiro lugares na classificação mensal. Esta área da figura 5-14 esta intitulada ‘Previsões outros métodos’. Por fim, adicionou-se também uma oscilação estimada da previsão chamada na planilha como ‘Variação da Vendas’. Os valores máximo e mínimo são obtidos através da soma e subtração do erro absoluto (MAD) do método escolhido ao valor da previsão. Esta informação foi disponibilizada com o intuito de evitar grandes ajustes baseados em otimismo, viés muito comum em previsores.

Ano	Mês	Venda Cambará m ³	Previsão SExon. (1)	Previsão Ajustada (2)	MAPE (1)
2009	mai	53,43	44,36		17%
	jun	39,77	44,37		12%
	jul	42,57	44,36		4%
	ago	33,15	44,36		34%
	set	46,34	44,35		4%
	out	53,41	44,35		17%
	nov	37,03	44,36		20%
	dez		44,35		
Média					18,7%

Previsões outros métodos

MMPond	MSimples
48,42	46,06

Variação das Vendas

Máximo	51,8
Previsão	44,4
Mínimo	37,0

Figura 5-14 Previsão cambará mês de dezembro.

Após a análise do gerente sobre as previsões apresentadas, ele não alterou nada e a previsão ajustada teve o mesmo valor da quantitativa. No mês seguinte (janeiro) a previsão final foi comparada ao valor real ocorrido e apresentada ao gerente conforme mostra a figura 5-15. O título da coluna da previsão quantitativa foi alterada para 'Previsão FOCUS (1)' pois em janeiro o método escolhido foi Holt, diferente do mês anterior (suavização exponencial).

Ano	Mês	Venda Cambará m ³	Previsão FOCUS (1)	Previsão Ajustada (2)	MAPE (2)
2009	dez	39,38	44,35	44,35	13%
2010	jan		37,26		
	fev				
	mar				
Média					13%

Previsões outros métodos

MM6P	Brown
42,08	44,02

Variação das Vendas

Máximo	41,7
Previsão	37,3
Mínimo	32,8

Figura 5-15 Previsão cambará mês de janeiro.

O especialista afirmou que as vendas do camaró em janeiro ficariam no intervalo de 38m^3 a 42m^3 , relativamente próximo das vendas de dezembro. Segundo o previsor, as vendas para pessoa física no mês de janeiro normalmente caem pelas obrigações financeiras assumidas no período de final de ano. Em compensação, as empresas não investem em dezembro pelos encargos pesados das folhas de pagamento dos empregados e voltam a fazê-lo em janeiro o que equilibra o mês. Isto resulta que as vendas de dezembro e janeiro normalmente são bem próximas. Comparando-se o histórico de vendas dos outros anos, conforme o quadro 5-9, verificou-se que isto só não ocorreu em dezembro de 2008 e janeiro de 2009. Segundo o especialista, o ano de 2009 foi atípico, com o fechamento de grandes pedidos inesperados nos primeiros meses do ano. Este fato pode ser confirmado pelas vendas nos meses de janeiro e abril de 2009 terem sido *outliers* da série de dados. Por fim, o valor escolhido da previsão de janeiro foi 38m^3 .

Vendas Camará (m^3)		
Período	Dezembro	Janeiro
2005/2006	22,26	20,7
2006/2007	35,34	31,58
2007/2008	33,42	27,36
2008/2009	34,25	88,92

Quadro 5-9 Comparativo de vendas dezembro e janeiro – madeira camaró.

Quando foi realizada a previsão de fevereiro (figura 5-16) observou-se que as vendas foram abaixo do esperado, porém o especialista não soube justificar a diferença. Na sua análise do mês de fevereiro, o previsor afirmou que neste mês as vendas recuperam-se, voltando aos patamares normais. Em função disto, ajustou a previsão para 40m^3 .

Ano	Mês	Venda Cambará m ³	Previsão FOCUS (1)	Previsão Ajustada (2)	MAPE (2)
2009	dez	39,38	44,35	44,35	13%
2010	jan	28,77	37,26	38,00	32%
	fev		21,65		
	mar				
Média					22%

Previsões outros métodos

MM6P	Brown
39,78	32,20

Variação das Vendas

Máximo	25,2
Previsão	21,7
Mínimo	18,1

Figura 5-16 Previsão cambará mês de fevereiro.

O resultado das vendas no mês de fevereiro superaram inclusive as estimativas do gerente ao chegar no patamar de 60m³. Para o mês de março as estimativas são de continuidade de crescimento nas vendas, o que modificou a previsão final para 72 m³, bem diferente da prevista quantitativamente pelo método média móvel seis períodos (figura 5-17).

Ano	Mês	Venda Cambará m ³	Previsão FOCUS (1)	Previsão Ajustada (2)	MAPE (2)
2009	dez	39,38	44,35	44,35	13%
2010	jan	28,77	37,26	38,00	32%
	fev	62,87	21,65	40,00	36%
	mar		44,73		
Média					27%

Previsões outros métodos

MM4P	SExon.
42,16	44,35

Variação das Vendas

Máximo	56,3
Previsão	44,7
Mínimo	33,2

Figura 5-17 Previsão cambará mês de março.

Contudo, no mês de abril verificou-se que as vendas novamente excederam as expectativas chegando a quase 75m³ (figura 5-18). Por mais que a quantidade de chuva não interfira diretamente nas vendas, não sendo possível estipular uma relação linear (visto na seção 5.3.4), o gerente afirma que as chuvas influenciam. Portanto, a sua argumentação é que as vendas de março e abril foram maiores porque choveu pouco nestes meses.

A previsão de abril foi ajustada pelo gerente para 51 m³.

Ano	Mês	Venda Cambará m ³	Previsão FOCUS (1)	Previsão Ajustada (2)	MAPE (2)
2009	dez	39,38	44,35	44,35	13%
2010	jan	28,77	37,26	38,00	32%
	fev	62,87	21,65	40,00	36%
	mar	74,77	44,73	72,00	4%
	abr		49,97		
Média					21%

Previsões outros métodos

Decomp. Adit.	MM6P
42,16	49,47

Varição das Vendas

Máximo	61,5
Previsão	50,0
Mínimo	38,4

Figura 5-18 Previsão cambará mês de abril.

De acordo com a figura 5-19, o ajuste realizado em abril não foi bom, visto que aumentou o erro da previsão. Percebendo uma queda nas vendas, o gerente reduziu a previsão de maio para 45m³.

Ano	Mês	Venda Cambará m ³	Previsão FOCUS (1)	Previsão Ajustada (2)	MAPE (2)
2009	dez	39,38	44,35	44,35	13%
2010	jan	28,77	37,26	38,00	32%
	fev	62,87	21,65	40,00	36%
	mar	74,77	44,73	72,00	4%
	abr	35,08	49,97	51,00	45%
	mai		57,11		
Média					26%

Previsões outros métodos

Decomp. Mult.	SExon
56,08	44,37

Varição das Vendas

Máximo	73,7
Previsão	57,1
Mínimo	40,5

Figura 5-19 Previsão cambará mês de maio.

Para o mês de junho o especialista afirma que as vendas deveriam atingir os mesmos patamares de maio. Desta forma, a previsão final foi de 49 m³, como mostra a figura 5-20, praticamente o valor obtido pelo método de Brown, que também possuía um dos melhores desempenhos no mês.

Porém, a previsão final de junho teve um erro de 76% para o valor de venda (figura 5-21). Segundo o especialista, havia um pedido de 16,84 m³ que seria expedido e faturado no final do mês. Contudo, houve problemas no crédito do cliente, o que postergou a retirada da nota fiscal para o mês de julho. Caso este valor fosse incorporado às vendas do mês, a previsão final teria um erro de somente 10%.

Ano	Mês	Venda Cambará m ³	Previsão FOCUS (1)	Previsão Ajustada (2)	MAPE (2)
2009	dez	39,38	44,35	44,35	13%
2010	jan	28,77	37,26	38,00	32%
	fev	62,87	21,65	40,00	36%
	mar	74,77	44,73	72,00	4%
	abr	35,08	49,97	51,00	45%
	mai	50,45	57,11	45,00	11%
	jun		47,08		
Média					23%

Previsões outros métodos

Decomp. Mult.	Brown
79,9	48,42

Variação das Vendas

Máximo	57,0
Previsão	47,1
Mínimo	37,1

Figura 5-20 Previsão cambará mês de junho.

Ano	Mês	Venda Cambará m ³	Previsão FOCUS (1)	Previsão Ajustada (2)	MAPE (2)
2009	dez	39,38	44,35	44,35	13%
2010	jan	28,77	37,26	38,00	32%
	fev	62,87	21,65	40,00	36%
	mar	74,77	44,73	72,00	4%
	abr	35,08	49,97	51,00	45%
	mai	50,45	57,11	45,00	11%
	jun	27,80	47,08	49,00	76%
	jul		44,36		
Média					31%

Previsões outros métodos

MSimples	MM6P
46,02	46,62

Variação das Vendas

Máximo	60,0
Previsão	44,4
Mínimo	28,8

Figura 5-21 Previsão cambará mês de julho.

Na previsão para o mês de julho o método escolhido para o cambará foi a suavização exponencial. O especialista afirma que a venda ficará em torno de 45m^3 a 50m^3 , ajustando no final para 47m^3 .

Para o mês de agosto utilizou-se o gráfico de regressão linear apresentado na seção 5.3.4 para informar ao especialista a existência de uma relação inversamente proporcional da quantidade de chuvas com as vendas do mês. Realizou-se um levantamento da média de chuvas na região do estado através do site do INMET e outras páginas da internet. Obteve-se a média de chuva para o mês de agosto de 132 mm (fonte <http://br.weather.com/weather/climatology/BRXX0126>) e a previsão para agosto de 2010 foi de 100 mm, conforme o relatório de previsão para o trimestre junho, julho e agosto [JAS] do site do instituto de meteorologia INMET (www.inmet.gov.br).

De acordo com a figura 5-6, da seção 5.3.4, para uma média de chuvas de 100 mm, as vendas totais das três madeiras estariam em torno de 165m^3 . Incorporou-se esta informação à usual exposta ao previsor no início do mês. O objetivo foi avaliar quanto o especialista seria influenciado pela informação adicional, alterando um ajuste inicialmente proposto.

Conforme a previsão quantitativa (figura 5-22), a soma das vendas das três madeiras resultaria $120,91\text{m}^3$, um pouco abaixo dos 165m^3 .

Ano	Mês	Venda Cambará m^3	Previsão FOCUS (1)	Previsão Ajustada (2)	MAPE (2)
2009	dez	39,38	44,35	44,35	13%
2010	jan	28,77	37,26	38,00	32%
	fev	62,87	21,65	40,00	36%
	mar	74,77	44,73	72,00	4%
	abr	35,08	49,97	51,00	45%
	mai	50,45	57,11	45,00	11%
	jun	27,80	47,08	49,00	76%
	jul	42,20	44,36	47,00	11%
	ago		44,16		
Média					29%

Previsões outros métodos

MSimples	SExpon
45,96	44,36

Varição das Vendas

Máximo	51,1
Previsão	44,2
Mínimo	37,3

Figura 5-22 Previsão cambará mês de agosto.

Após o gerente tomar conhecimento das informações da relação entre as chuvas e as vendas no mês de agosto e da previsão de pouca chuva no próximo mês, ele não alterou sua previsão inicial de queda nas vendas. Segundo o gerente, este movimento de diminuição das vendas, que vinha ocorrendo nos meses anteriores, influencia muito mais que a quantidade de chuvas do mês. Por isso, ele ajustou as previsões para números menores que a previsão quantitativa. Ao final do mês de agosto verificou-se que as vendas foram ainda menores que o ajuste realizado, confirmando a sua interpretação do mercado. Para o camarão, o ajuste reduziu de 10 a 15% as vendas e o valor final ficou em 38 m³.

No total, as previsões ajustadas das três madeiras somaram 106 m³ (38m³ para o camarão, 42m³ para a peroba e 26m³ para a itaúba). No final de agosto, a queda nas vendas totalizou 84,87 m³, sendo que as precipitações no estado foram ainda menores que as previstas, 83,4mm (segundo dados da estação meteorológica de Indaial no site do INMET). Para o camarão a quantidade vendida em agosto foi de 37,47m³, praticamente o valor previsto pelo especialista, 38m³.

Segundo o gerente, ele limita as suas previsões pela capacidade produtiva disponível. A empresa possui uma clientela fixa que ocupa grande parte da capacidade produtiva e ocorrem situações em que pedidos específicos de clientes esporádicos não são atendidos para não comprometer a entrega de produtos aos clientes rotineiros. Esta é mais uma variável avaliada mensalmente nos ajustes realizados.

5.6 MONITORAMENTO

O monitoramento refere-se a forma de avaliação do desempenho do sistema. Quando o sistema possui duas etapas de previsão, como neste trabalho a análise quantitativa e posteriormente a incorporação de julgamento, torna-se viável uma análise distinta para cada etapa, principalmente pelas diferentes características de cada previsão. Após verificar o que será avaliado, necessita-se definir a forma de mensurar o desempenho da previsão quantitativa e do especialista.

Além das medidas de erro convencionais, o *feedback* ao especialista auxilia no processo de aprendizagem do mesmo, sendo uma ferramenta importante no processo.

Portanto, as próximas seções descreverão as abordagens que devem ser utilizadas para monitorar o sistema de previsão.

5.6.1 Determinação de medidas de erro

De acordo com o modelo dinâmico de escolha da previsão quantitativa utilizado neste trabalho, quatro medidas de erro são

responsáveis pela determinação do método a ser aplicado: erro médio absoluto (MAD), erro quadrado médio (MSE), erro percentual absoluto médio (MAPE) e U de Theil.

O MAPE foi a medida de erro principal, servindo como critério de desempate na escolha dos métodos quantitativos e também para avaliar as previsões quantitativas e o ajuste do especialista. O MAD foi usado para determinar a variação máxima e mínima das vendas no mês. Como após a implantação do sistema de previsão na empresa a metodologia permanece a mesma, o monitoramento deverá ser realizado pelas mesmas medidas.

O erro médio (ME) pode ser utilizado para avaliar a introdução de vieses pelo especialista na previsão. Tendências como otimismo são identificadas a partir de um erro médio positivo.

5.6.2 Feedback aos especialistas

Neste trabalho realizou-se duas formas de *feedback* com o especialista. Disponibilizou-se o valor da venda mensal do mês anterior (*outcome feedback*) e o desempenho do mesmo através do MAPE (*performance feedback*). As duas abordagens estavam presentes na planilha mensal apresentada ao gerente, antes de ele realizar o ajuste do próximo mês e devem ser utilizadas no monitoramento do desempenho do especialista.

Outras medidas utilizadas para verificar o desempenho do especialista (erro médio) ou identificação de tendências como conservadorismo devem ser informadas à pessoa para que ela busque evoluir na tarefa de previsão.

5.7 AVALIAÇÃO DOS RESULTADOS

Após a realização da previsão quantitativa com incorporação de julgamentos por nove meses na empresa esta seção irá apresentar os resultados obtidos no estudo de caso. A figura 5-23, figura 5-24 e figura 5-25 demonstram os gráficos comparativos entre as vendas reais e as previsões quantitativas e por julgamento. Observa-se que a série que mais variou foi a do cambará (figura 5-24), registrando uma oscilação total de aproximadamente 45 m^3 (diferença entre a maior e menor demanda). Na sequência de variações vem a peroba ($24,5 \text{ m}^3$) e a itaúba ($19,41 \text{ m}^3$).




Figura 5-23 Comparativo entre o desempenho da previsão quantitativa e ajustada – madeira Itaúba.




Figura 5-24 Comparativo entre o desempenho da previsão quantitativa e ajustada – madeira Cambará.




Figura 5-25 Comparativo entre o desempenho da previsão quantitativa e ajustada – madeira Peroba.

Na sequência são exibidos os quadros com a análise quantitativa dos erros das previsões em cada mês da pesquisa. De forma geral, a incorporação de julgamento resultou em melhorias no desempenho das previsões.

Avaliando os incrementos em acuracidade (diferença entre MAPE (1) e MAPE (2)) verifica-se que para a série com menor variabilidade (itaúba) ocorreu a menor melhoria na acuracidade da previsão (3,9%). Isto confirma as conclusões de diversos estudos sobre a relação do incremento de acuracidade com a alta variabilidade da série.

Ano	Mês	Cambará	Previsão FOCUS (1)	Previsão Ajustada (2)	MAPE (1)	MAPE (2)
2009	dez	39,98	44,35	44,35	11%	11%
2010	jan	28,77	37,26	38,00	30%	32%
	fev	62,87	21,65	40,00	66%	36%
	mar	74,77	44,73	72,00	40%	4%
	abr	35,08	49,97	51,00	42%	45%
	mai	50,45	57,11	45,00	13%	11%
	jun	27,80	47,08	49,00	69%	76%
	jul	42,20	44,36	47,00	5%	11%
	ago	37,47	44,16	38,00	18%	1%
TOTAL					32,7%	25,4%

Quadro 5-10 Erros associados à previsão quantitativa e ajustada – madeira Cambará.

Ano	Mês	Itaúba	Previsão FOCUS (1)	Previsão Ajustada (2)	MAPE (1)	MAPE (2)
2009	dez	23,07	33,22	40,00	44%	73%
2010	jan	25,52	26,26	25,00	3%	2%
	fev	21,48	28,60	23,00	33%	7%
	mar	38,98	18,46	35,00	53%	10%
	abr	26,89	31,43	42,00	17%	56%
	mai	26,52	27,47	27,00	4%	2%
	jun	28,62	24,84	30,00	13%	5%
	jul	30,93	28,00	28,00	9%	9%
	ago	19,57	30,70	26,00	57%	33%
TOTAL					25,9%	22,0%

Quadro 5-11 Erros associados à previsão quantitativa e ajustada – madeira Itaúba.

Ano	Mês	Peroba	Previsão FOCUS (1)	Previsão Ajustada (2)	MAPE (1)	MAPE (2)
2009	dez	35,31	28,93	45,00	18%	27%
2010	jan	47,46	28,72	48,00	39%	1%
	fev	38,74	41,52	41,52	7%	7%
	mar	52,33	35,54	60,00	32%	15%
	abr	39,87	45,69	50,00	15%	25%
	mai	42,86	37,33	45,00	13%	5%
	jun	48,83	42,75	47,00	12%	4%
	jul	32,11	40,13	47,00	25%	46%
	ago	27,83	44,67	42,00	61%	51%
TOTAL					24,7%	20,2%

Quadro 5-12 Erros associados à previsão quantitativa e ajustada – madeira Peroba.

Verificando o desempenho do especialista através do erro médio, quadro 5-13, viu-se que ele tende a realizar ajustes positivos na previsão caracterizando certo otimismo. Principalmente para a madeira peroba, em que foi verificado o maior erro médio (6,69). Porém, os ajustes mais altos ocorreram na madeira cambará (-22,87 em fevereiro e 21,20 em junho). Esta também foi a espécie em que houve os maiores ganhos com a incorporação de julgamento (7,3%). Verifica-se, portanto, que grandes ajustes não reduzem a acuracidade média das previsões. Fildes et al. (2009) também chegam a esta conclusão no seu trabalho afirmando que enquanto os maiores ajustes tendem a melhorias na acuracidade os menores ajustes normalmente a danificam. Além disso, os autores

verificam que normalmente os ajustes são realizados na direção errada (a maioria aumenta o valor da previsão como no Quadro 5-13), sugerindo uma tendência geral ao otimismo.

Mês	Erro médio - Previsão Ajustada		
	Itaúba	Cambará	Peroba
dez/09	16,93	4,37	9,69
jan/10	-0,52	9,23	0,54
fev/10	1,52	-22,87	2,78
mar/10	-3,98	-2,77	7,67
abr/10	15,11	15,92	10,13
mai/10	0,48	-5,45	2,14
jun/10	1,38	21,20	-1,83
jul/10	-2,93	4,80	14,89
ago/10	6,43	0,53	14,17
Média	3,82	2,77	6,69

Quadro 5-13 Erros médios das previsões ajustadas.

O fato dos grandes ajustes aumentarem a acuracidade das previsões ocorre pois nestes casos os especialistas possuem informações relevantes para incorporar, sem considerar que devem realizar o ajuste por ser esta sua tarefa.

Para verificar a eficiência dos ajustes avaliou-se o número de vezes que eles foram benéficos (o erro diminuiu) em relação ao total de meses estudados. Em conversa com o especialista, neste ramo de mercado um erro nas previsões de 20% é considerado aceitável. Por isso, nos meses em que o gerente não ajustou as previsões e os erros foram abaixo de 20% são contabilizados como favoráveis. Para a madeira cambará de todos os meses de ajustes 55% deles foram favoráveis, para a peroba 67% e para a itaúba 78%. Ou seja, apesar de na maioria das vezes os ajustes na itaúba serem bons, não trouxeram melhorias substanciais como os ajustes ocorridos no cambará, que teve o menor índice de acertos mas o melhor resultado final.

Contudo os ajustes foram favoráveis à acuracidade em mais de 50% para todos os casos, o que confirma seu bom desempenho e a importância da incorporação de julgamento. Além disto, pode-se concluir que o especialista possui grande habilidade na tradução das informações contextuais em influências nas vendas, a maioria proveniente do seu conhecimento sobre o produto e o mercado.

5.8 CONSIDERAÇÕES FINAIS

Neste capítulo realizou-se um estudo de caso utilizando a metodologia descrita no capítulo 4. A empresa estudada é uma madeireira de pequeno porte. Os produtos escolhidos para o estudo foram as três madeiras classificadas como de alta rotatividade e participação financeira (classe A). Realizou-se inicialmente a previsão quantitativa considerando diversos métodos de previsão de séries temporais apresentados no capítulo 2. A escolha do método quantitativo foi executada de forma dinâmica através da metodologia *Focus Forecasting*. Posteriormente, efetuou-se a incorporação de julgamentos apresentando ao especialista dados que auxiliassem nos ajustes realizados.

Na análise dos resultados verificou-se que os ajustes por julgamento reduziram os erros das previsões quantitativas em média 5%. Observou-se que o melhor desempenho ocorreu para a madeira com maior variabilidade na série (Itaúba), confirmando estudos anteriores sobre a existência desta relação.

6 CONCLUSÕES

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

Um grande desafio da cadeia produtiva é a previsão de demanda. Diversos são os modelos e técnicas para obter previsões de demanda. Conforme apresentado no capítulo 2, os métodos de previsão podem ser quantitativos ou qualitativos. Os métodos quantitativos avaliam séries de dados a fim de encontrar padrões que possam se repetir no futuro. São objetivos e trabalham com uma grande quantidade de dados. A maioria dos métodos apresentados foi utilizada no estudo de caso para a confecção das previsões quantitativas. Já as predições qualitativas baseiam-se no conhecimento e experiência das pessoas que realizam a previsão, apesar de informações como pesquisa de mercado e dados sobre promoções poderem auxiliar neste processo.

Caso existam dados históricos de demanda e se deseje somente prevê-la para um horizonte de algumas semanas ou meses, no qual os indicadores econômicos, políticos ou tecnológicos tendem a permanecer relativamente estáveis, os resultados dos métodos qualitativos revelam maior utilidade se associados às previsões originadas por modelos de séries temporais (O'CONNOR et al., 1993 *apud* KURRLE, 2004).

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

Apesar do tema integração de previsões despertar o interesse dos pesquisadores já há bastante tempo, persiste ainda nos dias atuais uma escassa literatura a respeito de métodos estruturados para operacionalizá-la (principalmente os que utilizam o ajuste por julgamento) (SOUZA, 2008).

Por este motivo o trabalho concentrou-se na apresentação de um modelo para implantação de um processo preditivo com integração de previsões quantitativas e qualitativas. Inicialmente foram expostas no capítulo 3 as abordagens de integração de previsões conforme as visões de Webby e O'Connor (1996), Armstrong (2001) e Goodwin (2002). Verificou-se que o julgamento humano, base do ajuste, está sujeito a inúmeros vieses, que comprometem o desempenho de todo o processo. Para se obter o melhor aproveitamento da integração de previsões o especialista precisa ter domínio do conhecimento e o ajuste deve ser estruturado. Por isso, esta dissertação preocupou-se em realizar uma revisão bibliográfica e utilizar no estudo de caso procedimentos que estruturam a incorporação do julgamento, evitando a inserção de vieses provenientes dos ajustes de especialistas.

Dentre os métodos de integração apresentados no capítulo 3, inúmeros estudos afirmam que o ajuste de previsões quantitativas é a forma de integração mais difundida no meio empresarial, apesar de ser o que tem o pior desempenho, normalmente ocasionado pela falta de estruturação do julgamento.

Em função disto, o capítulo 4 demonstra o procedimento proposto para implementar um processo de previsão tendo como base o método de extrapolação corrigida (nomenclatura do trabalho para ajuste de previsões quantitativas). Este procedimento possui várias etapas, sendo as principais a determinação da previsão quantitativa e a elaboração do ajuste por julgamento.

O estudo de caso, capítulo 5, foi realizado em uma pequena empresa madeireira localizada no norte do estado de Santa Catarina. Definiu-se que a previsão de vendas seria realizada para os itens de matérias-primas ao invés de produtos acabados. Isto ocorreu pelo fato dos insumos possuírem um *lead time* de entrega maior que o tempo de transformação da matéria-prima em produto final. Após a aquisição das séries históricas de vendas realizou-se a classificação ABC das matérias-primas. Por fim, as madeiras classificadas como 'A' (itaúba, cambará e peroba) foram as escolhidas para a implantação de um método de previsão de vendas.

No estudo de caso, para a escolha da previsão quantitativa utilizou-se um procedimento dinâmico, *Focus Forecasting*, que avalia a cada período através de medidas de erro o método a ser selecionado no mês da previsão. Optou-se por este procedimento após ser verificado a grande variabilidade dos dados. Ao final do trabalho realizou-se uma análise (ver Apêndice C) avaliando o desempenho deste método através de duas simulações. Na primeira simulação foi comparado com um

método único para todos os meses, sendo que os coeficientes de amortização (dos métodos que possuíam) foram atualizados mensalmente realizando a minimização dos erros com a ferramenta Solver. A segunda simulação utilizou os dados históricos para prever todo o ano de 2009 e o método que se sobressaiu foi utilizado nas previsões de 2010. Contudo, desta vez os coeficientes permaneceram os mesmos em todo o período. Como resultado, verificou-se que para a madeira itaúba o método Holt com coeficientes dinâmicos reduziu os erros das previsões em 17,25% em relação ao *Focus Forecasting*. Na madeira cambará e peroba o *Focus Forecasting* foi melhor que os resultados dos testes. Para a itaúba, onde os métodos fixos tiveram melhor desempenho que o *Focus Forecasting*, indica-se a substituição do método atual pelo melhor avaliado na sequência dos trabalhos na empresa.

Antes de realizar o ajuste de previsões quantitativas o gerente relacionou fatores causais (chuvas e relação entre a venda dos produtos) que influenciavam as vendas em curto prazo. Após inúmeras simulações constatou-se que estes dados não possuem relação linear. Este resultado provocou grande surpresa ao gerente, visto que a sua experiência lhe mostra uma relação entre estas variáveis.

A incorporação de julgamentos às previsões quantitativas iniciou-se com a sua estruturação. Ela se deu através de ações simples como a apresentação dos dados em tabelas, determinação do tipo de *feedback* oferecido ao especialista, registro sobre a acurácia das previsões e solicitação de justificativa sempre no mês seguinte ao que o ajuste foi realizado. As formas de *feedback* aplicadas foram exibir o valor das vendas do último período e o desempenho do gerente, este último utilizando a medida de erro MAPE.

O *feedback* mensal e a relação causal entre variáveis (chuva x vendas) proporcionaram um processo de aprendizagem ao gerente. Principalmente no que diz respeito às influências entre variáveis e as suas consequências traduzidas em ajustes. Todas as vezes que o especialista avaliou um desempenho negativo, todas as relações entre variáveis e suas influências foram revistas e reconsideradas. Além disso, ao justificar os motivos de acertos ou erros nos ajustes outras relações que ele não havia exposto vieram à tona e puderam ser confirmadas ou ignoradas.

Por fim, na análise dos resultados constatou-se que a incorporação de julgamento aumentou a acuracidade das previsões das três madeiras, ratificando sua importância no processo preditivo. A redução dos erros de previsão para a itaúba, peroba e cambará,

respectivamente, foram de 3,9%, 4,5%, 7,3%. Isto demonstra que o domínio de conhecimento que o especialista possui e a estruturação do julgamento foram determinantes para alcançar um resultado positivo.

Como sugestão de futuros trabalhos está elaborar procedimentos para realizar julgamentos em diversos tipos de séries temporais e informações contextuais, avaliando em que situações seria pertinente aplicar determinado tipo de estrutura de ajuste.

Outros estudos avaliando os sistemas de previsão de grandes empresas tornam-se interessantes visto que nestas instituições normalmente são implementados sistemas de previsão quantitativos e ajustes são realizados por um grupo de pessoas. Portanto, a estruturação do julgamento torna-se mais complexa e com mais variáveis.

7 REFERÊNCIAS BIBLIOGRÁFICAS

- AHLBURG, D. A. Population forecasting. *In: ARMSTRONG, J. S. Principles of forecasting: a handbook for researches and practitioners.* Dordrecht: Kluwer Academic Publishers, 2001. p. 557-576.
- ALLEMÃO, M. A. F. Redes Neurais aplicadas à previsão de demanda de numerário em agências bancárias. 2004. 247f. Dissertação (Mestrado em Ciências da Computação) – Instituto de Matemática – Núcleo de Computação Eletrônica, Universidade Federal do Rio de Janeiro – UFRJ, Rio de Janeiro.
- ANSUJ, A. P.; CAMARGO, M. E.; RADHARAMANAN, R. PETRY, D. G. Sales Forecasting using time series and neural networks. *Computers and Industrial Engineering*, n .1, v. 31, p. 421-425, 1996.
- ARKES, H. R. Overconfidence in judgmental forecasting. *In: ARMSTRONG, J. S. Principles of forecasting: a handbook for researches and practitioners.* Dordrecht: Kluwer Academic Publishers, 2001. p. 495-516.
- ARMSTRONG, J. S. **Principles of forecasting:** a handbook for researches and practitioners. Dordrecht: Kluwer Academic Publishers, 2001. ISBN: 0-7923-7930-6.
- ARMSTRONG, J. S. Findings from evidence-based forecasting: Methods for reducing forecast error. *International Journal of Forecasting*, v. 22, p. 583-598, 2006.
- ARMSTRONG, J. S.; ADYA, M.; COLLOPY, F. Ruled-based forecasting: using judgment in time-series extrapolation. *In: ARMSTRONG, J. S. Principles of forecasting: a handbook for researches and practitioners.* Dordrecht: Kluwer Academic Publishers, 2001. p. 259-282.
- ARMSTRONG, J. S.; COLLOPY, F. Integration of statistical methods and judgment for time series forecasting: principles from empirical research. *Forecasting with Judgment*, John Wiley & Sons Ltd., Chichester, UK, p.269-293, 1998.
- BALLOU, R. H. **Logística empresarial:** transportes, administração de materiais e distribuição física. São Paulo: Atlas, 1993.
- BALLOU, R. H. **Gerenciamento da Cadeia de Suprimentos:** Planejamento, Organização e Logística Empresarial. 4. ed., Porto Alegre: Bookman, 2001.
- BARBOSA, M. A.; WANKE, P. Combinação ou competição de previsões: um estudo de caso nos fretes do agronegócio – Parte 1. *Revista MundoLogística*, 16 ed., p. 70-75, maio-junho/2010.

- BOWERSOX, D. J.; CLOSS, D. J.; COOPER, M. B. **Supply chain logistics management**. New York: McGraw-Hill/Irwin, 2002. ISBN: 0-07-112306-7.
- BUNN, D.; WRIGHT, G. Interaction of judgemental and statistical forecasting methods: issues and analysis, *Management Science*, n. 5, v. 37, p. 501-518, 1991.
- CAVALHEIRO, D. Método de previsão de demanda aplicada ao planejamento da produção de indústrias de alimentos. 2003. 125f. Dissertação (Mestrado em Engenharia Mecânica) – Programa de Pós-Graduação em Engenharia Mecânica, Universidade Federal de Santa Catarina – UFSC, Florianópolis.
- CHASE, R. B.; JACOBS, F. R.; AQUILANO, N. J. **Administração da produção e operações para vantagens competitivas**. 11ª Ed. São Paulo: McGraw-Hill, 2006.
- CLEMEN, R. T. Combining Forecasts: A Review and Annotated Bibliography. *International Journal of Forecasting*, v. 5, p.559-583, 1989.
- CONSELHO NACIONAL DE MEIO AMBIENTE (CONAMA) www.mma.gov.br. Acesso 15/09/2010.
- CONSTANTINI, M.; PAPPALARDO, C. A hierarchical procedure for the combination of forecasts. *International Journal of Forecasting*, v. 26, p. 725-743, 2010.
- DE GOOIJER, J. G.; HYNDMAN, R. J. 25 years of time series forecasting. *International Journal of Forecasting*, v. 22, p. 443-473, 2006.
- DEVORE, J. L. **Probabilidade e estatística**: para engenharia e ciências. São Paulo: Pioneira Thomson Learning, 2006.
- DIAS, A. S. Uso de conhecimento teórico e de especialista para previsão de demanda. 2004. 181f. Dissertação (Mestrado em Engenharia de Produção) – Programa de Pós-Graduação em Engenharia de Produção, Universidade Federal de São Carlos – UFSCar, São Carlos.
- DICKERSBACH, J. T. **Supply Chain Management with APO**: Structures, modelling approaches and implementation of mySAP SCM 4.1. 2. ed., Berlin: Springer, 2006.
- EROGLU, C.; CROXTON, K. L. Biases in judgmental adjustments of statistical forecasts: The role of individual differences. *International Journal of Forecasting*, v. 26, p. 116-133, 2010.
- FILDES, R.; GOODWIN, P. Against your better judgment? How organizations can improve their use of management judgment in forecasting. *Interfaces*, v. 37, n. 6, p. 570-576, nov-dec 2007.

- FILDES, R.; GOODWIN, P.; LAWRENCE, M.; NIKOLOPOULOS, K. Effective forecasting and judgmental adjustments: an empirical evaluation and strategies for improvement in supply-chain planning. *International Journal of Forecasting*, v. 25, p. 3-23, 2009.
- GÖNÜL, S.; ÖNKAL, D.; GOODWIN, P. Expectations, Use and Judgmental Adjustment of External Financial and Economic Forecasts: An Empirical Investigation. *Journal of Forecasting*, v. 28, p. 19-37, 2009.
- GOODWIN, P. Adjusting judgemental extrapolations using Theil's method and discounted weighted regression. *Journal of Forecasting*, v. 16, p. 37-46, 1997.
- GOODWIN, P. Improving the voluntary integration of statistical forecasts and judgement. *International Journal of Forecasting*, v. 16, p. 85-99, 2000.
- GOODWIN, P. Integrating management judgment and statistical methods to improve short-term forecasts. *Omega International Journal of Management Science*, v. 30, p. 127-135, 2002.
- GUJARATI, D. **Econometria Básica**. 3^a ed., Makron Books: São Paulo, 2000.
- HANKE, J. E.; WICHERN, D. W. **Business forecasting**. 8. ed., New Jersey: Pearson Prentice Hall, 2005.
- HERZOG, S. M.; HERTWIG, R. The Wisdom of many in one mind: improving individual judgments with Dialectical Bootstrapping. *Psychological Science*, n. 2, v. 20, p. 231-237, 2009.
- INSTITUTO NACIONAL DE METEOROLOGIA (INMET). Disponível em: <www.inmet.gov.br/sim/sonabra>. Acesso em: 10/06/2010.
- JÚDICE, P. A. Previsão de demanda na gestão logística de um produto perecível vendido por máquina automática. 2005. 92f. Dissertação (Mestrado em Logística) – Programa de Pós-Graduação de Engenharia Industrial, Pontifícia Universidade Católica do Rio de Janeiro – PUC/Rio, Rio de Janeiro.
- JULIANELLI, L. Problemas de julgamento e tomada de decisão no atendimento da demanda. 2007. Disponível em: www.coppead.ufrj.br. Acesso em 10/05/2010.
- KURRLE, M. A. Métodos para previsão de demanda de veículos novos - estudo de caso em uma concessionária de automóveis. 2004. 100f. Trabalho de Conclusão de curso (Mestrado Profissionalizante em Engenharia) – Programa de Mestrado Profissionalizante em Engenharia, Universidade Federal do Rio Grande do Sul – UFRGS, Porto Alegre.

- LAWRENCE, M.; GOODWIN, P.; O'CONNOR, M.; ÖNKAL, D. Judgmental forecasting: A review of progress over the last 25years. *International Journal of Forecasting*, v. 22, p.493-518, 2006.
- LEMOS, F. de O. Metodologia para seleção de métodos de previsão de demanda. 2006. 171f. Dissertação (Mestrado em Engenharia de Produção) – Programa de Pós-Graduação em Engenharia de Produção, Universidade Federal do Rio Grande do Sul – UFRGS, Porto Alegre.
- LIM, J. S.; O'CONNOR, M. Judgmental forecasting with time series and causal information. *International Journal of Forecasting*, v. 12, p. 139-153, 1996.
- LIN, T. Y. Estudo de modelos de previsão de demanda. Núcleo de Pesquisas e Publicações da FGV-EAESP, n. 1, v. 3, p. 25-29, 2000.
- LUCINI, F. R. Método para identificação de quedas de consumo atípicas em unidades consumidoras de energia elétrica. 2010. 117f. Dissertação (Mestrado em Engenharia de Produção, modalidade profissional) – Programa de Pós-Graduação em Engenharia de Produção, Universidade Federal do Rio Grande do Sul – UFRGS, Porto Alegre.
- MACGREGOR, D. G. Decomposition for judgmental forecasting and estimation. In: ARMSTRONG, J. S. *Principles of forecasting: a handbook for researches and practitioners*. Dordrecht: Kluwer Academic Publishers, 2001. p. 107-124.
- MACKAY, M. M.; METCALFE, M. Multiple Methods Forecasts for Discontinuous Innovations. *Technological Forecasting & Social Science*, v.69, p.221-232, 2002.
- MAKRIDAKIS, S.; WHEELWRIGHT, S.; HYNDMAN, R. *Forecasting: Methods and Applications*. 3. ed., New York: John Wiley & Sons, 1998.
- MARMIER, F.; GONZALES-BLANCH, M.; CHEIKHROUHOU, N. A new structured adjustment approach for demand forecasting. In: International Conference on Computers & Industrial Engineering, p. 773-778, 2009.
- MENDENHALL, W.; SINCICH, T. **A second course in statistics: regression analysis**. 6^a ed., New Jersey: Pearson Education, Inc., 2003. ISBN 0-13-022323-9.
- MILESKI JÚNIOR, A. Análise de métodos de previsão de demanda baseados em séries temporais em uma empresa do setor de perfumes e cosméticos. 2007. 100f. Dissertação (Mestrado em Engenharia de Produção e Sistemas – Programa de Pós-Graduação em Engenharia de Produção e Sistemas, Pontifícia Universidade Católica do Paraná – PUC-PR, Curitiba).

- MOON, M. A.; MENTZER, J.T.; SMITH, C.D. Conducting a sales forecasting audit. *International Journal of Forecasting*. v.19, p.5-25, 2003.
- MOREIRA, D. A. **Administração da produção e operações**. 2 ed. ver. e ampl., São Paulo: Cengage Learning, 2008.
- PEINADO, J.; GRAEML, A. R. **Administração da Produção**: Operações industriais e de serviços. Curitiba: UnicenP, 2007.
- PELLEGRINI, F. R. Metodologia para implementação de sistemas de previsão de demanda. 2000. 127f. Dissertação (Mestrado em Engenharia de Produção) – Programa de Pós-Graduação em Engenharia de Produção, Universidade Federal do Rio Grande do Sul – UFRGS, Porto Alegre.
- PELLEGRINI, F. R.; FOGLIATTO, F. S. Passos para implantação de sistemas de previsão de demanda: técnicas e estudo de caso. 2000. Disponível em: <http://www.inf.unisinos.br/~sellitto/logdem.PDF>. Acesso em: 11/07/2010.
- SAMOHYL, R. W. Measuring the Efficiency of an Informal Forecasting Process. *The International Journal of Applied Forecasting – Foresight*. v. 3, p. 16-21, 2006.
- SAMOHYL, R. W.; SOUZA, G. P.; MIRANDA, R. G. Métodos simplificados de previsão empresarial. Apostila, 2007.
- SANDERS, N. R.; MANRODT, K. B. Forecasting practices in US corporations: survey results. *Interfaces*, n. 2, v. 24, p. 92-100, 1994.
- SANDERS, N. R.; RITZMAN, L. P. Improving short-term forecasts. *Omega International Journal of Management Science*, n. 4, v. 18, p. 365-373, 1990.
- SANDERS, N. R.; RITZMAN, L. P. Judgmental adjustment of statistical forecasting. In: ARMSTRONG, J. S. *Principles of forecasting: a handbook for researchers and practitioners*. Dordrecht: Kluwer Academic Publishers, 2001. p. 405-416.
- SANTOS, P. M. Seleção de modelos de previsão baseada em informações de desempenho. 2006. 79f. Dissertação (Mestrado em Ciência da Computação) – Programa de Pós-Graduação em Ciência da Computação, Universidade Federal de Pernambuco – UFPE, Recife.
- SILVA, E. D.; MENEZES, E. M. Metodologia da Pesquisa e Elaboração de Dissertação. 3ª Ed. rev. atual. Florianópolis: Laboratório de Ensino a Distância da UFSC, 2001.
- SLACK, N.; CHAMBERS, S.; HARLAND, C.; HARRISON, A.; JOHNSTON, R. **Administração da Produção**. São Paulo: Atlas, 1997.
- SOUZA, G. P. Previsão do consumo industrial de energia elétrica no estado de Santa Catarina: uma aplicação da combinação de previsões

entre modelos univariados e de regressão dinâmica. 2005. 107f. Dissertação (Mestrado em Engenharia de Produção) – Programa de Pós-Graduação em Engenharia de Produção, Universidade Federal de Santa Catarina – UFSC, Florianópolis.

SOUZA, G. P. Método para estruturar a integração de previsões utilizando a técnica Delphi. 2008. 168f. Tese (Doutorado em Engenharia de Produção) – Programa de Pós-Graduação em Engenharia de Produção, Universidade Federal de Santa Catarina – UFSC, Florianópolis.

SYNTETOS, A. A.; NIKOLOPOULOS, K.; BOYLAN, J. E.; FILDES, R.; GOODWIN, P. The effects of integrating management judgment into intermittent demand forecasts. *International Journal Production Economics*, v. 118, p. 72-81, 2009.

SYNTETOS, A. A.; NIKOLOPOULOS, K.; BOYLAN, J. E. Judging the judges through accuracy-implication metrics: The case of inventory forecasting. *International Journal of Forecasting*, v. 26, p. 134-143, 2010.

TABACHNICK, B. G.; FIDELL, L. S. **Using multivariate statistics**. 4 ed., Needham Heights: Allyn & Bacon, 2001.

VONDOURIS, C.; OWUSU, G.; DORNE, R.; LESAINTE, D. **Service chain management: technology innovation for the service business**. Berlin: Springer, 2008.

WANKE, P.; JULIANELLI, L. **Previsão de vendas: processos organizacionais e métodos quantitativos e qualitativos**. São Paulo: Atlas, 2006. (Coleção Coppead de Administração).

WEBBY, R.; O'CONNOR, M. Judgmental and statistical time series forecasting: a review of the literature. *International Journal of Forecasting*, v. 12, p. 91-118, 1996.

WEBBY, R.; O'CONNOR, M. Judgmental time-series forecasting using domain knowledge. In: ARMSTRONG, J. S. *Principles of forecasting: a handbook for researchers and practitioners*. Dordrecht: Kluwer Academic Publishers, 2001. p. 389-404.

WEBBY, R.; O'CONNOR, M.; EDMUNDSON, B. Forecasting support systems for the incorporation of event information: An empirical investigation. *International Journal of Forecasting*, v. 21, p. 411-423, 2005.

WERNER, L. Um modelo composto para realizar previsão de demanda através da integração da combinação de previsões e do ajuste baseado na opinião. 2004. 153f. Tese (Doutorado em Engenharia de Produção) – Programa de Pós-Graduação em Engenharia de Produção, Universidade Federal do Rio Grande do Sul – UFRGS, Porto Alegre.

WERNER, L.; RIBEIRO, J. L. D. Modelo composto para prever demanda através da integração de previsões. *Produção*, v. 16, n. 3, p. 493-509, set./dez. 2006.

WILD, T. **Best practice in inventory management**. New York: John Wiley & Sons, 1997.

WRIGHT, G.; LAWRENCE, M.; COLLOPY, F. The Role and Validity of Judgment in Forecasting. *International Journal of Forecasting*, v. 12, n. 1, p. 1-8, 1996.

XAVIER, P. B.; JÚNIOR, G. C.; VINAL, C. D. N.; MARQUES, T. C.; CUNHA, A. L. A. Estudos comparativos entre modelos de previsão de vazões utilizando séries temporais. In: XVI SIMPEP – Simpósio de Engenharia de Produção, Bauru – SP, 2009.

ZAN, G. L. SELLITO, M. A. Técnicas de previsão de demanda: um estudo de caso triplo com dados de venda de materiais eletro-mecânicos. *Revista Gepros – Gestão da Produção, Operações e Sistemas*, ano 2, v.4, jul-set, p.95-106, 2007.

APÊNDICE A

A.1 SIMULAÇÕES REGRESSÃO LINEAR

A.1.1 Relação entre as chuvas e as vendas

Inicialmente verificou-se a existência de influências nas chuvas ocorridas em determinado período (t) para as vendas do período seguinte (t+1). A figura a-1 demonstra a regressão linear realizada para os dados de chuvas com o faturamento total da empresa no período mensal.




Figura A-1 Relação das chuvas (t) com faturamento (t+1) no período mensal – total geral.

A figura a-2, figura a-3 e figura a-4 demonstram a relação entre a chuva e vendas de cada madeira no período semanal.

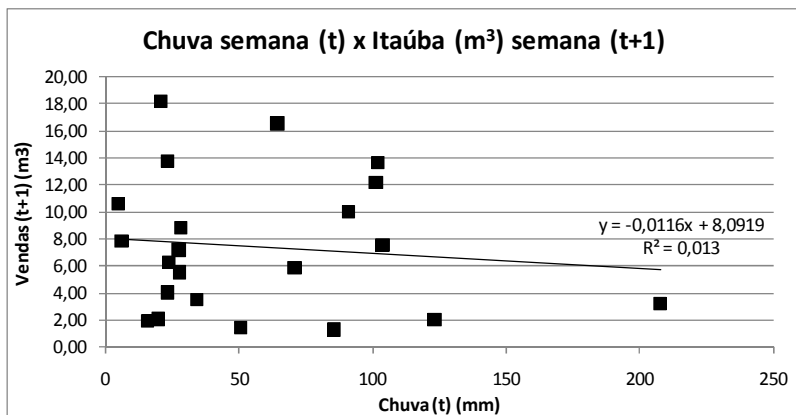


Figura A-2 Relação das chuvas (t) com vendas (t+1) no período semanal – madeira Itaúba.




Figura A-3 Relação das chuvas (t) com vendas (t+1) no período semanal – madeira Cambará.




Figura A-4 Relação das chuvas (t) com vendas (t+1) no período semanal – madeira Peroba.

Após verificar que não existe relação entre as chuvas que ocorrem em um período com as vendas do período seguinte, simularam-se as influências provocadas pelas chuvas nas vendas do mesmo período.

A Figura A-5 demonstra a relação das chuvas no mês (t) com as vendas das três madeiras no mesmo mês. A Figura A-6 demonstra a mesma correlação para o período semanal.




Figura A-5 Relação das chuvas com vendas no mesmo período mensal (t) – três madeiras.

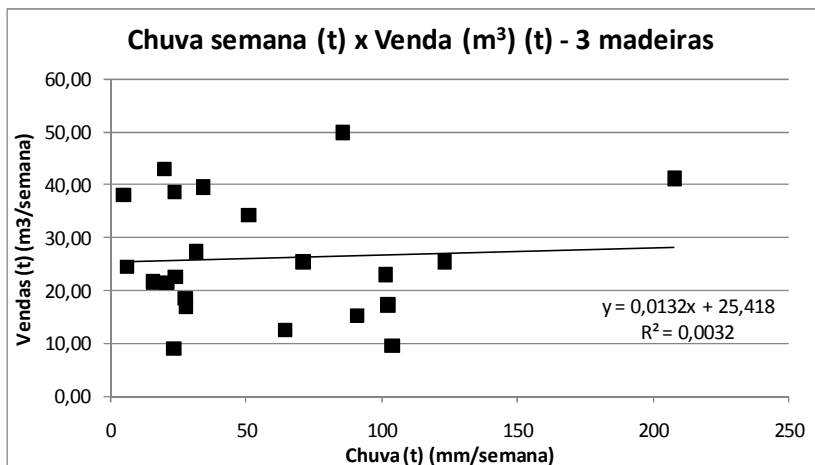


Figura A-6 Relação das chuvas com vendas no mesmo período semanal (t) – três madeiras.

Posteriormente, avaliou-se se havia alguma relação da chuva no período (t) para as vendas no mesmo período em alguma das três madeiras estudadas. A figura a-7, figura a-8 e figura a-9 exibem os resultados.

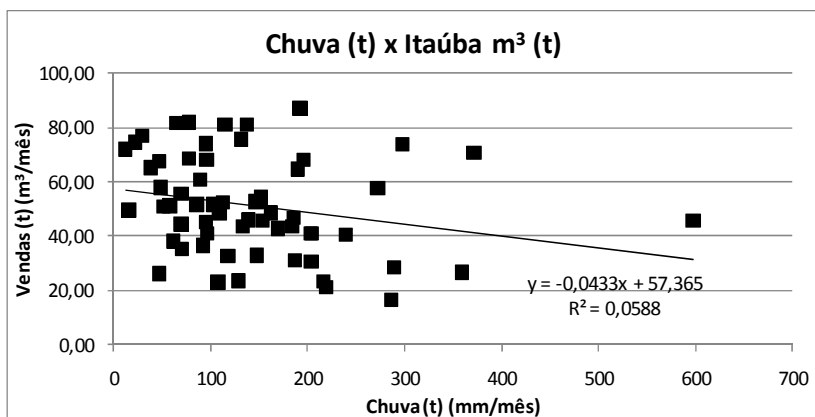


Figura A-7 Relação das chuvas (t) com vendas (t) no período mensal – madeira Itaúba.

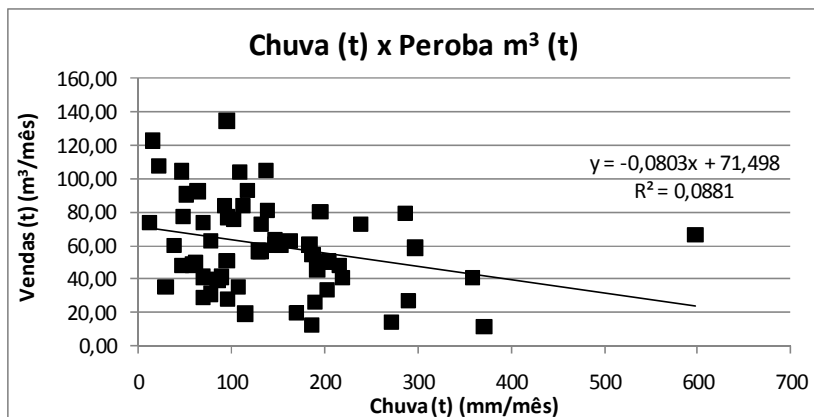


Figura A-8 Relação das chuvas (t) com vendas (t) no período mensal – madeira Itaúba.




Figura A-9 Relação das chuvas (t) com vendas (t) no período mensal – madeira Itaúba.

Conclui-se, portanto, que não existe uma relação linear entre as chuvas e as vendas.

A.1.2 Relação entre as vendas das madeiras

Outro vínculo abordado pelo especialista foi a correlação inversamente proporcional das três madeiras. Para avaliar se existe matematicamente uma relação entre as vendas dos tipos de madeira, confeccionaram-se gráficos confrontando o histórico de vendas das

espécies para o mesmo período de tempo. A figura a-10 e figura a-11 demonstram que também não existe correlação matemática entre as variáveis.




Figura A-10 Relação entre as vendas da madeira itaúba e camarará.




Figura A-11 Relação entre as vendas da madeira itaúba e peroba.

APÊNDICE B

B.1 AVALIAÇÃO FOCUS FORECASTING

A constatação que originou esta seção vem do quadro 5-7. Durante o estudo, alguns métodos foram selecionados diversas vezes. Por isso, decidiu-se comparar o desempenho do modelo dinâmico implantado e a utilização de um método único. Porém, este método único terá seus coeficientes de suavização (se houver) atualizados mensalmente através das simulações de valores iniciais apresentados na seção 5.4.1.

Inicialmente verificou-se qual método foi o mais escolhido para cada madeira. Para a itaúba e o cambará foi o método de Holt, escolhido em quatro meses dos nove estudados para cada madeira. A peroba teve a média móvel ponderada como principal método. O quadro b-1 demonstra o comparativo entre os erros de previsão dos métodos.

Mês	MAPE - Focus Forecasting x Método único					
	Itaúba		Cambará		Peroba	
	Focus	Holt	Focus	Holt	Focus	MMPond
dez/09	44%	44%	11%	20%	18%	42%
jan/10	3%	18%	30%	30%	39%	26%
fev/10	33%	2%	66%	66%	7%	7%
mar/10	53%	53%	40%	60%	32%	18%
abr/10	17%	5%	42%	175%	15%	15%
mai/10	4%	4%	13%	26%	13%	19%
jun/10	13%	2%	69%	69%	12%	12%
jul/10	9%	21%	5%	30%	25%	27%
ago/10	57%	57%	18%	18%	61%	61%
Média	25,9%	22,9%	32,7%	54,9%	24,7%	25,2%

Quadro B-1 Comparativo entre *Focus Forecasting* e método quantitativo mais selecionado.

Verifica-se que apesar do cambará ter o pior desempenho (em relação às três madeiras) utilizando a abordagem *Focus Forecasting*, ela superou o método único Holt. Já para a itaúba o método de Holt foi melhor, sugerindo que para as características presentes na série da itaúba o modelo do *Focus Forecasting* não tem boa atuação.

Posteriormente, avaliou-se o comportamento do *Focus Forecasting* em relação a um modelo único selecionado com os dados históricos do ano de 2009. Para selecionar o método único utilizou-se a

mesma abordagem demonstrada neste trabalho para a seleção mensal das previsões. Os mesmos métodos testados mensalmente foram aplicados às vendas de 2009. Para aqueles com coeficientes de amortização, testaram-se as mesmas combinações de valores iniciais apresentados na seção 5.4.1. Os coeficientes selecionados foram utilizados todos os meses de 2010. Os cálculos das medidas de erro contemplaram a média de todos os meses do ano de 2009.

Para a madeira itaúba, o método com melhor desempenho foi a média móvel ponderada, como mostra o quadro b-2.

Método / Erro	MAD	MSE	MAPE	U de Theil	alfa	beta	gama
Ingênua	11,34	205,2	33,8%	1,00			
MSimples	19,78	537,5	79,9%	1,14			
MM2P	13,56	274,3	42,0%	1,00			
MM4P	13,69	253,9	43,7%	0,87			
MM6P	13,36	243,6	47,6%	0,81			
MMDupla	16,10	363,9	49,2%	1,07			
Decomp. Adit.	22,48	666,6	82,5%	1,12			
Decomp. Mult.	22,68	683,1	83,1%	1,13			
MMPond	10,48	177,6	32,0%	0,89	0,837	0	0,163
SExpon.	11,35	205,2	33,8%	1,00	0,999		
Brown	12,61	271,6	35,9%	1,07	0,33		
Holt	11,70	239,7	33,0%	1,11	0,999	0,134	

Quadro B-2 Seleção do método quantitativo ano 2009 – madeira itaúba.

O comparativo entre a média móvel ponderada e *Focus Forecasting* encontra-se no quadro b-3.

Ano	Mês	Vendas Itaúba (m ³)	Previsão Quant FOCUS (1)	Previsão MMPond (2)	MAPE (1)	MAPE (2)
2010	jan	25,52	29,53	26,26	15,7%	2,9%
	fev	21,48	28,60	26,36	33,2%	22,7%
	mar	38,98	21,74	21,74	44,2%	44,2%
	abr	26,89	30,41	36,79	13,1%	36,8%
	mai	26,52	57,30	26,01	116,1%	1,9%
	jun	28,62	27,10	28,55	5,3%	0,3%
	jul	30,93	28,00	28,34	9,5%	8,4%
	ago	19,57	31,88	30,21	62,9%	54,4%
Média					37,5%	21,5%

Quadro B-3 Desempenho FOCUS e método único anual – madeira itaúba.

Verifica-se no quadro b-3 que a escolha de um método único (no caso o modelo de maior acuracidade) teve um desempenho melhor que o método iterativo. Comparando a média dos erros do método de Holt para os meses de janeiro a agosto de 2010 (20,25%) com a média dos erros da média móvel ponderada no mesmo período (21,5%) constata-se que o método de Holt dinâmico (atualização mensal dos coeficientes) obteve os menores índices de erro. A partir destas análises verifica-se novamente que o método *Focus Forecasting* não teve bom desempenho para os dados da itaúba, sendo inferior nas duas simulações. Contudo, mensurando a média dos erros do especialista para o mesmo período (janeiro a agosto de 2010) verifica-se que a acuracidade das previsões aumenta com a redução do erro para 15,6%.

Conclui-se que cada produto possui um comportamento único e deve-se buscar a abordagem que alcance os melhores resultados. Para a itaúba a empresa não precisa avaliar mensalmente todos as abordagens pois o método de Holt dinâmico gera bons resultados quantitativos.

Para a madeira cambará, o método com melhor desempenho foi a média móvel ponderada, como mostra o quadro b-4.

Método / Erro	MAD	MSE	MAPE	U de Theil	alfa	beta	gama
Ingênua	17,84	505,8	31,5%	1,00			
MSimples	14,15	382,5	23,3%	0,85			
MM2P	16,57	376,9	30,9%	0,82			
MM4P	15,49	310,5	30,3%	0,74			
MM6P	15,40	332,6	30,2%	0,82			
MMDupla	16,51	392,38	31,2%	0,91			
Decomp. Adit.	20,07	605,7	37,8%	1,10			
Decomp. Mult.	23,12	793,0	43,8%	1,25			
MMPond	12,52	242,5	24,4%	0,70	0,445	0	0,555
SExpon.	14,03	388,6	22,4%	0,85	0,001		
Brown	16,07	420,7	29,2%	0,90	0,41		
Holt	15,47	325,3	31,2%	0,75	0,155	0,623	

Quadro B-4 Seleção do método quantitativo ano 2009 – madeira cambará.

O Quadro B-5 exibe o comparativo entre o desempenho da média móvel ponderada com o *Focus Forecasting*.

Ano	Mês	Vendas Cambará (m ³)	Previsão Quant FOCUS (1)	Previsão MMPond (2)	MAPE (1)	MAPE (2)
2010	jan	28,77	37,26	47,44	29,5%	64,9%
	fev	62,87	21,65	33,35	65,6%	46,9%
	mar	74,77	44,73	50,16	40,2%	32,9%
	abr	35,08	49,97	49,22	42,4%	40,3%
	mai	50,45	57,11	50,51	13,2%	0,1%
	jun	27,80	47,08	63,96	69,4%	130,1%
	jul	42,20	44,36	31,84	5,1%	24,5%
	ago	37,47	44,16	46,78	17,9%	24,9%
				Média	35,4%	45,6%

Quadro B-5 Desempenho FOCUS e método único anual – madeira cambará.

Os resultados apresentados demonstram que para a madeira cambará o método *Focus Forecasting* foi superior aos demais (MMPond anual e Holt dinâmico mensal).

A madeira Peroba também foi analisada nos mesmos critérios das madeiras anteriores. O quadro b-6 apresenta os erros médios no ano de 2009 para todos os modelos de previsão estudados. De acordo com os critérios de classificação estipulados para determinar o melhor método, Holt foi o escolhido.

Método / Erro	MAD	MSE	MAPE	U de Theil	alfa	beta	gama
Ingênua	15,40	298,9	33,6%	1,00			
MSimples	18,07	441,4	52,5%	1,13			
MM2P	13,23	238,5	32,5%	0,95			
MM4P	12,94	246,2	33,7%	0,81			
MM6P	13,71	242,1	37,0%	0,80			
MMDupla	13,34	250,4	30,6%	0,88			
Decomp. Adit.	23,76	887,9	59,7%	1,40			
Decomp. Mult.	21,32	729,4	54,5%	1,29			
MMPond	13,22	238,3	32,3%	0,95	0,511	0,489	0
SExpon.	13,50	236,1	32,5%	0,88	0,591		
Brown	12,91	236,8	29,7%	0,95	0,27		
Holt	9,65	136,9	23,0%	0,74	0,022	0,824	

Quadro B-6 Seleção do método quantitativo ano 2009 – madeira Peroba.

Ano	Mês	Vendas Peroba (m ³)	Previsão Quant FOCUS (1)	Previsão Holt (2)	MAPE (1)	MAPE (2)
2010	jan	47,46	28,72	22,82	39,5%	51,9%
	fev	38,74	41,52	20,45	7,2%	47,2%
	mar	51,33	35,54	18,27	30,8%	64,4%
	abr	39,87	45,69	17,01	14,6%	57,3%
	mai	42,86	37,33	15,94	12,9%	62,8%
	jun	48,83	42,75	15,44	12,5%	68,4%
	jul	32,11	40,13	15,69	25,0%	51,1%
	ago	27,83	44,67	15,86	60,5%	43,0%
			Média		25,4%	55,8%

Quadro B-7 Seleção do método quantitativo ano 2009 – madeira Peroba.

Observa-se novamente que a abordagem *Focus Forecasting* foi superior na comparação com a MMPond dinâmica e com o método de Holt anual.

Estes testes demonstraram que a abordagem foi adequada para dois dos três produtos analisados nesta dissertação.

APÊNDICE C

C.1 APLICAÇÃO DOS AJUSTES POR JULGAMENTO

A incorporação dos julgamentos ocorreu da mesma forma relatada na seção 5.5.3, com a apresentação mensal da previsão quantitativa ao especialista que ajustava conforme seu conhecimento sobre o produto e mercado. A configuração das planilhas que exibiam os dados é idêntica às apresentadas para a madeira cambará. Pela similaridade de informações, nesta seção serão resumidas as previsões do *Focus Forecasting* e do julgamento em um quadro único para cada madeira, conforme o quadro c-1 e quadro c-2. A descrição das incorporações de julgamento será apresentada na sequência.

Ano	Mês	Itaúba	Previsão FOCUS (1)	Previsão Ajustada (2)	MAPE (2)
2009	dez	23,07	33,22	40,00	73%
2010	jan	25,52	26,26	25,00	2%
	fev	21,48	28,60	23,00	7%
	mar	38,98	18,46	35,00	10%
	abr	26,89	31,43	42,00	56%
	mai	26,52	27,47	27,00	2%
	jun	28,62	24,84	30,00	5%
	jul	30,93	28,00	28,00	9%
	ago	19,57	30,70	26,00	33%
Média					22%

Quadro C-1 Resumo previsões mensais itaúba.

Ano	Mês	Peroba	Previsão FOCUS (1)	Previsão Ajustada (2)	MAPE (2)
2009	dez	35,31	28,93	45,00	27%
2010	jan	47,46	28,72	48,00	1%
	fev	38,74	41,52	41,52	7%
	mar	52,33	35,54	60,00	15%
	abr	39,87	45,69	50,00	25%
	mai	42,86	37,33	45,00	5%
	jun	48,83	42,75	47,00	4%
	jul	32,11	40,13	47,00	46%
	ago	27,83	44,67	42,00	51%
Média					20,2%

Quadro C-2 Resumo previsões mensais peroba.

A previsão quantitativa da itaúba no mês de dezembro foi de 33,22 m³, mas de acordo com a análise e expectativa de vendas do gerente o valor final foi alterado para 40 m³, fato que não se confirmou.

Para a peroba, no mês de dezembro, o especialista aumentou a previsão para 45 m³. Verifica-se que as vendas realmente foram maiores que o previsto quantitativamente, mas houve um excesso de otimismo ao averiguar que a demanda ficou 10 m³ abaixo da previsão final.

Para o mês de janeiro o gerente considerou para a itaúba a mesma análise feita para o camarará, em que as vendas de janeiro são muito próximas a dezembro. Sua argumentação está embasada nas compensações entre a disponibilidade financeira da pessoa física em dezembro resultando queda em janeiro com o movimento inverso das empresas, que voltam a investir em janeiro.

Avaliando-se o histórico de vendas das madeiras quadro c-3 e quadro c-4, observa-se que para a itaúba as vendas de dezembro e janeiro também são próximas, assim como com a madeira camarará. Por este motivo o valor final da previsão da itaúba ficou em 25 m³.

Vendas Itaúba(m ³)		
Período	Dezembro	Janeiro
2005/2006	32,95	23,38
2006/2007	40,91	41,03
2007/2008	41,01	48,51
2008/2009	23,54	16,35

Quadro C-3 Comparativo de vendas dezembro e janeiro – madeira itaúba.

Vendas Peroba (m ³)		
Período	Dezembro	Janeiro
2005/2006	60,51	48,29
2006/2007	27,96	33,37
2007/2008	51,03	62,91
2008/2009	56,83	79,26

Quadro C-4 Comparativo de vendas dezembro e janeiro – madeira peroba.

Ao observar-se o mesmo comparativo de vendas para a peroba, verifica-se que para esta madeira o equilíbrio entre os meses de dezembro e janeiro não é tão freqüente. Por ter conhecimento que esta análise não se adéqua para a peroba, o gerente aumentou o valor final da previsão para 48 m³. Este ajuste aumentou a acuracidade da previsão em 38%, restando somente 1% de erro.

Para o mês de março o gerente vislumbra um grande aumento nas vendas, por isso aumentou a previsão da itaúba para 35 m³ e da peroba para 60 m³. As vendas realmente aumentaram em março, confirmando as expectativas do especialista.

Em abril, os ajustes realizados também aumentaram as previsões da itaúba e peroba, para 42 m³ e 50m³, respectivamente. Segundo o especialista, a itaúba ficaria nos patamares previstos quantitativamente caso não tivessem ocorrido alguns pedidos grandes que mudaram o cenário. Além disso, outra justificativa seria que vários pedidos ficaram para entregar em abril por ter passado o limite da capacidade produtiva. Contudo, esta tendência não deve perdurar. Segundo o especialista, de maneira geral está ocorrendo queda nas vendas de itaúba pelo alto custo das obras. Os clientes estão optando por madeiras mais baratas como a peroba, que substitui a itaúba, e este é o argumento utilizado para ajustar a peroba.

A expectativa de aumento nas vendas da itaúba e peroba não se confirmaram em abril. Uma parcela da diferença na itaúba está em um pedido grande (aproximadamente 13 m³) que foi fechado no mês de abril, mas só foi entregue e faturado no mês de maio.

Nos meses seguintes o gerente seguiu a tendência de queda da itaúba e apostou no aumento da peroba substituindo esta essência. As previsões finais da itaúba ficaram em torno de 28 m³ e os resultados foram melhores que a previsão quantitativa. Para a peroba a perspectiva de aumento não se confirmou ao longo dos meses, o que resultou erros maiores em julho e agosto, meses de queda nas vendas.