

UNIVERSIDADE FEDERAL DE SÃO CARLOS
CENTRO DE CIÊNCIAS EXATA E DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE PRODUÇÃO

USO DE CONHECIMENTO TEÓRICO E DE ESPECIALISTA PARA
PREVISÃO DE DEMANDA

ANDREZA SILVA DIAS

UNIVERSIDADE FEDERAL DE SÃO CARLOS
CENTRO DE CIÊNCIAS EXATA E DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE PRODUÇÃO

USO DE CONHECIMENTO TEÓRICO E DE ESPECIALISTA PARA
PREVISÃO DE DEMANDA

Andreza Silva Dias

Exame de defesa apresentado ao Programa de Pós-Graduação em Engenharia de Produção da Universidade Federal de São Carlos, como parte dos requisitos para a obtenção do título de Mestre em Engenharia de Produção.

Orientador: Prof. Dr. Néocles Alves Pereira

SÃO CARLOS
2004

**Ficha catalográfica elaborada pelo DePT da
Biblioteca Comunitária da UFSCar**

D541uc

Dias, Andreza Silva.

Uso de conhecimento teórico e de especialista para
previsão de demanda / Andreza Silva Dias. -- São Carlos :
UFSCar, 2004.

181 p.

Dissertação (Mestrado) -- Universidade Federal de São
Carlos, 2004.

1. Planejamento da produção. 2. Previsão de demanda.
3. Inteligência artificial. 4. Sistemas especialistas
(computação). 5. Ajuste de previsão. I. Título.

CDD: 658.5038 (20^a)

DISSERTAÇÃO APRESENTADA À BANCA EXAMINADORA

Néocles Alves Pereira

DEP / UFSCar

(Presidente)

Maria Rita

DEP / UFSCar

(Membro)

Paulo Rogério Politano

DC / UFSCar

(Membro)

Fernando de Campos

UNIMEP

(Membro)

DEDICATÓRIA

A Deus e à minha maravilhosa família: José Roberto, Maria Luiza, Anelise, Adler e Douglas.

AGRADECIMENTOS

Esta dissertação foi concretizada graças ao estímulo de pessoas às quais eu admiro e devo expressar aqui o devido e profundo agradecimento.

Em primeiro lugar devo agradecer à minha família, Maria Luiza, José Roberto, Adler, Anelise e Doug, pelo apoio e incentivo na realização desta etapa da minha formação e sem a qual nada disto seria possível.

Ao meu orientador Néocles que me encorajou e estimulou durante todo o curso. A todos os professores presentes na banca, Politano e Fernando de Campos por suas importantes contribuições. Gostaria de agradecer a todos os colegas de departamento, mas em especial à professora Maria Rita e ao professor Flávio Fernandes que muito me ajudaram e incentivaram e sem os quais esta pesquisa não poderia ter sido realizada.

Devo um especial agradecimento Fabíola e à Companhia de Bebidas Ipiranga, que permitiram a realização do estudo de caso desta pesquisa.

Também gostaria de agradecer à todos os colegas do grupo de pesquisa Placop/Laserp: Gustavo, Fábio Azeka, Reinaldo, Vivian, Fábio, Zé Roberto, Ludmila, Taty e Karine.

Finalmente, gostaria de citar o apoio incondicional que recebi dos amigos que, com amizade e companheirismo, enaltecera a realização deste mestrado: Ana, Bia, Aretha, Erina, Tidi, Dani, Eli, Juliana, Isaías, Renato, Fabiana, Cris, Gamon, Natasha, Big, Marisa, Priscila, Vander, Nelson, Marco, Meiry, Jefferson, Erich, Bradock, Professor Dr. Dorival, Carlinhos, Paola, Leca, Mariângela e a todos os outros que não foram mencionados, mas que estão em meu coração.

Obrigado, Senhor, pelos dons recebidos, que propiciaram viver e aprender com todas as circunstâncias durante o curso e a realização do trabalho.

RESUMO

Em um mercado altamente competitivo como o atual, a administração da produção deve garantir que bens e serviços sejam fornecidos aos clientes em tempo adequado, para que ofereçam uma vantagem competitiva ou, pelo menos, possam ser vendidos por um preço que supere os custos de produção. Pode-se afirmar que uma das variáveis que determina o nível de serviço ao cliente é disponibilidade do produto – tanto em termos de rapidez, quanto quantidade. Uma função determinante para a disponibilidade de um produto ou serviço é a previsão de demanda, que observando os registros sobre vendas infere o possível comportamento dos consumidores para os períodos seguintes. A demanda é influenciada por fatores qualitativos e quantitativos, que não são considerados simultaneamente pelos métodos de previsão de demanda tradicionais. Assim, observando as tendências no uso de sistemas especialistas e a importância da previsão de demanda, esta pesquisa objetiva desenvolver o protótipo de um sistema especialista para previsão de demanda que combine métodos qualitativos e quantitativos. Para testar e analisar o desempenho do protótipo desenvolvido foi realizado um estudo de caso em uma indústria de refrigerantes. Este trabalho propõe uma adaptação ao método de ajuste de previsão quantitativa por julgamento para desenvolver o protótipo do sistema especialista para previsão de demanda. A previsão quantitativa é resultado da combinação das previsões geradas pelos métodos mais conhecidos. Os resultados obtidos a partir de testes realizados com dados coletados durante o estudo de caso confirmam que a utilização do julgamento como forma de ajuste de previsão de demanda obtida por meio de métodos quantitativos melhora a qualidade da previsão. Além disso, este trabalho permitiu comprovar que o conhecimento de um especialista que realiza a previsão de demanda por julgamento permite a construção de uma Base de Conhecimento de um Sistema Especialista.

Palavras Chave: Previsão de Demanda. Sistemas Especialistas. Ajuste de Previsão. Inteligência Artificial.

ABSTRACT

In a highly competitive market as the actual one, the production management must ensure that goods and services are supplied to the customers in right time, so they can offer a competitive advantage or, at least, can be sold by a price that surpasses the production costs. It can be affirmed that one of the variables which determines the service level, to the customer, is the product availability, such in rapidity terms, as the amount of the available product. A determinant function for the availability of a product or service is the forecasting, it analyses the records about the past sales and it infer the possible behavior of the consumers for the following periods. The demand is influenced by qualitative and quantitative factors that are not considered simultaneously by the traditional forecasting methods. Thus, observing the trends in the use of expert systems and the importance of the demand forecast, this research aims to develop an expert system for demand forecast that combines qualitative and quantitative methods. To test and to analyze the performance of the systems a case study in an industry of soft drink had been carried through. This work considers an adaptation to the method of quantitative forecast adjustment with judgment to develop an expert system for demand forecast. The quantitative forecast is outcome by the combination of the forecasts generated for the most known methods. The results obtained in the tests carried through with data that had been collected during the study case confirm that the use of judgment as adjustment form of forecasting obtained by quantitative methods improve the quality of the forecast. Moreover, this work allowed proving that the knowledge of an expert who calculates the forecasting using his own judgment allows the construction of a Knowledge Base of an Expert System.

Keywords: Forecasting. Expert Systems. Forecasting Adjustment. Artificial Intelligence.

SUMÁRIO

LISTA DE TABELAS	i
LISTA DE FIGURAS	iii
LISTA DE EQUAÇÕES	v
1 INTRODUÇÃO.....	1
2 PROJETO METODOLÓGICO.....	5
2.1 Introdução.....	5
2.2 Identificação do problema	6
2.3 Projeto Metodológico	6
2.3.1 Estudo de caso	10
2.4 Justificativa.....	15
2.5 Formas de integrar julgamento de especialista e métodos quantitativos de previsão de demanda.....	16
3 PREVISÃO DE DEMANDA.....	21
3.1 Introdução.....	21
3.2 Gestão da Demanda.....	21
3.3 Processo de Previsão da Demanda	23
3.4 Métodos de Previsão de Demanda	26
3.4.1 Métodos bayesianos.....	26
3.4.2 Métodos de média móvel.....	27
3.4.2.1 Média móvel ponderada	28
3.4.3 Métodos de suavização exponencial.....	29
3.4.3.1 Método de Holt.....	29
3.4.3.2 Método de Winters	30
3.4.4 Métodos de regressão	31
3.4.5 Modelos de Box-Jenkins	32
3.4.6 Modelos econométricos.....	33
3.4.7 Métodos de simulação	34
3.4.8 <i>Focus forecasting</i>	35
3.4.9 Métodos baseados em redes neurais.....	35
3.4.10 Cenários.....	38

3.4.11	Análise de impacto cruzado.....	39
3.4.12	<i>Survey</i> de Mercado	39
3.4.13	Delphi ou método de hierarquia de decisões.....	40
3.4.14	Julgamento de Especialista.....	41
3.5	Considerações Adicionais	42
3.5.1	Horizonte de planejamento.....	42
3.5.2	Erro	44
3.6	<i>Softwares</i> de Previsão de Demanda.....	46
3.7	Considerações sobre a Previsão de Demanda.....	50
4	SISTEMAS ESPECIALISTAS	52
4.1	Introdução.....	52
4.2	Principais conceitos	53
4.3	Base de Conhecimento	54
4.4	Métodos de aquisição do conhecimento.....	56
4.4.1	Representação do conhecimento	58
4.4.2	Mecanismo de Inferência.....	60
4.4.3	Interface com o Usuário	62
4.5	Desenvolvimento de Sistemas Especialistas	64
4.5.1	Identificação e Análise do Problema.....	65
4.5.2	Implementação do sistema especialista	67
4.5.3	Testes e manutenção.....	68
4.5.4	Shells	70
4.6	Sistemas Especialistas no ambiente industrial	72
4.6.1	Sistemas especialistas para previsão de demanda	74
5	PROTÓTIPOS DOS SISTEMAS ESPECIALISTAS PARA PREVISÃO DE DEMANDA.....	76
5.1	Introdução.....	76
5.2	Solução: sistema especialista para previsão de demanda	77
5.2.1	A escolha do shell.....	78

5.3	SEIMP – Sistema Especialista para Identificação dos Métodos de Previsão de Demanda.....	79
5.3.1	Combinação das previsões quantitativas	92
5.4	SEAP – Sistema Especialista de Ajuste da Previsão	95
5.4.1	Estudo de Caso	96
5.4.1.1	Caracterização da Empresa.....	96
5.4.1.2	Processo de Previsão de Vendas.....	100
5.4.1.3	Aquisição do Conhecimento.....	102
5.4.2	Base de Conhecimento do SEAP	104
5.4.3	Método de Construção da Base de Conhecimento do SEAP	113
5.5	Considerações finais.....	114
6	TESTES E AVALIAÇÃO DOS RESULTADOS.....	115
6.1	Considerações.....	115
6.2	Refrigerante lata: coca-cola 350ml.....	116
6.3	Refrigerante em embalagem <i>pet</i> de 600ml: coca-cola light	122
6.4	Refrigerante em embalagem <i>pet</i> de 2000ml: coca-cola.....	128
6.5	Refrigerante em embalagem de vidro retornável de 290ml (KS): coca-cola	133
7	CONCLUSÕES	140
8	REFERÊNCIAS BIBLIOGRÁFICAS	144
8.1	BIBLIOGRAFIA	153
	APÊNDICES	157
	APÊNDICE A	158
	APÊNDICE B – PESQUISA SOBRE PREVISÃO DE DEMANDA NAS EMPRESAS.	180

LISTA DE TABELAS

TABELA 3.1 – Modelos de Box-Jenkins.....	33
TABELA 3.2 – Métodos de Previsão de Demanda e Horizontes de Planejamento.....	42
TABELA 3.3 – Horizontes de Planejamento.	43
TABELA 3.4 – Caracterização dos Softwares de Previsão de Demanda.	47
TABELA 3.5 – Características Técnicas.....	48
TABELA 3.6 – Processo de Previsão de Demanda nos Softwares.....	48
TABELA 3.7 – Informações adicionais sobre os softwares.....	49
TABELA 4.1 – Exemplo de uma estrutura de <i>frame</i>	59
TABELA 4.2: Categorias de problemas para Sistemas Especialistas.....	66
TABELA 4.3 – Exemplos de sistemas especialistas na manufatura.	73
Tabela 5.1 – Relação entre os métodos de previsão de demanda e a tendência dos dados. .	81
TABELA 6.1 – Vendas de um tipo de refrigerante em lata no ano de 2002.....	116
TABELA 6.2 – Cálculo das previsões quantitativas para refrigerante em lata.	118
TABELA 6.3 – Previsões ajustadas pelo SEAP para refrigerante em lata.....	120
TABELA 6.4 – Previsões para refrigerante em lata.	120
TABELA 6.5 – Comparação dos erros das previsões para refrigerante em lata.	122
TABELA 6.6 – Vendas de refrigerante <i>pet</i> 600ml em 2002.	122
TABELA 6.7 – Cálculo das previsões quantitativas para refrigerante <i>pet</i> 600ml.	124
TABELA 6.8 – Previsões ajustadas pelo SEAP para refrigerante <i>pet</i> 600ml.	126
TABELA 6.9 – Previsões para refrigerante <i>pet</i> 600ml.	126
TABELA 6.10 – Comparação dos erros das previsões para refrigerante <i>pet</i> 600ml.....	128
TABELA 6.11 – Vendas para refrigerante <i>pet</i> 2 litros em 2002.....	128
TABELA 6.12 – Cálculo das previsões quantitativas para refrigerante <i>pet</i> 2 litros.	130
TABELA 6.13 – Previsões ajustadas pelo SEAP para refrigerante <i>pet</i> 2 litros.	131
TABELA 6.14 – Previsões para refrigerante <i>pet</i> 2 litros.	132
TABELA 6.15 – Comparação dos erros das previsões para refrigerante <i>pet</i> 600ml.....	133
TABELA 6.16 – Vendas de refrigerante embalagem KS em 2002.....	133
TABELA 6.17 – Cálculo das previsões quantitativas para refrigerante ks.	135
TABELA 6.18 – Previsões ajustadas pelo SEAP para refrigerante ks.....	137

TABELA 6.19 – Previsões para refrigerante ks.....	137
TABELA 6.15 – Comparação dos erros das previsões para refrigerante ks.....	139
TABELA A.1 – Dados do problema.....	162
TABELA A.2 – Função de autocorrelação amostral da série.....	162
TABELA A.3 – Resultados da diferenciação da série.....	163
TABELA A.4 – Função de autocorrelação amostral para a série diferenciada.....	164
TABELA A.5 – Função de autocorrelação parcial para a série diferenciada.....	165
TABELA A.6 – Resultados para a série, considerando o modelo ARIMA (2,1,0).....	167
TABELA A.7 – Função de autocorrelação amostral dos resíduos gerados pelo modelo ..	168
TABELA A.8: Previsões para os próximos 14 períodos.....	169
TABELA B.1 – Questionário.....	180
TABELA B.2 – Respostas.....	181

LISTA DE FIGURAS

FIGURA 2.1 – Passos do estudo de caso.	12
FIGURA 2.2 – Construindo o modelo de previsão usando julgamento de especialista.....	18
FIGURA 2.3: Combinação de previsões quantitativa e qualitativa.....	19
FIGURA 2.4: Ajuste por julgamento de uma previsão quantitativa.	19
FIGURA 2.5 Decomposição por julgamento.	20
FIGURA 3.1 – Gestão de demanda.	22
FIGURA 3.2 – Representação de um neurônio real e um artificial.	36
FIGURA 3.3: Exemplo de uma rede neural BP.	37
FIGURA 4.1 – Componentes básicos dos sistemas especialistas.	54
FIGURA 4.2 – Relacionamento dos participantes no desenvolvimento de um sistema especialista.....	57
FIGURA 4.3 – Exemplo de uma rede semântica	60
FIGURA 4.4 – Processo de desenvolvimento de um sistema especialista.....	65
FIGURA 5.1 – Método de previsão de demanda proposto.	76
FIGURA 5.1 – Componentes sazonais e de tendência da demanda.....	81
FIGURA 5.2 - Adicionar linha de tendência no Excel.....	84
FIGURA 5.3 – Linha de tendência a um conjunto de dados.	84
FIGURA 5.4 – Encadeamento da regras na base de conhecimento do SEIMP.	89
FIGURA 5.5 – Tela de abertura do SEIMP.....	90
FIGURA 5.6 – Exemplo de pergunta do SEIMP.	90
FIGURA 5.7 – Exemplo de explicação do SEIMP.	91
FIGURA 5.8 – Exemplo de aconselhamento do SEIMP.....	91
FIGURA 5.8 – Exemplo de árvore de pesquisa do SEIMP.....	92
FIGURA 5.9 – Tratamento da Água.	96
FIGURA 5.10 – Fabricação do Xarope.	97
FIGURA 5.11 – Despaletização.	98
FIGURA 5.12 – Engarrafamento.....	99
FIGURA 5.13 – Empacotamento.	99
FIGURA 5.14– Distribuição.	100

FIGURA 5.15 – Representação da Base de Conhecimento do SEAP.....	111
FIGURA 5.16 – Exemplo de pergunta de múltipla escolha do SEAP.	112
FIGURA 5.17 – Exemplo de pergunta de como o usuário informa um valor ao SEAP. ...	113
FIGURA 5.18 – Exemplo como o SEAP retorna a previsão semanal.	113
FIGURA 6.1 – Gráfico de comparação entre as previsões e a venda de refrigerante em lata.	121
FIGURA 6.2 – Gráfico de comparação entre as previsões e a venda de refrigerante <i>pet</i> 600ml.	127
FIGURA 6.3 – Gráfico de comparação entre as previsões e a venda de refrigerante <i>pet</i> 2 litros.	132
FIGURA 6.4 – Gráfico de comparação entre as previsões e a venda de refrigerante ks. ..	138
FIGURA A.1 – Gráfico da função de autocorrelação.	163
FIGURA A.2 – Gráfico da primeira diferenciação.	164
FIGURA A.3 – Gráfico da função de autocorrelação da primeira diferenciação da série.	165
FIGURA A.4: Gráfico da função de autocorrelação parcial para a série diferenciada.	166
FIGURA A.5 – Gráfico da função de autocorrelação dos resíduos gerados pelo modelo.	168
FIGURA A.6 – Demanda no aeroporto de Rhodes	170
FIGURA A.7 – Exemplo de gráfico de simulação.....	172

LISTA DE EQUAÇÕES

(3-01)	27
(3-02)	27
(3-03)	27
(3-04)	28
(3-05)	29
(3-06)	30
(3-07)	30
(3-08)	30
(3-09)	30
(3-10)	30
(3-11)	31
(3-12)	31
(3-12)	31
(3-13)	32
(3-14)	32
(3-15)	32
(3-16)	37
(3-17)	38
(3-18)	44
(3-19)	45
(3-20)	45
(3-21)	45
(3-22)	45
(5-01)	93
(5-02)	94
(5-03)	94
(5-04)	94
(5-05)	94
(A-01)	162

(A-02)	163
(A-03)	165
(A-04)	166
(A-05)	167
(A-06)	168
(A-07)	169
(A-08)	173
(A-09)	174
(A-10)	174
(A-11)	174
(A-12)	174

1 INTRODUÇÃO

As empresas estão se integrando na economia mundial por meio de alianças com outras empresas, instituições governamentais e universidades. Os mercados estão mudando rapidamente, se fundindo e se superpondo uns aos outros, deixando de ser distintos e separados. O mundo de Adam Smith e sua forma de fazer negócios são paradigmas do passado. ROBERTSON (1994) define globalização como a concretização do mundo inteiro como um único lugar, se referindo tanto à compreensão do mundo quanto à intensificação da consciência do mundo como um todo. Com o auxílio de uma série de tecnologias, como avanços nas telecomunicações e difusão da internet, foi possível transpor as barreiras físicas dos países com maior facilidade.

Com a globalização dos mercados, os concorrentes oferecem, em grande escala, bens e serviços com elevados níveis de qualidade e baixos custos. As exigências do comércio em termos de velocidade e exatidão levaram muitas empresas a repensar seus processos, transformando velhas estruturas menos produtivas em estruturas ágeis e flexíveis. Esta transformação representa o dinamismo que a conjuntura atual impõe a todas as organizações.

Juntamente com as pressões pela eficiência, os clientes passaram a exigir novos serviços e produtos personalizados, com características específicas e qualidade superior. Para atender tais necessidades as empresas investiram nas áreas de Marketing e Pesquisa & Desenvolvimento, para que suas atividades de lançamento de produtos inovadores sejam mais precisas e ágeis e lhe tragam vantagem competitiva no atual mundo dos negócios. O mesmo pode ser dito a respeito daquelas que apostaram no desenvolvimento de tecnologias de processo mais avançadas, procurando diminuir os estoques e melhorar o fluxo da produção, otimizando o uso dos recursos fabris.

Em termos de planejamento, dentro da gestão da produção os avanços ocorridos têm sido significativos. Busca-se um compromisso entre a necessidade de focalização na gestão de suas operações e obtenção de resposta rápida e flexível às flutuações do mercado, tanto nos processos produtivos de baixo custo e alta qualidade, quanto na troca e utilização das informações.

As atividades de Planejamento e Controle da Produção estão sendo agilizadas e racionalizadas e a função de previsão, responsável pelas estimativas sobre o futuro, deve ser tratada com mais atenção. Não é possível planejar a produção com efetividade se a previsão é negligenciada, pois é a atividade que antecede o planejamento ou re-planejamento das operações. Quando não existe integração dos setores de uma empresa, cada área funcional desenvolve suas próprias previsões a partir da interpretação das observações históricas sob uma ótica local e com diferentes níveis de agregação no processo de decisão. Se as informações não são compartilhadas, um desvio no padrão de uma operação pode passar despercebido, comprometendo a qualidade da previsão. E, para SHOBRY & WHITE (2000), a efetividade do processo de previsão não é função da exatidão, mas também na habilidade de identificar e reagir a desvios significativos dos padrões normais.

A melhor prática, portanto, é a criação de uma única função que dá suporte a todos os setores, produzindo previsões que podem combinar técnicas estatísticas e de inteligência do negócio, em um processo colaborativo. A integração das previsões das diferentes unidades funcionais com as ordens de produção fornece uma melhor visibilidade da demanda (CORRÊA et al., 1997). O planejamento das operações ou planejamento da produção necessita de uma estimativa da demanda por produtos e serviços que a empresa deverá atender em um período futuro. Assim, pode-se concluir que deve haver uma integração entre o planejamento e a previsão para o bom funcionamento da empresa.

Segundo WINKLHOFER et al. (1996), a previsão de demanda é essencial para a tomada de decisão e sua crescente importância é refletida por um aumento do nível de investimento, na contratação de profissionais das áreas de pesquisa operacional e de estatística e na compra de *softwares*. Os mesmos autores afirmam que as possíveis causas para a importância da previsão da demanda para as organizações são:

- a. A crescente complexidade das organizações e seus ambientes de atuação dificultam a tarefa dos tomadores de decisão, pois devem levar em consideração os diversos fatores que envolvem uma situação futura;
- b. As organizações estão tomando as decisões de forma mais sistemática, o que envolve justificativa das ações; e,

- c. O desenvolvimento dos métodos de previsão e das ferramentas para suas aplicações práticas permitem que as pessoas possam ter maior facilidade de acesso e uso.

Vários métodos foram desenvolvidos para a estimativa da previsão da demanda. Segundo NAHMIAS (2001) estes métodos podem ser agrupados em duas categorias principais:

- a. Quantitativa (objetiva): os métodos são baseados no julgamento humano; e,
- b. Qualitativa (subjetiva): os métodos se baseiam na análise de dados históricos para fazer a previsão.

Contudo, WRIGHT (1996) afirma que todos os métodos, até os quantitativos, envolvem algum tipo de julgamento, pois, mesmo sendo baseados em cálculos matemáticos e estatísticos complexos, recorrem a métodos de julgamento para ajustar as séries temporais, removendo situações atípicas da demanda causadas por promoções, fenômenos climáticos ou modificações de natureza econômica ou mercadológica.

Recentemente, os pesquisadores dirigiram sua atenção para métodos alternativos às técnicas clássicas de previsão de demanda, desenvolvendo sistemas baseado em inteligência artificial, como sistemas especialistas. “Um Sistema Especialista é um programa de computador que emula o comportamento de um especialista humano em um domínio bem definido de conhecimento” (LIEBOWITZ, 1995). Os sistemas especialistas utilizam o conhecimento de um especialista sobre técnicas e dados a respeito de uma situação. Assim, um sistema especialista para previsão de demanda permite aos gerentes usar seu conhecimento na estimativa das vendas da empresa (ARMSTRONG & YOKUM, 2001) de forma sistêmica e combinada com métodos objetivos de previsão.

Assim, observando as tendências e melhores práticas, esta pesquisa tem por objetivo o desenvolvimento de um protótipo de sistema especialista, para previsão de demanda, combinando métodos de previsão qualitativos ou subjetivos e quantitativos ou objetivos.

Esta pesquisa propõe, então, que a previsão de demanda seja realizada combinando métodos objetivos e subjetivos, em um processo de duas etapas. Na primeira

etapa, a partir da identificação de certas características dos dados históricos do produto, os métodos objetivos mais adequados são identificados. As previsões obtidas a partir destes métodos são então combinadas e, na segunda etapa, a previsão resultante é ajustada com o uso de conhecimento de especialista sobre as características específicas do produto e do mercado, que são critérios qualitativos.

No desenvolvimento do método proposto identificou-se a necessidade do desenvolvimento de dois sistemas especialistas, com uso integrado a uma planilha eletrônica que realizasse os cálculos matemáticos necessários. O primeiro sistema especialista aponta quais os métodos objetivos de previsão demanda que são mais adequados e o segundo sistema ajusta a previsão objetiva para incorporar o conhecimento do especialista e com isto procurar diminuir o erro, ou seja, a diferença entre a previsão e a venda. Para o desenvolvimento do segundo sistema especialista, considerou-se um estudo de caso em uma indústria de refrigerantes para levantamento dos dados, testes e avaliação da eficiência do método proposto.

A dissertação estará organizada da seguinte forma: o capítulo 2 identifica o problema de previsão de demanda a ser solucionado, justifica a proposta de solução e apresenta o projeto metodológico. O capítulo 3 discute os conceitos e a importância da previsão de demanda, apresentando uma revisão sobre algumas das técnicas existentes e o capítulo 4 aborda os conceitos de sistemas especialistas, discutindo suas características e aplicações. O capítulo 5 aborda questões relativas aos protótipos desenvolvidos e o capítulo 6 discute os testes realizados, avaliando a eficiência do método proposto. O capítulo 7 traz as considerações finais.

2 PROJETO METODOLÓGICO

2.1 Introdução

A administração da produção deve garantir que bens e serviços sejam fornecidos aos clientes em tempo adequado, para que ofereçam uma vantagem competitiva ou, pelo menos, possam ser vendidos por um preço que supere os custos de produção. A falta ou atraso no fornecimento de um produto ou serviço implica na insatisfação ou até mesmo na perda do cliente. Da mesma forma, a sua disponibilidade em quantidade e tempo corretos pode aumentar a satisfação ou até mesmo ser determinante no ganho de novos clientes.

Existem programas específicos que automatizam a previsão de demanda, alguns dos quais são caracterizados no Capítulo 3, mas estes, apesar de implementarem técnicas mais “refinadas”, ou seja, consideram variáveis que podem alterar a demanda, porém estas não são combinadas e as previsões não são ajustadas a partir das particularidades do mercado e dos produtos das empresas.

Assim, observando as tendências no uso de sistemas especialistas e a importância da previsão de demanda, esta pesquisa objetiva desenvolver o protótipo de um sistema especialista para previsão de demanda e fornecer uma metodologia para a construção da base de conhecimento que armazena as características específicas dos produtos e do mercado da empresa. Para testar e analisar o desempenho do protótipo desenvolvido será realizado um estudo de caso. Como para LAKATOS & MARCONI (1995) a atividade científica deve ser uma ponte que conecta as teorias científicas e a observação da realidade, explicando-a, esta pesquisa se baseia em métodos de previsão de demanda e sistemas especialistas para preencher uma lacuna existente: a falta de sistemas de previsão de demanda que implementem ajuste, com uso de julgamento, as previsões baseadas em métodos quantitativos.

2.2 Identificação do problema

Observou-se que quando os métodos de pesquisa operacional para previsão de demanda são utilizados pelas empresas, eles geram previsões que não são satisfatórias, uma vez que não conseguem representar matematicamente todos os fatores que influenciam a demanda em uma situação real. Dessa forma há a necessidade de incorporar ao processo de previsão alguma técnica que considere os eventos e fatores intangíveis, também relacionados à demanda.

Foi constatado que a literatura disponível sobre metodologias de combinar conhecimento qualitativo e quantitativo para desenvolver um processo de previsão para uma empresa ainda é insuficiente. Assim o problema identificado é a falta de exatidão nas previsões de curto prazo calculadas por meio de métodos quantitativos por realizarem apenas a análise de dados históricos, uma vez que outros fatores intangíveis também são influentes nas vendas e não existe literatura disponível sobre combinar os métodos quantitativos e qualitativos, gerando previsões para a indústria de alimentos.

2.3 Projeto Metodológico

Segundo BERTO e NAKANO (1998):

“A metodologia da pesquisa provê subsídios ao planejamento e desenvolvimento sistematizado de uma investigação científica a respeito de um fenômeno observado na ‘realidade do mundo físico/material’. Utiliza um ou vários métodos combinados de observação, de maneira a aprender fatos e dados dessa realidade, com a intenção de entender, explicar e, se possível ou necessário, aplicá-la ou replicá-la em favor de outros eventos ou episódios semelhantes” (BERTO e NAKANO, 1998, p. 02).

Assim, a metodologia compreende os métodos de pesquisa empregados em um estudo. CERVO & BERVIAN (1983) afirmam que método é a ordem que se deve

impor aos diferentes processos necessários para atingir um fim dado ou um resultado desejado. O método é o caminho escolhido para se desenvolver a pesquisa.

Para LAKATOS & MARCONI (1995) o método científico moderno é a investigação científica que cumpre seus objetivos através de etapas. BUNGE (1980) propôs as seguintes etapas:

- i. Identificação de um problema em uma área do conhecimento.
- ii. Contextualização do problema.
- iii. Identificação de conhecimento e instrumentos que possam resolver o problema.
- iv. Através do que foi identificado no passo anterior busca-se uma solução preliminar.
- v. Geração de novos conhecimentos que prometam resolver o problema.
- vi. Solução.
- vii. Análise da solução encontrada e exame de suas conseqüências.
- viii. Avaliação da solução obtida, confrontando-a com as teorias e informações empíricas existentes.
- ix. identificação e correção das causas que geraram a solução incorreta.

Segundo BERTO e NAKANO (1998) a pesquisa pode ser classificada em duas categorias abrangentes: quantitativa e qualitativa, quanto os métodos que utiliza. Segundo os autores, na abordagem quantitativa, o pesquisador, usando dedução, formula hipóteses baseadas na teoria, analisando algum aspecto particular da realidade. Uma das grandes preocupações é a medição objetiva dos resultados. Já o principal objetivo da pesquisa qualitativa é o estudo dos fenômenos através de descrição e interpretação, aproximando assim a teoria e a prática (BERTO e NAKANO, 1998). O pesquisador preocupa-se com os dados descritivos do fenômeno.

Pode-se identificar duas fases no presente trabalho, que correspondem às abordagens discutidas anteriormente:

1ª. A primeira fase caracteriza-se por ser uma pesquisa quantitativa. Inicialmente levantou-se problemas na literatura. Ao se decidir pelo tema de previsão de demanda, foi pesquisado material e dados que pudessem ser usados para justificar a escolha do problema e a identificar uma possível solução.

2ª. A fase seguinte consiste no desenvolvimento de uma solução através da definição e diagnóstico do problema e sua aplicação na prática, analisando e discutindo os resultados obtidos, através de uma abordagem qualitativa.

Além de identificar as características da pesquisa, que vão auxiliar a escolha das técnicas de coleta de dados, existe a necessidade de um projeto, para orientação de desenvolvimento e análise para conclusão. Este projeto deve definir, com clareza, o problema motivador da investigação, o referencial teórico que a suportará e a metodologia a ser empregada. (VERGARA, 2000). A autora afirma que um projeto de pesquisa deve ser composto de: problema chave, um objetivo geral, objetivos específicos, questão de pesquisa, proposições ou hipóteses e delimitação do estudo. É a partir da definição destes elementos que se desenvolverá a espinha dorsal da pesquisa.

O primeiro passo para o desenvolvimento do projeto é a escolha do tema da pesquisa, que é, segundo LAKATOS & MARCONI (1995), o assunto sobre o qual se deseja desenvolver uma pesquisa. A partir do tema, que é abrangente, se determina uma posição mais específica, ou seja, qual a questão que se pretende solucionar (LAKATOS & MARCONI, 1995). Assim, problema chave é uma questão não resolvida, é algo para o qual se deve buscar uma resposta através da pesquisa (VERGARA, 2000).

Se o problema é uma questão a investigar, o objetivo é um resultado a alcançar (VERGARA, 2000). Dessa maneira, ao se desenvolver a pesquisa e alcançar seu objetivo, será encontrada uma resposta ao problema proposto. Os objetivos intermediários são metas que, se atingidas, contribuem para o alcance do objetivo final (VERGARA, 2000).

A partir da definição do problema pode-se fazer a pergunta que será respondida pela pesquisa e que deve ser definida de forma clara e operacional. Hipóteses ou suposições são a antecipação da resposta ao problema e a sua investigação é realizada de modo a confirmar ou, ao contrário, refutar a hipótese ou suposição (VERGARA, 2000). Dessa forma, as hipóteses traçadas vão compondo um roteiro para a busca da conclusão.

Outro item de um projeto de pesquisa é a delimitação do estudo, que se refere à moldura que o autor coloca ao estudo, trata de fronteiras concernentes a variáveis, aos pontos abordados, ao corte, ao período de tempo e ao objeto da investigação

(VERGARA, 2000). A relevância do estudo reflete as contribuições de ordem prática ou ao estado da arte na área da pesquisa (VERGARA, 2000).

Os itens do projeto para esta pesquisa são:

- ✓ Tema:
 - Previsão de demanda usando conhecimento teórico (acadêmico) e de especialista (prático).
- ✓ Problema chave:
 - Utilização de sistemas especialistas como ferramentas para a solução de problemas de previsão de demanda, permitindo a combinação de conhecimento acadêmico e de especialista.
- ✓ Objetivo geral:
 - Desenvolvimento de dois sistemas especialistas para previsão de demanda que combinem conhecimento teórico e de especialista, ajustando, com base em critérios qualitativos, uma previsão gerada por métodos quantitativos.
- ✓ Objetivos específicos:
 - Estudo da Previsão de Demanda, sua importância para as empresas e quais as soluções existentes nas empresas.
 - Estudo dos métodos de previsão de demanda, suas características e requisitos para aplicação.
 - Avaliação das contribuições do uso de Sistemas Especialistas no processo de previsão da demanda em uma empresa.
 - Estudo de métodos de combinação de previsões geradas por técnicas quantitativas.
 - Levantamento de como os Sistemas Especialistas podem ser usados no processo de previsão de demanda e como podem ser integrados com os métodos estatísticos tradicionais.
- ✓ Questão da pesquisa:
 - O uso de um sistema especialista para ajuste de previsão de curto prazo resultante da combinação de métodos de quantitativos diminui a diferença entre o valor real da demanda e o que foi previsto?

- ✓ Hipóteses:
 - H1: A utilização do julgamento como forma de ajuste de previsão de demanda obtida por meio de métodos quantitativos melhora a qualidade da previsão.
 - H2: Os métodos tradicionais da Pesquisa Operacional para Previsão de Demanda não atendem a todas as expectativas dos tomadores de decisão em um ambiente industrial.
 - H3: O conhecimento utilizado no julgamento de uma previsão gerada por métodos quantitativos permite, por si só, a construção de uma Base de Conhecimento de um Sistema Especialista.
- ✓ Delimitação:
 - O protótipo desenvolvido gerará previsões de curto prazo e os métodos quantitativos de previsão de demanda utilizados no desenvolvimento da solução proposta se limitam àqueles mais citados na literatura, bem como a implementação não seja complexa.
- ✓ Relevância:
 - A previsão de demanda, muitas vezes, é um fator crítico de sucesso para o faturamento de uma empresa, ou seja, um fator do qual depende o sucesso ou fracasso de um empreendimento. Assim o desenvolvimento de um método que diminua a diferença entre o valor real e o previsto contribui para a sobrevivência da empresa.

2.3.1 Estudo de caso

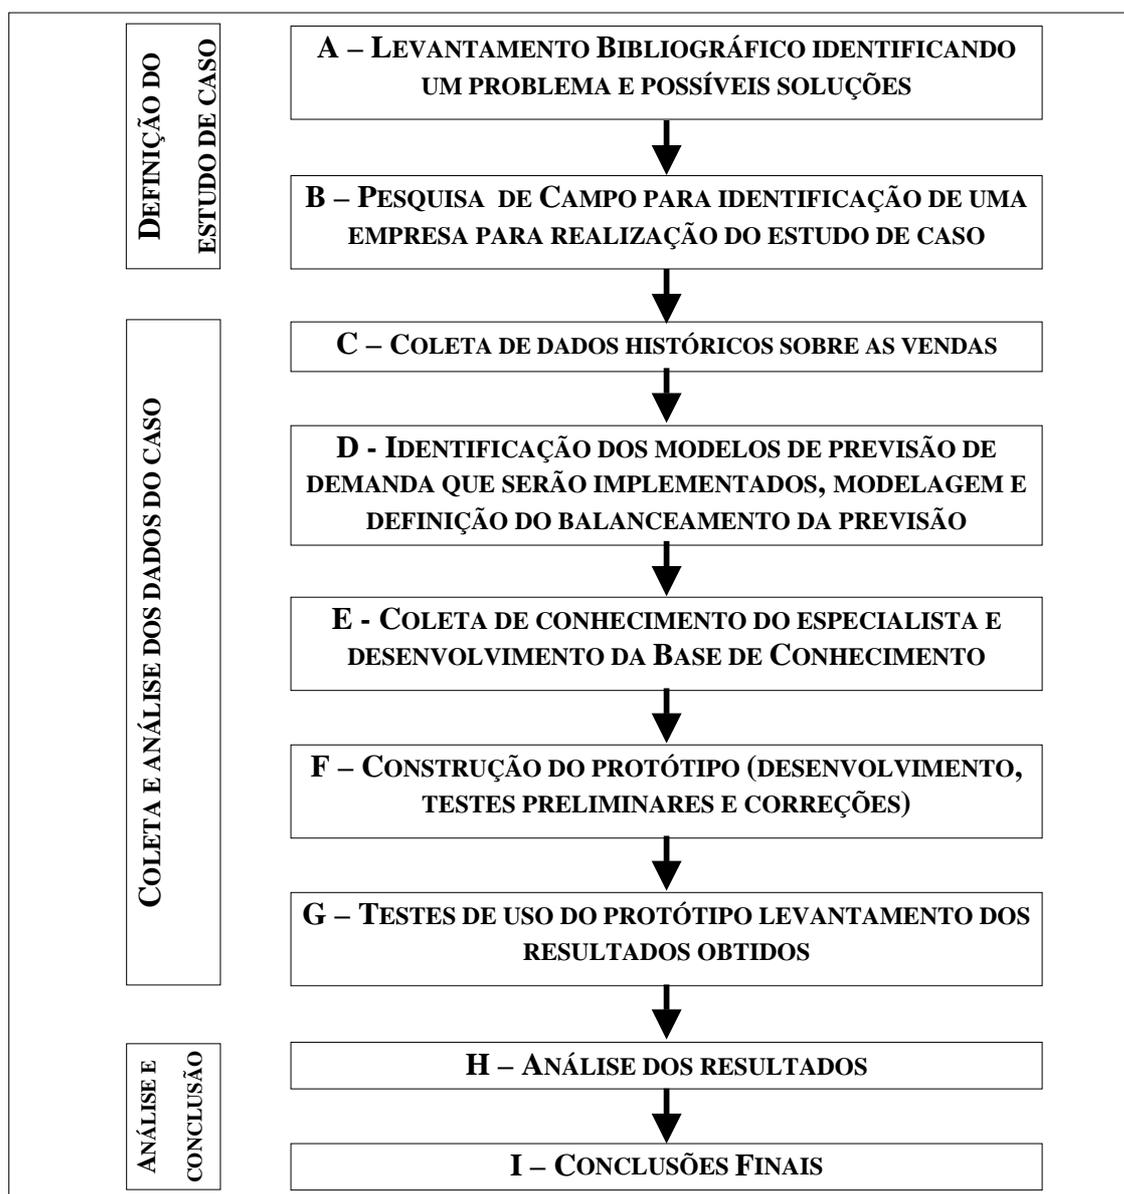
Para LÜDKE & ANDRÉ (1986) o método de estudo de caso é o estudo de um caso em particular feito com contornos claramente definidos. Para sua realização, inicialmente, deve-se obter um quadro inicial teórico, que servirá como esqueleto para que novos elementos sejam identificados. Durante a realização do estudo, o pesquisador tem acesso a várias formas de dados, coletados em diferentes momentos, em situações variadas, enfatizando a complexidade natural das situações e evidenciando as relações das variáveis

da situação que está sendo estudada (BRYMAN, 1995). Após a coleta de dados é feita uma análise para se provar, ou refutar, uma hipótese.

YIN (1994) afirma que as questões relevantes para a formulação de um estudo de caso são:

- ✓ Como definir o caso a ser estudado?
 - Inicialmente foi feito um levantamento bibliográfico sobre previsão de demanda e sobre sistemas especialistas, identificado um possível problema a ser estudado e possíveis soluções com o uso de julgamento. Uma rápida pesquisa de campo foi feita para identificar uma situação real para estudo: identificação de uma empresa que fornecesse dados para o desenvolvimento da solução proposta e para realização de coletas de dados.
- ✓ Como definir quais os dados relevantes e como coletá-los?
 - O levantamento bibliográfico identifica quais dados são necessários para a construção do protótipo, ou seja, quais os dados são utilizados para o processo de previsão de demanda. Esses dados são observações históricas da demanda, quais as características dos produtos quais os fatores que influenciam a demanda. Durante os testes do protótipo, os dados levantados são os dados sobre a situação, quais os fatores que estão influenciando a demanda naquele momento e sobre os resultados, quais foram os valores previstos e qual foi a demanda real.
- ✓ Como analisar os dados coletados?
 - Os dados levantados em um primeiro momento serão analisados para a construção do protótipo de previsão de demanda proposto, assim, serão utilizados na construção dos modelos identificados na literatura. Os dados relativos aos testes servirão para verificar se o protótipo desenvolvido tem um comportamento adequado, ou seja, reage de maneira correta em determinadas situações, e se as previsões estão próximas da demanda real. Essa avaliação será confrontada com as hipóteses formuladas para refutá-las ou confirmá-las e assim concluir se a solução proposta resolve o problema identificado.

O estudo de caso da pesquisa é composto pelos passos identificados na FIGURA 2.1.



Fonte: YIN (1984).

FIGURA 2.1 – Passos do estudo de caso.

Os métodos de levantamento e coleta de dados utilizados na pesquisa são:

- ✓ Para VERGARA (2000) a pesquisa de campo é uma investigação empírica realizada em um local onde se possa coletar dados sobre fenômeno para explicá-lo.
 - A pesquisa de campo foi útil para a identificação da empresa na qual será desenvolvido o estudo de caso e será realizada para coleta de dados para a construção do protótipo e no teste do mesmo.
- ✓ Questionário é o meio utilizado para obter respostas a questões impressas, no qual o informante preenche (GOODE & HATT, 1979). O questionário pode ser enviado para o informante e este o remete para o pesquisador quando terminar de preencher. As questões devem ser claras e bem redigidas, para que o informante não tenha dúvida ao responder. Além disso, na sua formulação a questão não deve induzir a uma resposta ou deixar o informante constrangido.
 - O questionário foi a forma escolhida para o levantamento de dados da pesquisa que está no Anexo B.
- ✓ O método de análise documental ou levantamento bibliográfico consiste na seleção e análise de material bibliográfico com o objetivo de identificar as informações factuais, a partir de questões ou hipóteses de interesse (LÜDKE & ANDRE, 1986). São levantados materiais aos quais o público em geral tem acesso (VERGARA, 2000). O primeiro ponto que deve ser considerado é sobre quais fontes devem ser consideradas. Coletar e analisar material de vários autores e fontes dá uma visão abrangente sobre o assunto e diminui o risco de se ignorar algum material importante.
 - A revisão bibliográfica da pesquisa foi feita sobre Sistemas Especialistas e Previsão de Demanda e está apresentada nos Capítulos 3 e 4. As fontes consideradas foram: livros, publicações científicas e materiais disponíveis eletronicamente em bases de dados como *ScienceDirect* e *Emerald*.
- ✓ Observação é um método de coleta de dados produzidos por um comportamento não-verbal, que embora envolva coleta de dados visuais, também inclui coleta através de outros sentidos, como audição, tato ou gustação (BRYMAN, 1995). Esta técnica permite que o observador tenha a perspectiva da visão de mundo do sujeito

que desempenha uma ação, ou seja, o significado por ele atribuído às suas ações e ao que o cerca (LÜDKE & ANDRE, 1986). O pesquisador que irá realizar a coleta de dados pode participar de forma regular das atividades observadas ou, por outro lado, ser não-participante, não interferindo na situação observada (ALVES-MAZZOTTI & GEWANDSZNAJDER, 1998).

- Na pesquisa a observação vai ser um dos métodos de aquisição de conhecimento do especialista, observando ele desenvolve as previsões e como são tomadas as decisões relativas a elas.
- ✓ LÜDKE & ANDRÉ (1986) afirmam que a entrevista é uma relação de interação, na qual há influência recíproca entre quem pergunta e quem responde. A entrevista pode ser conduzida de várias formas: desde uma conversa totalmente desestruturada até a um questionamento que segue, de forma rígida, uma série de perguntas elaboradas anteriormente. Segundo LÜDKE & ANDRÉ (1986), o entrevistador deve ouvir atentamente o informante e deve ser cauteloso para que suas perguntas não antecipem ou provoquem determinadas respostas. Além de ouvir, o entrevistador deve estar atento à comunicação não verbal, como gestos, expressões, entonações e hesitações (LÜDKE & ANDRÉ, 1986). A observação dessas manifestações é importante para a compreensão e validação do que foi dito pelo entrevistador. Outro ponto importante é o grau de conhecimento sobre o assunto abordado, tanto por parte do entrevistador, quanto do informante, pois quanto mais o entrevistado conhecer sobre o tema, mais proveitosa será a entrevista, levantando as informações desejadas e fazendo as intervenções necessárias.
 - A entrevista foi a outra forma de aquisição de conhecimento utilizada nesta pesquisa. Através da entrevista com o especialista, poderão ser levantadas as formas como ele faz as previsões de demanda e identificação do seu conhecimento sobre os produtos e o mercado da empresa.
- ✓ Pesquisa experimental é uma investigação empírica na qual o pesquisador manipula variáveis, em um ambiente controlado, e observa como essa manipulação afeta determinados pontos de seu interesse (VERGARA, 2000).

- A pesquisa experimental será realizada para testar o protótipo desenvolvido em uma situação real, tanto no seu desenvolvimento quanto no teste para validação da solução (prova da sua contribuição).

2.4 Justificativa

Em uma pesquisa feita em dez empresas de médio e grande porte, a previsão de demanda é feita sem o auxílio de um programa específico, mas com base em análises manuais dos dados ou em planilha Excel. Duas, das empresas pesquisadas são do tipo produção por encomenda, assim a função de previsão de demanda não é importante e estas mantêm pequenos estoques dos materiais mais utilizados. Mais informações sobre esta pesquisa podem ser encontradas no Apêndice B.

Quando a previsão é feita em planilha Excel, como no caso citado acima, alguns métodos quantitativos são considerados, mas, segundo GOODWIN (2002), em um ambiente dinâmico como o atual, tais métodos, para extrapolar padrões em séries de dados históricos, reagem vagarosamente às mudanças e, além disso, não conseguem lidar com eventos não triviais que modificam as observações. O autor ainda afirma que o julgamento é o método predominante porque não existe muita disponibilidade de mão-de-obra especializada para trabalhar com os métodos estatísticos e, além disso, o responsável pela previsão tem conhecimento adicional sobre as características do produto e do mercado. Assim, para facilitar este processo e essa utilização do julgamento foi formalizada pelo uso de sistemas especialistas.

Em seu artigo ARMSTRONG & YOKUM (2001) analisam um levantamento realizado em quatro grupos de profissionais especializados em previsão de demanda – pesquisadores (responsáveis pelo estudo e criação de técnicas), educadores (que ensinam as técnicas), profissionais (que implementam os métodos) e tomadores de decisão (que usam as informações sobre previsão de demanda para tomarem decisões) – compara três técnicas: *Box-Jenkins*, Cenários e Sistemas Especialistas. Os autores relatam que, neste levantamento, os apontamentos, de um modo geral, são mais favoráveis para a adoção de

Sistemas Especialistas do que para as outras duas técnicas. ARMSTRONG & YOKUM (2001) também afirmam que as perspectivas de adoção de Sistemas Especialistas foram mais altas entre os tomadores de decisão, o que se mostra promissor, visto que as outras duas técnicas são relativamente mais conhecidas.

Os sistemas especialistas desenvolvidos para previsão de demanda armazenam em sua base conhecimento de como realizar essas previsões através do julgamento de um especialista. Os métodos quantitativos para previsão de demanda são utilizados para comparação e análise das previsões.

Além disso, o desenvolvimento de um sistema de previsão, tradicionalmente, se ou em métodos quantitativos ou em métodos qualitativos. Porém ambos os métodos apresentam benefícios e características que podem aumentar a acurácia da previsão. Apesar da amostra da pesquisa realizada, e descrita no Anexo B, ser modesta pode-se notar a ausência de um procedimento formal que combine métodos qualitativos e quantitativos para elaborar a previsão da demanda. Desta forma, esta pesquisa propõe um sistema especialista para previsão de demanda que combine formalmente tanto métodos qualitativos, quanto quantitativos.

2.5 Formas de integrar julgamento de especialista e métodos quantitativos de previsão de demanda

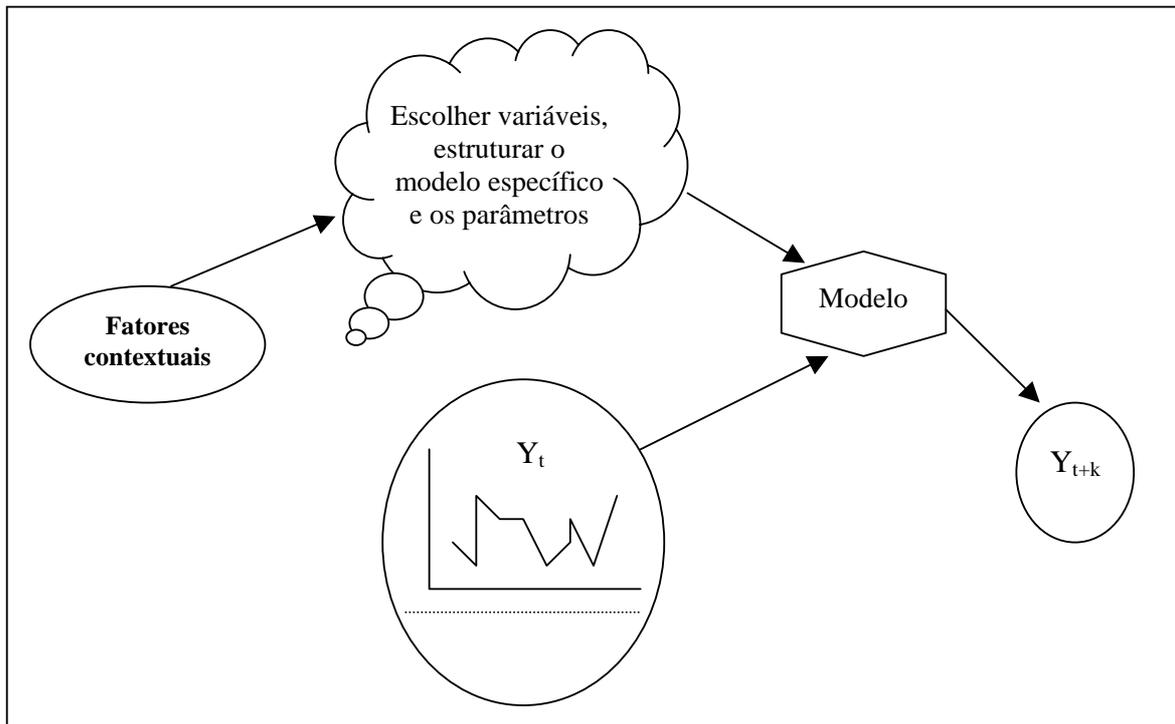
Segundo WEBBY & O'CONNOR (1996), as características do julgamento e do ambiente na previsão de demanda feita por especialistas são:

- ✓ Experiência: a avaliação da experiência que o especialista adquiriu na tarefa de fazer a previsão com modelos de pesquisa operacional. Os dois aspectos principais são o conhecimento técnico e causal, discutidos no Capítulo 3.
- ✓ Contexto: conhecimento que não é gerado pela experiência, mas ajuda na explicação, interpretação e antecipação do comportamento das séries. Existem duas formas de classificação:
 - Pistas: descreve os eventos especiais que não podem ser estruturados em um modelo.

- Informação informal: informação gerada através de conversas.
- ✓ Motivação: características do ambiente que levam ao rigor na aplicação da estratégia escolhida pelo especialista. Por exemplo, se a reputação dele está sendo posta a prova ou se a informação tem qualidade.

Conhecer essas características é um importante fator durante a aquisição do conhecimento do especialista para o desenvolvimento do sistema inteligente. Segundo WEBBY & O'CONNOR (1996) existem quatro maneiras de usar o julgamento do especialista no processo de previsão de demanda, que estão representados nas FIGURAS 2.2, 2.3, 2.4 e 2.5. Nestas figuras, os balões representam processos que envolvem julgamento, as elipses representam processos que envolvem cálculos matemáticos, os hexágonos representam a construção de um modelo para a previsão de demanda e os quadrados com cantos arredondados representam os processos de combinação.

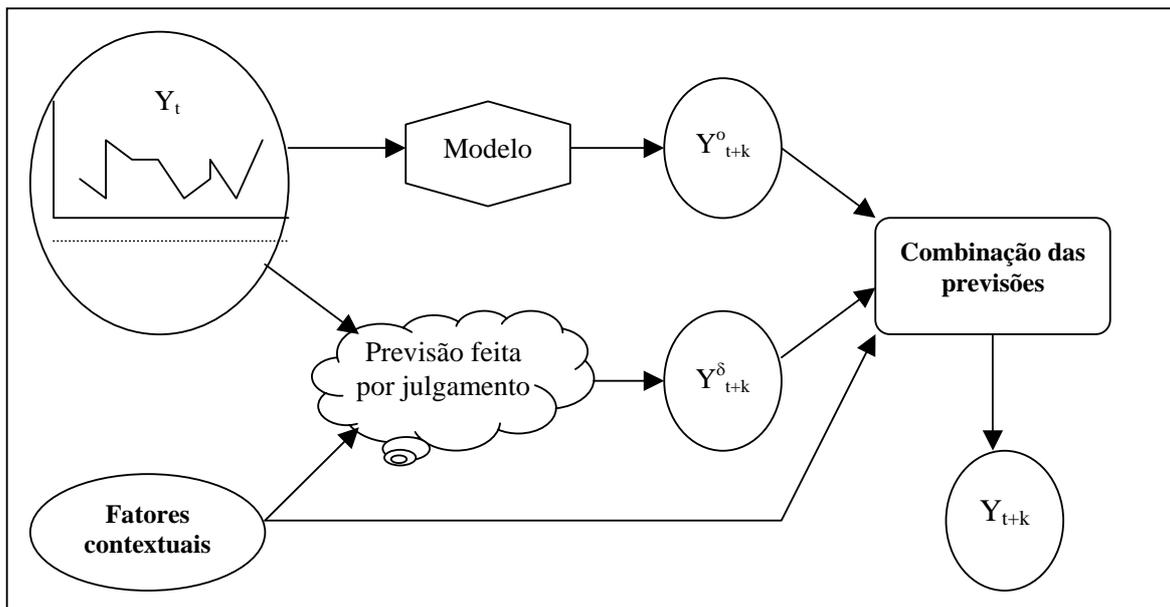
1. Na construção do modelo: nesta abordagem o julgamento é usado para escolher variáveis, especificar a estrutura do modelo e estimar os parâmetros, para que depois o modelo seja construído. Durante a especificação do modelo, o conhecimento informal pode ser incorporado depois de ser quantificado, por exemplo, com o uso de modelos econométricos ou com a identificação de eventos principais que afetam a demanda. Esse método é ilustrado na FIGURA 2.2.



Fonte: WEBBY & O'CONNOR (1996).

FIGURA 2.2 – Construindo o modelo de previsão usando julgamento de especialista.

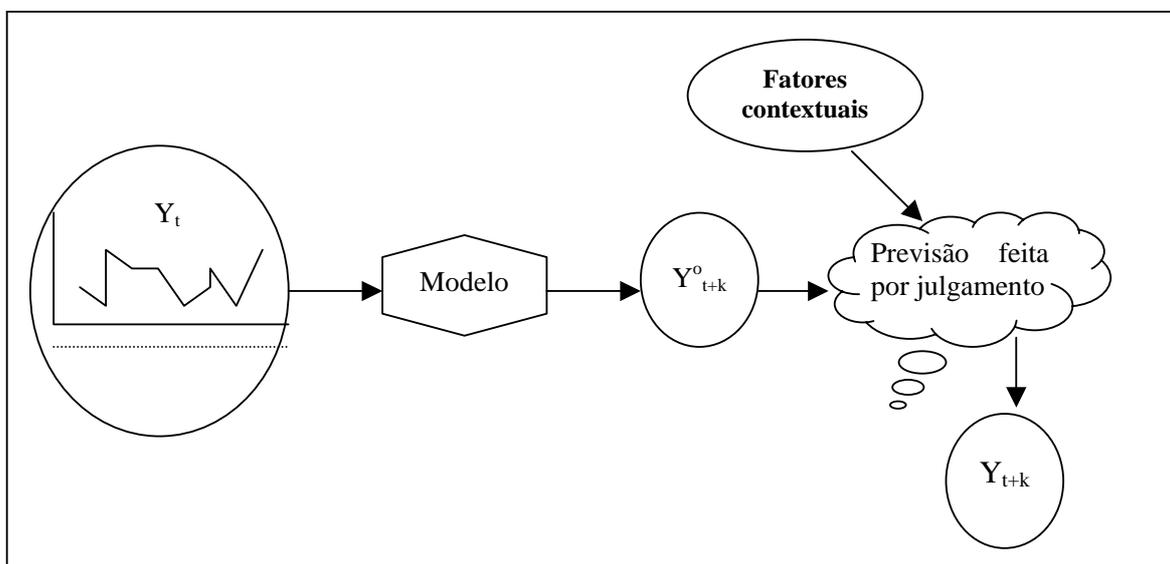
2. Combinação: um método quantitativo é combinado com um método qualitativo, na qual uma previsão subjetiva é obtida por séries temporais combinadas com informações ou outras variáveis causais, como pode ser visto na FIGURA 2.3. Neste método, a interpretação subjetiva é introduzida no processo de previsão de demanda.



Fonte: WEBBY & O'CONNOR (1996).

FIGURA 2.3: Combinação de previsões quantitativa e qualitativa.

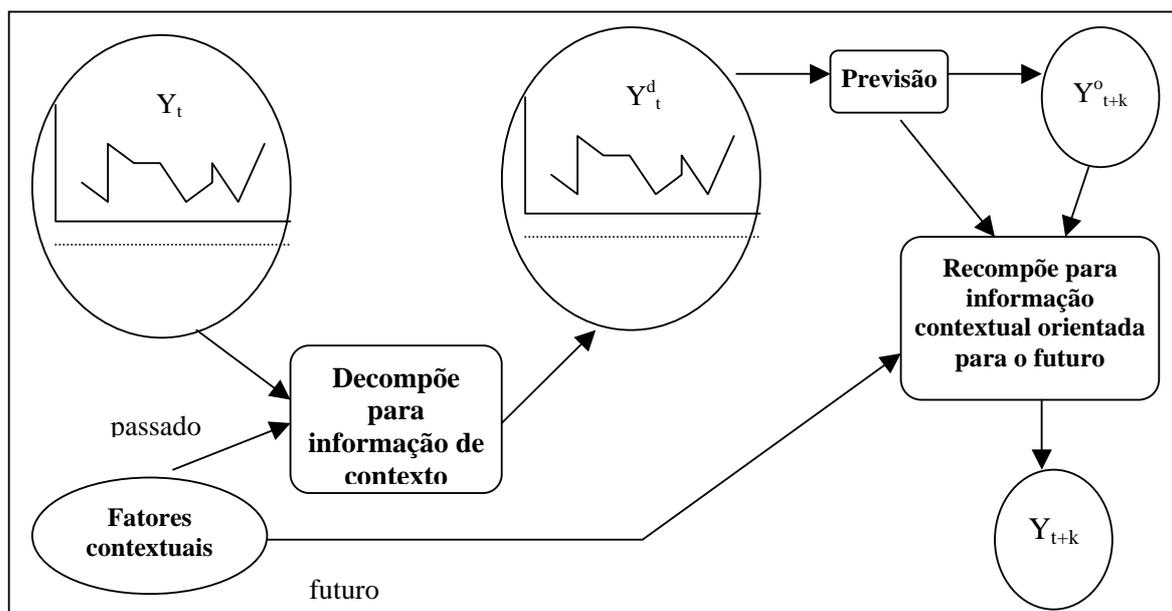
3. Ajuste: a previsão quantitativa é ajustada por fatores contextuais, pelo julgamento, e a previsão final é produzida, como mostra a FIGURA 2.4.



Fonte: Webby & O'Connor (1996).

FIGURA 2.4: Ajuste por julgamento de uma previsão quantitativa.

4. Decomposição: 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. Esse processo está ilustrado na FIGURA 2.5.



Fonte: WEBBY & O'CONNOR (1996).

FIGURA 2.5 Decomposição por julgamento.

Os sistemas especialistas são a forma de automatizar a integração do julgamento com métodos de pesquisa operacional para previsão de demanda. Essa integração é proposta para melhorar a acurácia das previsões feitas apenas por métodos quantitativos, pela consideração de fatores qualitativos na previsão.

3 PREVISÃO DE DEMANDA

3.1 Introdução

A seguir será apresentado como o processo de previsão de demanda é feito em uma empresa e como esse processo pode ser formalizado. Na seqüência é apresentada uma revisão sobre os principais métodos qualitativos e quantitativos de previsão de demanda. O capítulo contém ainda um levantamento sobre alguns *softwares* de previsão de demanda e faz algumas considerações sobre os métodos quantitativos e qualitativos apresentados, os horizontes de previsão e as formas de monitoramento das diferenças entre o que foi previsto e a demanda real.

3.2 Gestão da Demanda

Para NARSIMHAN et al. (1995) a Gestão da Demanda é a função da empresa que lida com as necessidades dos consumidores e a coordenação dos fornecedores, sendo assim, um dos elos de ligação entre o ambiente no qual a empresa está inserida, e o planejamento da produção. Ao lidar com os consumidores, a gestão da demanda identifica padrões de comportamento e tendências de consumo e então, planeja ações que podem estimular ou desacelerar as vendas, de acordo com os objetivos da empresa. A partir das perspectivas de vendas, a gestão da demanda pode, baseada em alguma técnica de planejamento, estimar os inícios e términos dos processos produtivos e então coordenar as atividades de compra com os fornecedores de forma que as matérias-primas estejam disponíveis no momento mais oportuno.

Segundo CORRÊA et al. (2001) a gestão de demanda inclui atividades em cinco áreas principais, como está representado na FIGURA 3.1.



Fonte: CORRÊA et al. (2001).

FIGURA 3.1 – Gestão de demanda.

Para CORRÊA et al. (2001) e VOLLMANN et al. (1997):

- ✓ A habilidade de previsão de demanda deve, considerando cálculos matemáticos de métodos de previsão e fatores internos, como promoções, e externos à empresa, como condições climáticas e econômicas, antecipar o comportamento da demanda, de forma que a produção possa corretamente planejada e, em consequência, os consumidores sejam atendidos da melhor forma possível.
- ✓ Pela habilidade de comunicação com o mercado, a gestão de demanda coleta informações que sejam úteis para o processo de previsão.
- ✓ A gestão de demanda deve ter a habilidade de influenciar tanto a demanda já concretizada, negociando novos prazos de entrega para o cliente, quanto a demanda que ainda vai acontecer, pelo uso de recursos de propaganda e marketing.
- ✓ Ao estar integrada com o processo produtivo, a gestão de demanda tem a habilidade de oferecer prazos de entrega confiáveis, que sejam razoáveis tanto para a empresa, quanto para os consumidores.
- ✓ Quando a demanda supera as expectativas e não pode ser imediatamente satisfeita, a gestão de demanda deve ter a habilidade de escolher como e quais clientes serão

atendidos inicialmente e, qual a seqüência de atendimento dos demais, priorizando e alocando os pedidos.

De todas estas habilidades, “*o processo de previsão de demanda é possivelmente o mais importante dentro da gestão demanda*” (CORRÊA et al., 2001, p.244), pois é base para o planejamento da produção e da programação das compras.

3.3 Processo de Previsão da Demanda

Previsão é o processo de se fazer inferências sobre o futuro, a partir de dados históricos (JOHNSON & MONTGOMERY, 1974) ou sobre as conseqüências de ações presentes. Uma outra forma de estimar um valor futuro é a predição de valores, ou seja, fazer uma estimativa subjetiva que envolve fatores qualitativos como mudanças na economia do país ou lançamento de produtos, dos quais não se tem muita informação como base.

A previsão de demanda projeta as necessidades futuras do mercado ou de consumidores específicos, definindo a demanda esperada considerando objetivos financeiros, medidas de desempenho e limitações e metas de outras funções. A realização da previsão de fatores incontrolláveis, como a demanda, antes da tomada de decisão seja feita, permite que se faça uma melhor escolha de ações e segundo MONTGOMERY & JOHNSON (1976) pode ser útil para:

- ✓ Controle de estoques: para o controle de estoques de materiais usados na produção é necessário que se saiba a taxa de uso de cada item;
- ✓ Planejamento financeiro: informações sobre a previsão de vendas possibilitam uma estimativa sobre o fluxo de dinheiro em caixa;
- ✓ Programação de recursos de transformação: sabendo o quanto vai ser necessário produzir, pode-se organizar de forma eficiente os funcionários e equipamentos para se obter um melhor desempenho; e,
- ✓ Planejamento de facilidades: a estimativa das atividades das facilidades que uma organização possui, permite a ela decidir se há necessidade de desativar uma

facilidade ociosa ou criar uma nova facilidade para melhorar o atendimento aos clientes.

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: disponibilidade de dados e informação, custo da análise, exatidão a ser alcançada e necessidades da gerência. Outras características dependentes do problema de decisão são: (a) período – a unidade de tempo na qual a previsão será expressa; (b) horizonte – número de períodos futuros que serão cobertos pela previsão, e (c) intervalo – frequência com que a previsão vai ser realizada. O intervalo também é afetado pelo tipo de sistema de previsão.

A forma da previsão é afetada pelo tipo de informação que o processo de decisão necessita, como por exemplo, média, desvio padrão, probabilidade ou forma de distribuição, e pela apresentação desejada pelo tomador de decisão, podendo estar apresentada como variável discreta ou contínua. Além disso, a capacidade da administração para lidar com as fontes de incerteza determinará o nível de exatidão com que a informação deve ter e, conseqüentemente, irá afetar o sistema de previsão.

A análise dos dados disponíveis permite identificar se existe algum “fator causal”. Fator causal é algo que influencia os dados de uma forma conhecida e pode auxiliar no processo de previsão (SIPPER & BULFIN, 1998).

O comportamento dos dados a serem utilizadas também deve ser considerado. Se há estabilidade ou mudanças lentas, o sistema de previsão escolhido deve ser diferente do que se há instabilidade e grandes mudanças ocorrem com frequência. O comportamento constante pode ser assumido se o horizonte é muito pequeno ou se o produto já atingiu um estado de “maturidade” em seu ciclo de vida. Um processo de tendência pode ser identificado quando existe um padrão de variação nos dados, como no caso de produtos em fase de “crescimento” ou “declínio” em seu ciclo de vida. Quando o padrão se *repete* periodicamente, pode-se identificar um processo sazonal.

A disponibilidade dos dados é outro fator determinante. Dados históricos e informações sobre a situação atual devem estar disponíveis. Mas, observações sobre o futuro e sobre o comportamento do sistema de previsão também devem ser utilizadas para que possíveis melhorias possam ser efetuadas. As fontes de dados devem ser registros sobre compra e venda da companhia ou serem originadas de fontes governamentais ou comerciais. A economia do país, ações de concorrentes, lançamentos de produtos e comportamento dos consumidores são fatores externos à companhia que afetam a demanda. Fatores internos incluem qualidade, preço, descontos, tempo de entrega e propagandas promocionais.

Características como quantidade, exatidão e conveniência das informações também devem ser consideradas, assim como sua representatividade e importância. As habilidades e interesses dos usuários devem ser levados em conta, uma vez que a previsão deve ser apresentada de uma forma apropriada para que a gerência possa utilizá-la na tomada de decisão. A partir desta análise, vão ser escolhidos os métodos utilizados no desenvolvimento de um sistema de previsão, cuja meta principal será fornecer previsões com a exatidão apropriada, na hora certa e a um custo razoável.

Para a partir do método, ou métodos escolhidos um processo formal de previsão de demanda é desenvolvido. Para tanto é necessário que informações sejam coletadas, e dependendo da escolha, parâmetros e variáveis devem ser estimadas. Depois de ser desenvolvido, o processo deve ser constantemente monitorado para se verificar se as previsões que estão sendo feitas, são acuradas e estão próximas da demanda real. Caso a diferença, entre a previsão e as vendas, seja muito grande, é necessário que um novo processo de previsão seja desenvolvido, que pode ser baseado em um outro método de previsão.

Os métodos de previsão de demanda podem ser classificados em quantitativos e qualitativos. Os métodos qualitativos de previsão envolvem julgamento e estimativa subjetiva de um ou mais especialistas. Existem alguns procedimentos formais para se obter previsões desta maneira, mas a tarefa de previsão não é explícita, mas baseada na experiência. Os métodos quantitativos possuem uma lógica clara de definição da demanda através de operações matemáticas. Os procedimentos envolvem a análise de

observações para determinar as variáveis que representam o comportamento da demanda e usam este conhecimento para prever a demanda no futuro.

Os métodos quantitativos podem, ainda, ser divididos em duas categorias: séries temporais e métodos causais.

Séries temporais são uma seqüência temporalmente ordenada de observações de uma variável (MONTGOMERY & JOHNSON, 1976). Os métodos de séries temporais analisam dados históricos para determinar a forma de seu comportamento, assumindo que os fatores e os eventos, que existiram no passado e moldaram a demanda, continuarão existindo. Os métodos causais exploram a relação entre diversos fatores, procurando explicitar relações causais. Se outras variáveis têm correlação com a variável de interesse (demanda), então um modelo é construído para descrever essa relação.

O que diferencia o uso de uma ou outra técnica são as respectivas características de cada uma, o que será abordado na seção 3.4.

3.4 Métodos de Previsão de Demanda

Nesta seção são descritas algumas técnicas utilizadas para previsão de demanda. Cabe observar que não está no âmbito da pesquisa se aprofundar em cada um dos métodos, o que pode ser feito através de consulta à literatura citada no fim de cada item que descreve cada um dos métodos de previsão de demanda.

3.4.1 Métodos bayesianos

São úteis quando os dados históricos iniciais são insuficientes, sendo necessário, como primeiro passo, a estimativa subjetiva dos parâmetros a serem usados na previsão. Conforme novos dados sobre demanda tornam-se disponíveis, o Teorema de Bayes é utilizado para atualizar os parâmetros, até que se tenham dados suficientes para desenvolver um sistema de previsão permanente.

Supondo a equação da demanda como sendo:

$$d_t = a + \varepsilon_t \quad (3-01)$$

onde a representa o fator constante, d_t é a demanda no instante t e ε_t é o componente que representa o erro. O Teorema de Bayes pode ser aplicado para estimar a . A estimativa de Bayes para a é apenas uma média ponderada da média amostral e uma estimativa subjetiva de a (MONTGOMERY & JOHNSON, 1976), como pode se visto na equação 3-02.

$$a_t = \alpha \cdot d_t + (1 - \alpha) \cdot a_{t-1} \quad (3-02)$$

onde $\alpha = \frac{1}{u - t}$ e $u = \frac{\sigma_\varepsilon^2}{\sigma_o^2}$. A equação 3-02 é usada para calcular a estimativa de a que vai ser a previsão de demanda para o próximo período.

Um exemplo ilustrativo da aplicação do método pode ser encontrado no Apêndice A, exemplo A-01. A demonstração do teorema de Bayes e também informações adicionais sobre o método podem ser encontradas em: MONTGOMERY & JOHNSON (1976), BARBOSA (1989), WEST & HARRISON (1997), POLE et al. (1994), PILZ (1983) e BROEMELING (1985).

3.4.2 Métodos de média móvel

Estes métodos consideram apenas os n últimos períodos da série de dados históricos para fazer a previsão. A demanda média destes n períodos é calculada e usada como previsão de demanda para o próximo período. A cada iteração, o novo dado de demanda é acrescentado na análise e o dado mais antigo é descartado, e, assim, os dados mais antigos do que os n períodos considerados não têm influência sobre a previsão. A previsão é dada pela equação 3-03.

$$F_t = (1/N) \cdot \sum_{i=t-N}^{t-1} D_i \quad (3-03)$$

O comportamento do método é função da escolha do número de observações, se N é grande, a média móvel vai reagir lentamente às mudanças na demanda. Quando N é menor, a média móvel vai reagir mais rápido.

Um exemplo ilustrativo da aplicação do método pode ser encontrado no Apêndice A, exemplo A-02. Outras informações sobre o método podem ser encontradas em: MONTGOMERY & JOHNSON (1976), BUFFA & SARIN (1987), JOHNSON & MONTGOMERY (1974), NAHMIAS (2001), SIPPER & BULFIN (1998), MAKRIDAKIS et al. (1983) e BROWN (1962).

3.4.2.1 Média móvel ponderada

A média móvel dá um peso igual a cada observação passada da demanda usada na média. A média móvel ponderada permite que quaisquer pesos desejados sejam adicionados à demanda passada, permitindo que as observações da demanda sejam consideradas de diferentes formas na previsão. Uma média móvel ponderada de n períodos é definida da seguinte forma:

$$F_t = \sum_{i=t-N}^{t-1} C_i D_i \quad (3-04)$$

onde $0 \leq C_t \leq 1$, o que significa que C_t é uma fração usada como peso para o período t , e

$$\sum_{i=t-N}^{t-1} C_i = 1.$$

De maneira geral, maior peso é dado para a demanda mais recente e conseqüentemente a média móvel ponderada dá menos valor a informações mais antigas. Assim, a previsão tende a ser mais responsiva às mudanças no comportamento da demanda.

Alguns autores que apresentam mais informações sobre a média móvel ponderada são: MAKRIDAKIS et al. (1983), KRAJEWSKI & RITZMAN (1987), NARASIMHAN et al. (1995) e WINSTON (1994).

3.4.3 Métodos de suavização exponencial

A abordagem de suavização exponencial prevê a demanda para o próximo período considerando uma média ponderada da demanda atual e da previsão para o período atual, através da equação 3-05.

$$F_t = \alpha d_t + (1 - \alpha)F_{t-1} \quad (3-05)$$

onde F_t representa a previsão para o próximo período, d_t representa a demanda no período atual e a constante de suavização é $0 \leq \alpha \leq 1$. A constante de suavização é o peso atribuído à última observação. Essa constante determina o equilíbrio entre a sensibilidade das previsões às mudanças que ocorrem na demanda e conseqüentemente, a estabilidade das previsões. Quanto mais a constante for próxima de zero, mais a previsão atual será suavizada pela anterior.

A suavização exponencial exige que em cada estágio se tenha a previsão anterior, o que dificulta a inicialização do método. Pode-se assumir que a primeira previsão tenha sido igual à demanda. Como a suavização exponencial põe grande peso nas observações feitas, o valor inicial da demanda terá um grande efeito nas primeiras previsões.

Um exemplo ilustrativo da aplicação do método pode ser encontrado no Apêndice A, exemplo A-04. Outras informações sobre o método podem ser encontradas em: MONTGOMERY & JOHNSON (1976), BUFFA & SARIN (1987), JOHNSON & MONTGOMERY (1974), NAHMIA (2001), SIPPER & BULFIN (1998), BOWERMAN & O'CONNEL (1993), BERRY & BLIEMEL (1974) e BROWN (1962).

3.4.3.1 Método de Holt

O método de Holt é um tipo de suavização dupla projetado para séries com tendência linear. O método usa 2 constantes de suavização α e β , e duas equações de

suavização: uma para o valor das séries (equação 3-06) e outra para a tendência da demanda (equação 3-07). O valor das séries é dependente dos registros da demanda e a tendência está relacionada com a diferença entre as demandas observadas.

$$S_t = \alpha(d_t) + (1 - \alpha)(S_{t-1} + G_{t-1}) \quad (3-06)$$

$$G_t = \beta(S_t - S_{t-1}) + (1 - \beta)G_{t-1} \quad (3-07)$$

A equação 3-06 é similar à equação usada na suavização exponencial simples. Na equação 3-07, a nova estimativa de S_t atualiza o valor de G_t com $S_t - S_{t-1}$, ponderado pela estimativa anterior G_{t-1} . As constantes de suavização podem ter o mesmo valor, mas a estimativa é mais suavizada quando $\beta \leq \alpha$. A previsão é dada pela equação 3-08.

$$F_t = S_{t-1} + G_{t-1} \quad (3-08)$$

O método de Holt é útil para séries que tenham uma tendência. Um exemplo ilustrativo da aplicação do método pode ser encontrado no Apêndice A, exemplo A-05. Outras informações sobre o método podem ser encontradas em: MONTGOMERY & JOHNSON (1976), JOHNSON & MONTGOMERY (1974), NAHMIA (2001), BOWERMAN & O'CONNEL (1993) e HOLT (1957).

3.4.3.2 Método de Winters

Este método é um tipo de suavização exponencial tripla com fácil atualização das previsões, indicado para demandas que apresentam comportamento sazonal. Assumindo que a estação tenha N períodos, e que os fatores sazonais da demanda tenham a propriedade de $\sum c_t = N$, três equações são usadas para atualizar as estimativas da série (equação 3-09), dos fatores sazonais (equação 3-10) e a tendência da série (equação 3-11).

$$S_t = \alpha(d_t/c_{t-N}) + (1 - \alpha)(S_{t-1} + G_{t-1}) \quad (3-09)$$

$$G_t = \beta(S_t - S_{t-1}) + (1 - \beta)G_{t-1} \quad (3-10)$$

$$c_t = \gamma(d_t/S_t) + (1-\gamma)c_{t-N} \quad (3-11)$$

As equações podem ter três diferentes constantes de suavização: α , β e γ . A previsão é dada pela equação 3-12.

$$F_{t+1} = (S_t + G_t)c_{t-N} \quad (3-12)$$

Considerando uma estação como o período de um ano (N), para que a previsão seja feita, deve-se ter as observações da demanda do ano anterior. A partir desses dados calcula-se a estimativa do fator sazonal que vai ser usado na previsão pela fórmula

$$c_t = \left(N / \sum_{i=1}^n d_i \right) \cdot d_t. \text{ Para o período } t + N \text{ calcula-se os valores de } S_{t+N} \text{ e } G_{t+N}.$$

Os valores calculados, juntamente com a estimativa sazonal calculada com dados do ano anterior, serão usados para estimar a previsão em $t + N + 1$. Ainda para o período $t + N$, calcula-se o valor de c_{t+N} pela equação 3-11, que será usado para a previsão do ano seguinte.

Um exemplo ilustrativo da aplicação do método pode ser encontrado no Apêndice A, exemplo A-06. Outras informações sobre o método podem ser encontradas em: MONTGOMERY & JOHNSON (1976), JOHNSON & MONTGOMERY (1974), NAHMIA (2001), BOWERMAN & O'CONNEL (1993), WINTERS (1960) e BROWN (1962).

3.4.4 Métodos de regressão

Usando técnicas estatísticas, este método realiza o “melhor ajuste” entre a previsão e as observações, incluindo todos os fatores que possam influenciar a demanda. Considerando dados na forma (x, y) , a relação entre as variáveis pode ser escrita da seguinte forma:

$$y = a + b \cdot x \quad (3-12)$$

Os valores ótimos de a e b são dados pelas equações 3-13 e 3-14.

$$a = \bar{d} - b \cdot (n + 1) / 2 \quad (3-13)$$

onde \bar{d} é a média aritmética da demanda observada nos períodos $t = 1, 2, \dots, n$.

$$b = S_{xy} / S_{xx} \quad (3-14)$$

$$\text{onde } S_{xy} = n \sum_{i=1}^n id_i - \frac{n(n+1)}{2} \sum_{i=1}^n d_i, \text{ e } S_{xx} = \frac{n^2(n+1)(2n+1)}{6} - \frac{n^2(n+1)^2}{4}.$$

A previsão da demanda é obtida através da equação 3-15.

$$F_t = a - (b \cdot t) \quad (3-15)$$

Um exemplo ilustrativo da aplicação do método pode ser encontrado no Apêndice A, exemplo A-06. Outras informações sobre o método podem ser encontradas em: MONTGOMERY & JOHNSON (1976), JOHNSON & MONTGOMERY (1974), NAHMIA (2001), BOWERMAN & O'CONNEL (1993), DRAPER (1968).

3.4.5 Modelos¹ de Box-Jenkins

Os modelos de Box-Jenkins exploram possíveis dependências entre os valores de uma série temporal, utilizando métodos de média móvel e de regressão para prever a demanda. Este método de previsão é útil quando as sucessivas observações sobre a demanda são dependentes. A partir de filtros lineares as séries são transformadas em processos de ruído branco, ou seja, com valores de erro oscilando em torno de zero. A abordagem do método consiste em um processo iterativo de três passos: (i) um modelo é identificado a partir dos dados; (ii) os parâmetros do modelo são estimados; e, (iii) a adequação do modelo é determinada.

A identificação do modelo é feita com base na análise dos dados históricos. É realizada a análise de autocorrelação e autocorrelação parcial, que são convenientemente exibidos em um gráfico e os padrões identificados são comparados. Os padrões podem ser de *tailing off*, no qual a função tem uma queda aproximadamente exponencial, com um

¹ Esta pesquisa mantém a nomenclatura encontrada na literatura, que se refere a este método de previsão de demanda como modelo de Box-Jenkins, assim como para outros métodos que são conhecidos como modelos.

grande número de valores não nulos, ou padrão de *cutting off*, no qual a função é “truncada” abruptamente, com poucos valores diferentes de zero. A partir da análise do padrão o modelo é identificado.

TABELA 3.1 – Modelos de Box-Jenkins.

MODELO	AUTOCORRELAÇÃO	AUTOCORRELAÇÃO PARCIAL
AR(p)	<i>Tailing off</i>	<i>Cutting off</i> depois de p intervalos
MA(q)	<i>Cutting off</i> depois de q intervalos	<i>Tailing off</i>
ARMA (p,q)	<i>Tailing off</i> , exibindo onda senoidal depois de (q - p) intervalos	<i>Tailing off</i> , exibindo onda senoidal depois de (p - q) intervalos

Fonte: JOHNSON & MONTGOMERY (1974)

- ✓ AR(p) – utiliza técnicas de regressão;
- ✓ MA(q) – utiliza técnicas de média móvel;
- ✓ ARMA (p,q) – é uma combinação de AR e MA,e,
- ✓ ARIMA (p,d,q) – método que usa técnicas de AR e MA integradas.

Os índices dos modelos indicam quantas vezes o filtro linear foi utilizado. Depois que o modelo é identificado, os parâmetros são estimados pela técnica de mínimo quadrado. Se o filtro linear aplicado for apropriado, as observações são transformadas em um processo de ruído branco, e então o modelo pode ser usado para gerar previsões.

Um exemplo ilustrativo da aplicação do método pode ser encontrado no Apêndice A, exemplo A-07. Outras informações sobre o método podem ser encontradas em: MONTGOMERY & JOHNSON (1976), BOWERMAN & O’CONNEL (1993), BOX & JENKINS (1970).

3.4.6 Modelos econométricos

Consistem de um sistema de equações de regressão que descrevem relações complexas de causa e efeito. As equações são resolvidas simultaneamente, permitindo uma representação mais realista. Como em regressão, inicialmente determina-se a forma funcional de cada equação. Posteriormente são estimados os valores dos parâmetros e,

como nos outros métodos, os resultados obtidos com a resolução das equações são analisados para verificar se as equações são adequadas.

Um exemplo ilustrativo da aplicação do método pode ser encontrado no Apêndice A, exemplo A-08. Outras informações sobre o método podem ser encontradas em: CHAMBERS et al. (1971), BUFFA & SARIN (1987) e PROFILLIDIS (2000).

3.4.7 Métodos de simulação

A simulação imita o comportamento de um sistema complexo. A simulação por computador é a descrição de um problema reduzido a um programa de computador. O programa recria as características importantes da situação. Através de um processo de tentativa e erro, diferentes variáveis de entrada e diferentes conjuntos de características são testados para determinar qual a melhor estratégia (NAHMIAS, 2001).

Para se construir um programa de simulação, inicialmente os objetivos da simulação devem estar bem definidos, uma vez que as saídas da simulação serão usadas para se tomar decisões. Depois é construído um modelo conceitual, que deve capturar a essência do sistema que vai ser simulado, usando relacionamentos lógicos e matemáticos. Deve-se definir as variáveis de decisão, as variáveis externas, sob as quais não se tem controle e influenciam o resultado, as variáveis de saída e as restrições.

O próximo passo é a coleta dos dados que serão usados para estimar os parâmetros de *input*. Estes dados têm valor fixo e não variam durante a simulação. Depois, é calculada a distribuição de probabilidade das variáveis aleatórias do modelo. Também é feito um levantamento de dados sobre o sistema real para que se possa fazer comparações. Um programa de computador é então desenvolvido, usando uma linguagem de programação ou um pacote de aplicação. São realizados testes para verificar se o programa tem o desempenho esperado e para determinar se o modelo e seus elementos são uma representação acurada de um sistema do mundo real.

Através dos modelos de simulação, o tomador de decisão pode estudar o comportamento do sistema sob algumas condições ou então testar as implicações de suas decisões.

Na previsão de demanda, é criado um modelo para demanda, no qual as variáveis são os fatores que podem influenciá-la. O programa de simulação varia essas variáveis em algum intervalo e os resultados dessa variação sobre a demanda são analisados para que uma previsão final seja feita.

Um exemplo ilustrativo da aplicação do método pode ser encontrado no Apêndice A, exemplo A-09. Outras informações sobre o método podem ser encontradas em: BUFFA & SARIN (1987), NAHMIAS (2001), SIPPER & BULFIN (1998), McWILLIAMS (1995), ASCHER (1978).

3.4.8 Focus forecasting

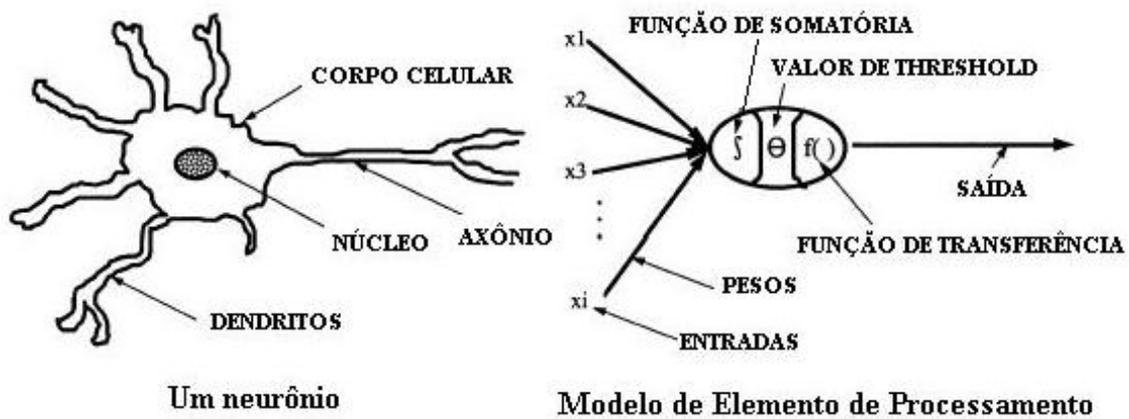
É um método que utiliza outros métodos de previsão de forma intuitiva. Faz-se a previsão através de diversos métodos e o que obtiver o melhor resultado será usado na previsão da demanda do próximo período. O melhor resultado pode ser visto com a menor diferença entre a previsão e a realidade e o método que o apresentou é escolhido como o método que vai estimar a demanda.

Um exemplo ilustrativo da aplicação do método pode ser encontrado no Apêndice A, exemplo A-10. Outras informações sobre o método podem ser encontradas em: SIPPER & BULFIN (1998) e SMITH (1978).

3.4.9 Métodos baseados em redes neurais

Uma rede neural imita a estrutura do cérebro. 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, o processa através de equações matemáticas e transmite o

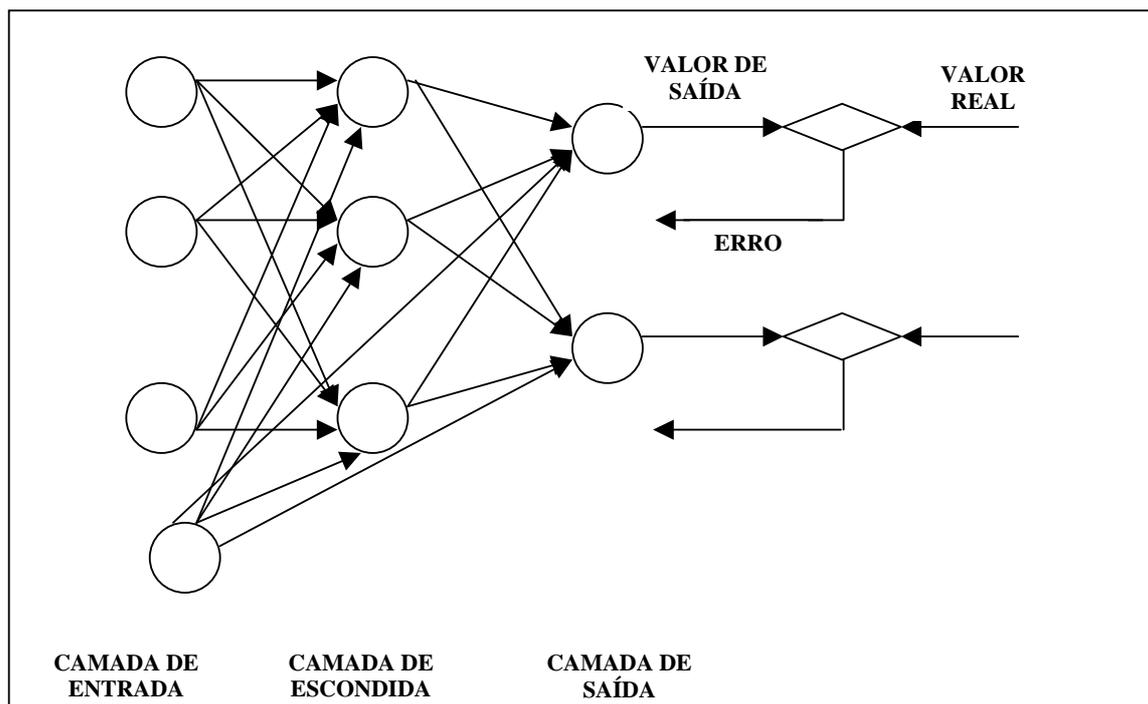
resultado ao próximo neurônio até que se obtenha uma saída desejada. A relação entre um neurônio artificial e um real pode ser vista na FIGURA 3.2.



Fonte: HSU & CHEN (2003)

FIGURA 3.2 – Representação de um neurônio real e um artificial.

Uma rede neural é composta de várias camadas de nós, onde a camada mais baixa é a camada de entrada, onde a informação externa é recebida. A camada mais alta é a camada de saída, onde a solução do problema é obtida. Estas camadas são separadas por camadas intermediárias, chamadas de escondidas (ZHANG et al., 1998). Existem vários tipos de arquitetura, entre as quais a mais usada é a de *back propagation* (BP), que é representada na FIGURA 3.3.



Fonte: HSU & CHEN (2003).

FIGURA 3.3: Exemplo de uma rede neural BP.

O processamento na rede neural ocorre da seguinte forma: um valor de entrada alimenta a camada de entrada, esses dados são transformados pelos neurônios e transferidos para a camada escondida. Em um neurônio da camada escondida, as entradas x_i são reunidas pela função \int , balanceado por θ e então transferidos para os próximos neurônios pela função $f(\cdot)$. Esse processo continua até a camada de saída, na qual a função de saída do neurônio gera a saída para o usuário. O valor real alimenta a rede que calcula o erro que vai atualizar os valores de pesos e funções e assim, treinar a rede. Cada valor que entra em um neurônio é modificado por um peso determinado por um neurônio de bias.

Segundo ZHANG et al. (1998), para um problema de previsão de demanda usando método causal, as variáveis de entrada geralmente são independentes e o relacionamento funcional estimado pela rede neural pode ser descrito como:

$$y = f(x_1, x_2, \dots, x_p) \quad (3-16)$$

onde x_1, x_2, \dots, x_p são p variáveis independentes e y é a variável dependente. Mas em um problema de previsão utilizando séries temporais, as entradas são dados históricos e a saída é a previsão. Neste caso, a rede neural desempenha a seguinte função de mapeamento:

$$y_{t+1} = f(y_t, y_{t-1}, \dots, y_{t-p}) \quad (3-17)$$

onde y_t é a observação feita no instante t . Antes que seja usada, uma rede neural deve ser treinada para desempenhar a tarefa desejada. O conhecimento que é adquirido pela rede durante o treinamento é armazenada nos arcos, na forma de pesos ou tendências a determinados nós. No treinamento, os exemplos do conjunto de treinamento são colocados nos nós de entrada. Os valores de ativação dos nós de entrada são balanceados e acumulados em cada nó na primeira camada escondida. O total é transformado por uma função de ativação no valor de ativação do nó. Isto se torna uma entrada para os nós da próxima camada, até que, eventualmente os valores de ativação de saída sejam encontrados (ZHANG et al, 1998).

Um exemplo ilustrativo da aplicação do método pode ser encontrado no Apêndice A, exemplo A-11. Outras informações sobre o método podem ser encontradas em: SIPPER & BULFIN (1998), ZHANG et al (1998), HSU & CHEN (2003) e NASR et al. (2003).

3.4.10 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.

Um exemplo ilustrativo da aplicação do método pode ser encontrado no Apêndice A, exemplo A-12. Outras informações sobre o método podem ser encontradas em: SIPPER & BULFIN (1998), BUFFA & SARIN (1987), HELMER (1977) e LINSTONE & TUROFF (1975).

3.4.11 Análise de impacto cruzado

Esta técnica indica quais os cenários devem ser descritos minuciosamente, resultando em uma visão abrangente da interação de eventos, suas probabilidades de ocorrência e como isto irá afetar decisões futuras.

Consiste uma planilha que é analisada por especialistas para determinar qual a melhor estratégia. Inicialmente são determinados os fatores críticos para uma determinada situação, os quais são relacionados em uma matriz. As interações entre os fatores são assinaladas por especialistas com setas para cima ou para baixo, indicando influências positivas ou negativas para a situação. A partir de estimativas de probabilidades de cada fator, são feitos os cálculos de probabilidade da matriz e uma solução é alcançada.

Um exemplo ilustrativo da aplicação do método pode ser encontrado no Apêndice A, exemplo A-13. Outras informações sobre o método podem ser encontradas em: SIPPER & BULFIN (1998), BUFFA & SARIN (1987) e BEASLEY (1984).

3.4.12 *Survey* de Mercado

Surveys de mercado e análise do comportamento de consumidores são técnicas sofisticadas e valiosas para se prever a demanda do mercado. De forma geral envolvem o uso de questionários e testes de novos produtos e serviços. A abordagem de *survey* é um processo interativo que consiste de três passos:

- ✓ Um questionário cujas informações relevantes que auxiliarão na previsão da demanda é feito. A elaboração das perguntas não deve influenciar ou constranger a pessoa que vai respondê-las. O questionário pode ser acompanhado, por exemplo, de uma amostra de um produto para avaliação.
- ✓ O questionário é enviado para uma amostra pré-determinada de pessoas, por fax, e-mail ou pelo correio. A pessoa deve responder as perguntas e devolver o

questionário. No caso de teste de produto, o questionário avalia o desempenho do produto e deve ser remetido a quem enviou.

- ✓ Os resultados devem ser resumidos e analisados. O uso de ferramentas estatísticas se mostra útil, porém uma análise subjetiva também é necessária.

Um exemplo ilustrativo da aplicação do método pode ser encontrado no Apêndice A, exemplo A-14. Outras informações sobre o método podem ser encontradas em: SIPPER & BULFIN (1998), BUFFA & SARIN (1987), SÁNCHEZ & PÉREZ (2003).

3.4.13 Delphi ou método de hierarquia de decisões

É uma técnica usada para a obtenção da opinião de um grupo de pessoas. Pode ser definida como um método de estruturação de um grupo ou comunicação, de forma que o processo seja efetivo ao permitir que o grupo de indivíduos, como um todo, lide com um problema complexo (LINSTONE & TUROOF, 1975). Os participantes interagem de forma anônima e controlada. São reunidos especialistas sobre um determinado assunto e sua interação é controlada e organizada por um coordenador.

Primeiramente o coordenador expõe um assunto ao grupo de especialistas, os quais devem escrever suas opiniões a respeito do problema. Os resultados são resumidos e agregados, por afinidade ou votação, pelo coordenador e novamente apresentado ao grupo para que a análise se repita. O processo é continua até que se atinja um consenso. O resultado final é resumido, apresentado aos participantes e utilizado para a tomada de decisão.

Um exemplo ilustrativo da aplicação do método pode ser encontrado no Apêndice A, exemplo A-15. Outras informações sobre o método podem ser encontradas em: SIPPER & BULFIN (1998), BUFFA & SARIN (1987), ETO (2003), CHANG et al. (2002).

3.4.14 Julgamento de Especialista

Em alguns casos, a complexidade do contexto que envolve a previsão faz com determinados eventos não possam ser modelados com o uso de métodos quantitativos. Assim, a opinião de pessoas que, por sua experiência em situações semelhantes ou familiaridade com o problema são consideradas especialistas, auxilia no processo de previsão. O julgamento de um especialista pode ser visto como um método cognitivo, no qual o especialista utiliza o seu conhecimento sobre a situação para dar um parecer ou auxiliar na tomada de decisão. Há dois aspectos sobre o conhecimento de um especialista (WEBBY & O'CONNOR, 1996):

- ✓ Conhecimento técnico: é o conhecimento sobre técnicas de análise de dados e procedimentos formais para a previsão; e,
- ✓ Conhecimento causal: é a compreensão sobre os relacionamentos de causa-efeito envolvidos nos eventos de ocorrência da demanda e do processo de como prevê-la, adquirido com a experiência e, além disso, envolve conhecimento sobre o produto e influência das ações da empresa sobre a demanda.

O conhecimento técnico é utilizado para desenvolver um processo de previsão. Já o conhecimento causal é usado para realizar a previsão de demanda.

TUBINO (1997) afirma que embora os recursos computacionais tenham evoluído e os métodos matemáticos tenham se tornado mais sofisticados, eles não conseguem lidar com a variabilidade do comportamento da demanda, e experiência e conhecimento são necessários para se fazer a previsão.

Mais informações podem ser encontradas em WEBBY & O'CONNOR (1996), TUBINO (1997), NAHMIA (2001), SIPPER & BULFIN (1998), BUFFA & SARIN (1987), KRAJEWSKI & RITZMAN (1987), NARASIMHAN et al. (1995).

3.5 Considerações Adicionais

3.5.1 Horizonte de planejamento

Outra forma de classificação dos métodos de previsão quanto ao horizonte de planejamento. Previsões de longo prazo são componentes da estratégia da empresa e dizem respeito a decisões que são tomadas meses ou anos antes de serem colocadas em prática. Geralmente padrões de vendas e tendências de crescimento são analisados. O horizonte de planejamento de médio prazo é usado para determinar a quantidade de recursos e pessoal que a produção vai necessitar. No curto prazo, as previsões são cruciais para o dia-a-dia da empresa, uma vez que têm impacto direto em decisões de planos de produção, *scheduling* e controle de estoque.

TABELA 3.2 – Métodos de Previsão de Demanda e Horizontes de Planejamento.

Método	Horizonte de planejamento	Fontes
Métodos bayesianos	Previsão de curto prazo	MONTGOMERY & JOHNSON (1976), SIPPER & BULFIN (1998)
Média móvel	Previsão de curto prazo	SIPPER & BULFIN (1998), BUFFA & SARIN (1987), KRAJEWSKI & RITZMAN (1987), NAHMIAS (2001), NARASIMHAN et al. (1995), WINSTON (1994)
Suavização exponencial	Previsão de curto prazo	SIPPER & BULFIN (1998), BUFFA & SARIN (1987), KRAJEWSKI & RITZMAN (1987), NAHMIAS (2001), NARASIMHAN ET AL. (1995), WINSTON (1994)
Método de Holt	Previsão de curto prazo	SIPPER & BULFIN (1998), BUFFA & SARIN (1987), NAHMIAS (2001), MONTGOMERY & JOHNSON (1976), WINSTON (1994), KRAJEWSKI & RITZMAN (1987)
Método de Winters	Previsão de curto prazo	SIPPER & BULFIN (1998), BUFFA & SARIN (1987), NAHMIAS (2001), MONTGOMERY & JOHNSON (1976), NARASIMHAN ET AL. (1995), WINSTON (1994), KRAJEWSKI &

Método de Regressão	Previsão de médio e curto prazo	RITZMAN (1987) WINSTON (1994), SIPPER & BULFIN (1998), BUFFA & SARIN (1987), MONTGOMERY & JOHNSON (1976), KRAJEWSKI & RITZMAN (1987)
Modelos de Box-Jenkins	Previsão de vendas de médio e curto prazo	SIPPER & BULFIN (1998), BUFFA & SARIN (1987), MONTGOMERY & JOHNSON (1976)
Modelos econométricos	Previsão de médio prazo	BUFFA & SARIN (1987) E SIPPER & BULFIN (1998)
Métodos de simulação	Previsão de longo prazo	SIPPER & BULFIN (1998) E NAHMIAS (2001)
Focus Forecasting	Previsão de médio prazo	KRAJEWSKI & RITZMAN (1987) E NARASIMHAN ET AL. (1995)
		(continua...)
Redes neurais	Previsão de curto e médio prazo.	SIPPER & BULFIN (1998), ZHANG ET AL. (1998)
Cenários	Previsões de longo prazo	SIPPER & BULFIN (1998), BUFFA & SARIN (1987)
Análise de Impacto Cruzado	Previsão de longo e médio prazo	BUFFA & SARIN (1987) E SIPPER & BULFIN (1998)
Pesquisa de mercado	Previsões de longo prazo	KRAJEWSKI & RITZMAN (1987), BUFFA & SARIN (1987) E SIPPER & BULFIN (1998)
Delphi	Previsões de longo prazo	KRAJEWSKI & RITZMAN (1987), SIPPER & BULFIN (1998) E BUFFA & SARIN (1987)
Julgamento de Especialista	Previsões de curto, médio e longo prazo	WEBBY & O'CONNOR (1996), SIPPER & BULFIN (1998), KRAJEWSKI & RITZMAN (1987) E BUFFA & SARIN (1987)

Os autores diferem quanto à diferenciação dos horizontes de planejamento.

Levantou-se que:

TABELA 3.3 – Horizontes de Planejamento.

Autor	Longo Prazo	Médio Prazo	Curto prazo
PLOSSL (1985)	5 anos ou mais	1 a 2 anos	3 a 6 meses
BUFFA & SARIN (1987)	maior que 1 ano	1 a 12 meses	menor que 1 mês
NAHMIAS(2001)	Meses ou anos	Semanas ou meses	Dias

NARASIMHAN et al. (1995)	Acima de 5 anos	Entre 1 e 3 anos	Até 1 ano
SIPPER & BULFIN (1998)	3 a 5 anos	3 meses a 2 anos	Até 3 meses
KRAJEWSKI & RITZMAN (1987)	Acima de 2 anos	Entre 3 meses e 2 anos	Até 3 meses

Nesta pesquisa será considerada a definição para curto prazo proposta por KRAJEWSKI & RITZMAN (1987) e por SIPPER & BULFIN (1998), que considera previsão de curto prazo como de até três meses. Esta definição se encaixa ao horizonte de planejamento da empresa na qual será realizado o estudo de caso.

3.5.2 Erro

Erro de previsão é a diferença entre a previsão da demanda e a demanda real, representada pela variável ε_t na equação 3-01 e em qualquer equação de representação da demanda. A equação 3-18 representa matematicamente o erro, onde F_t representa a previsão para o período t e d_t a demanda real para o mesmo período.

$$\varepsilon_t = d_t - F_t \quad (3-18)$$

Essa diferença, também conhecida como ruído ou erro, pode ser absoluta para números de previsão e observação com ordem de grandeza relativamente pequena ou pode ser relativa, como por exemplo, porcentagem, facilitando a interpretação do significado de determinado valor de um ruído.

Em um processo bem definido de previsão, o erro deveria ter valor médio zero (0). Mas, como existem muitos fatores não controláveis que influenciam a demanda e como os métodos de previsão de demanda não consideram todos esses fatores ao mesmo tempo, há variação no erro. Os modelos assumem que a variação seja constante MONTGOMERY & JOHNSON (1976), assim, é razoável admitir que o erro segue distribuição de probabilidade simétrica, normalmente distribuída, com valor esperado

$E[\varepsilon_t] = 0$ e variância $V[\varepsilon_t] = \sigma^2$. Os erros de previsão proporcionam uma medida de exatidão e uma base para comparar o desempenho com métodos alternativos de previsão. As formas mais usadas para medir o erro, segundo BUFFA & SARIN (1987), são:

- Erro médio: é uma média aritmética dos erros de previsão. A desvantagem é os erros negativos são anulados pelos positivos, o que pode minimizar o erro. A vantagem é este método apresenta um viés, que indica a tendência da previsão. Um viés positivo, indica que há uma tendência da previsão ser maior que demanda. Quando o viés é negativo, as previsões tendem a ser menores que a demanda.

$$AE = \frac{1}{N} \sum_{t=1}^N \varepsilon_t \quad (3-19)$$

- Desvio absoluto da média: este método considera os valores absolutos dos erros.

$$MAD = \frac{1}{N} \sum_{t=1}^N |\varepsilon_t| \quad (3-20)$$

- Erro quadrado médio: este método considera os erros elevados ao quadrado e então, penaliza os erros maiores.

$$MSE = \frac{1}{N} \sum_{t=1}^N \varepsilon_t^2 \quad (3-21)$$

- Erro percentual absoluto médio: este método considera os valores percentuais dos erros. Esta medida relativa é o melhor forma de saber o erro médio quando as vendas têm valores altos.

$$MAPE = \frac{1}{N} \sum_{t=1}^N \left| \frac{\varepsilon_t}{d_t} \times 100 \right| \quad (3-22)$$

Em um ambiente com mudanças constantes, um modelo desenvolvido para apresentar boas previsões pode ter seu desempenho comprometido com o passar do tempo.

Assim é necessário que o processo de previsão de demanda seja constantemente monitorado.

A observação dos valores de erro das previsões é uma boa forma de análise do modelo empregado. Se o valor do erro é pequeno, é sinal de que o modelo de previsão empregado é adequado ao problema. Mas, caso contrário, indica que é necessário que se desenvolva um novo método de previsão de demanda.

3.6 Softwares de Previsão de Demanda

O desenvolvimento da computação possibilitou o desenvolvimento de *softwares* que automatizassem as rotinas de previsão de demanda, permitindo que se analisassem grandes quantidades de dados em menos tempo. Algumas empresas optam por desenvolver internamente seus próprios programas de previsão de demanda, adequando o sistema às características de seus problemas. Contudo, outras preferem comprar programas prontos de empresas especializadas. Existem muitos pacotes disponíveis no mercado, que utilizam desde técnicas de análise de dados históricos até simulações e inteligência artificial. As empresas que os desenvolvem alegam que seus produtos proporcionam previsões mais exatas, resultando em menores investimentos de estoque e em economias para a organização.

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, mas apenas há 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.

A seguir serão apresentadas em tabelas com características de alguns dos softwares comerciais existentes. Escolheu-se estes programas apenas por disponibilidade das informações. Critérios técnicos, tanto em termos computacionais quanto de métodos implementados, não foram levados em conta para seleção. Pode-se obter informações sobre

uma análise rigorosa e criteriosa sobre softwares de previsão de demanda existentes em KÜSTERS & BELL (1999).

TABELA 3.4 – Caracterização dos Softwares de Previsão de Demanda.

Software	Empresa	Caracterização	Endereço
Autobox	Automatic Forecasting Systems	Software que promete “proporcionar um ambiente desenvolvido para facilitar o processo de previsão com a utilização de uma ou mil séries”. O Autobox identifica tendências locais, oferece análise gaussiana dos dados.	http://www.autobox.com
DecisionPro	Vanguard Software Corp.	Fácil de usar e ao mesmo tempo permite análise avançadas para usuários mais experientes. <i>Software</i> cuja “interface inovativa permite fácil utilização e fornece flexibilidade na utilização de diversos métodos de previsão em uma única aplicação”.	http://www.vanguardsw.com
Forecast Pro	Business Forecast Systems Inc.	“Fácil de aprender e usar, os sistema combina métodos estatísticos com um sistema especialista para obter uma previsão exata”.	http://www.forecastpro.com
Forecast X	John Galt Solutions Inc.	Sistema que permite ao usuário opções de escolha entre os métodos de previsão de demanda existentes e permite a inclusão de características da empresa e do negócio para gerar a previsão.	http://www.forecastx.com
GAUSS	Aptech Systems, Inc.	Modelagem e análise de grande quantidade de dados. “É um ambiente de análise apropriado para fazer desde cálculos rápidos até análise complexa de milhões de dados”.	http://www.aptech.com
Neuralworks Predict	Neuralware	Sistema que combina técnicas “não-convencionais” para previsão de demanda, como redes neurais e algoritmos genéticos.	http://www.neuralware.com
Smart Forecasts	Smart Software Inc.	Tem ferramentas de previsão que lidam com sazonalidade, promoções, lançamentos e demanda intermitente. É um sistema “projetado para fornecer previsões rápidas e exatas de vendas, demanda e níveis de estoque baseadas em seu sistema especialista e julgamento do negócio”.	http://www.smartcorp.com
Time Trends Forecast	ALT-C Systems Inc.	Sistema com grande capacidade de armazenamento de dados e com rapidez de cálculos.	http://www.alt-c.com

A TABELA 3.5 apresenta algumas características técnicas dos *softwares*.

TABELA 3.5 – Características Técnicas.

Software	Sistema Operacional	Integração com outros softwares	Recursos
Autobox	Windows, Unix	Informação não encontrada	Possui recursos/ferramentas de análises gráficas facilitando a análise das previsões, além de apresentar gráficos de ferramentas estatísticas.
DecisionPro	Windows 95, 98, NT4, 2000, Me, XP	Informação não encontrada	Informação não encontrada
Forecast Pro	Windows e IBM OS/2	Pode ser combinado com outros softwares sendo opção de previsão para os sistemas de planejamento para ERP, SCM, MRP, EIS	Informação não encontrada
Forecast X	é compatível com <i>Microsoft Windows</i> e Unix	Permite integração com outros sistemas, podendo ser embutido em qualquer aplicação via <i>ActiveX</i> ou <i>JAVA</i> .	Apresenta ferramenta de suporte a relatórios
GAUSS	Unix, Linux, Win32 e IBM OS/2	É compatível com vários tipos de Bancos de Dados e aceita programas feitos em C ou Fortran para inserção de novas técnicas	Tem ferramentas para construção de gráficos de previsão e de funções estatísticas como função de autocorrelação.
Neuralworks Predict	<i>Microsoft Windows</i> , Linux, <i>Sun Microsystems Solaris</i> , SGI Irix e IBM AIX.	Informação não encontrada	Os resultados são expostos em planilhas, cujos gráficos permitem fácil visualização da solução.
Smart Forecasts	Windows 95/98/NT/2000/XP	Pode ser integrado com ERP e SCM e pode colaborar diretamente com esses sistemas acessando suas bases de dados. Permite fácil integração com sistemas de produção através de uma ferramenta de conectividade de banco de dados.	Tem ferramentas que permitem a construção de diversos tipos de gráficos sobre os resultados e sobre funções de análise estatística.
Time Trends Forecast	Windows	Pode ser integrado com MRP, ERP, SCM e sistemas financeiros	Os dados podem ser vistos em gráficos ou em forma de tabelas e, através de manipulação, são usados para fazer a previsão de manufatura e distribuição

A TABELA 3.6 apresenta como os *softwares* fazem a previsão e quais são as técnicas implementadas.

TABELA 3.6 – Processo de Previsão de Demanda nos Softwares.

Software	Processo de Previsão	Técnicas implementadas
Autobox	O <i>Autobox</i> não seleciona um modelo a partir de um conjunto definido pelo usuário, mas ajusta o modelo de previsão a cada problema. O sistema analisa os dados de entrada para a procura de ciclos, sazonalidade e tendências locais.	Suavização Exponencial Simples, Box-Jenkins e Métodos de Regressão
DecisionPro	Combina características de ferramentas de inteligência artificial, aplicações matemáticas e planilhas eletrônicas com métodos quantitativos.	Métodos de Holt e Winters, Simulação, Média Móvel, Suavização Exponencial e Métodos de Regressão
Forecast Pro	O sistema especialista escolhe automaticamente qual o melhor método de previsão de demanda ao analisar os dados de entrada.	Suavização exponencial, Métodos de Holt e Winters, Média móvel, Regressão Linear e Box Jenkins,
Forecast X	Combina regras de negócio, como tendências e	Suavização exponencial, Métodos

	sazonalidades, com previsão estatística	de Holt e Winters, Box Jenkins e Método de Fourier
GAUSS	O usuário escolhe o método, insere os dados no sistema e este desenvolve o modelo de previsão de demanda.	Box-Jenkins, Métodos de Regressão, e Método de <i>Fourier</i> .
Neuralworks Predict	Este software usa um algoritmo genético para selecionar quais as variáveis que mais influenciam um problema e então constrói uma rede neural para resolver problemas de previsão.	Rede Neural e algoritmos genéticos
Smart Forecasts	A partir dos dados que o usuário insere no sistema, este fornece a previsão.	Suavização Exponencial, Métodos de Winters e Holt, Métodos de Regressão e Média móvel
Time Trends Forecast	“Sua proposta é armazenar e gerenciar todas as informações relacionadas com previsões, criando séries temporais e permitindo a análise de grandes quantidades de dados armazenados na base de dados da empresa”.	Suavização exponencial, Métodos de Holt e Winters, Média móvel

A TABELA 3.7 fornece informações sobre os preços, disponibilidade de versão demo para testes e algumas das empresas que utilizam estes softwares. A informação sobre os preços, que estão expressos em dólares, foi coletada em março de 2003 e não foi encontrada nenhuma referência sobre a possibilidade de que esteja incluído nos preços a customização dos *softwares*.

TABELA 3.7 – INFORMAÇÕES ADICIONAIS SOBRE OS SOFTWARES.

Software	Preço (dólares)	Versão demo para testes	Clientes
Autobox	\$395 até \$20000	Versão com todas as funções, mas não permite a entrada de dados (base padrão). Oferece documentação impressa e <i>on-line</i> .	Motorola Philip Morris Usa Pizza Hut Coca Cola Company
DecisionPro	\$495 até \$3995	Requisitar versão para testes no web-site da empresa. Estão disponibilizados documentação de ajuda <i>on-line</i> .	Nokia Ford Caterpillar Novartis
Forecast Pro	\$300 até \$4995	Versão possui todas as funções, informações sobre o produto e lista de preços completa. Há disponibilização de documentação <i>on-line</i>	informação não encontrada
Forecast X	\$595	Versão de uma demonstração do planejamento da demanda e soluções de Previsão	Hewlett Packard Ericsson Alcon Laboratories
GAUSS	informação não encontrada	Versão demo para Windows para <i>download</i> via FTP	informação não encontrada
Neuralworks Predict	\$995 até \$5775	Requisitar versão para testes no web-site da empresa	Boeing General Electric General Motors Xerox
Smart Forecasts	informação não encontrada	Requisitar versão para testes no web-site da empresa. A empresa disponibiliza documentação <i>on-line</i> .	Alcoa Cargill Foods Toshiba L'Oreal
Time Trends Forecast	\$4995	Não disponibiliza versão para testes	Parmalat Compac Molson

3.7 Considerações sobre a Previsão de Demanda

Como as empresa só têm pedidos firmes poucas semanas antes do fornecimento e a alta concorrência e o mercado atual exigem prazos de entrega cada vez menores, o planejamento da produção é feito com base em uma visão de futuro. Assim, se a previsão de vendas for correta ou muito próximo do real, a empresa conseguirá atingir um bom nível de disponibilidade para fornecimento. Contudo existem empresas que produzem apenas contra-pedido. Estas têm dados reais sobre a demanda e não precisam prevê-la.

Mas, se, ao contrário, a previsão for ruim, as conseqüências serão negativas. Se a produção for maior que a demanda, os produtos que não foram vendidos ficarão em estoque e isto pode representar capital “empatado” que poderia ter sido investido ou perda de capital, uma vez que alguns produtos têm prazo de validade muito pequeno. Se a demanda for maior que a produção, a empresa perde oportunidade de vendas. Dessa forma, a exatidão da previsão de demanda é importante para o bom funcionamento da produção e para o bom desempenho da empresa.

A percepção que o cliente tem ao comprar de uma determinada organização reflete o nível de serviço prestado. A previsão de demanda tem impacta diretamente na disponibilidade, uma vez que determina o quanto vai estar disponível ao cliente. Assim, se for prevista uma demanda menor do que a real, alguns consumidores não serão atendidos e ficarão insatisfeitos com o fornecimento. Se a demanda prevista for maior do que a real, os produtos permanecem em estoque até que sejam consumidos, o que pode deteriorar a qualidade do produto ou, se o *shelf life* do produto for curto, pode resultar em perdas para a empresa, incorre em maior custo com estoque.

A previsão de demanda, é importante, uma vez que todas as decisões sobre capacidade na função operação dependem de alguma forma da previsão da demanda: pessoal, uso das facilidades, horas-extras, estoques, *scheduling* e controle (BUFFA & SARIN, 1987).

A análise de tendências econômicas e políticas governamentais determina como os fatores estruturais vão afetar a demanda. Os métodos matemáticos usados na previsão de demanda têm obtido bons resultados, mas reagem lentamente frente a

mudanças e muitas vezes necessitam da realização de cálculos complexos e custosos. Segundo SIPPER & BULFIN (1998), as redes neurais têm limitações, uma vez que sua matemática é complexa e pode ser influenciada por dados irrelevantes. Não é feita validação, uma vez que o modelo de execução não é explícito. Além disso, medidas estatísticas de exatidão são inexistentes para redes neurais.

Os métodos econométricos, cenários e simulação são métodos complexos, que necessitam de grande quantidade de dados e recursos computacionais, além de serem de difícil manipulação. O método *delphi* e *surveys* de mercado consomem muito tempo e exigem grande número de pessoas envolvidas, dificultando a execução do método.

Como em muitos casos há dados insuficientes para se estimar variáveis ou parâmetros de um modelo, as técnicas existentes se mostram insuficientes para se fazer uma boa previsão. Dado que os relacionamentos entre os fatores influentes na demanda são muitos complexos para serem modelados matematicamente e de forma realística a instabilidade do ambiente estimula comportamento atípico da demanda, o uso de conhecimento de especialista é uma alternativa para a previsão da demanda. Segundo WEBBY & O'CONNOR (1996), o uso de conhecimento de especialista é mais exato do que métodos estatísticos em séries com tendência. O uso de sistemas especialistas para previsão de demanda é abordado no Capítulo 4. Sistemas especialistas são programas de computador que embutem o conhecimento do especialista e realizam processos semelhantes ao raciocínio humano, auxiliando em atividades como tomada de decisão, previsão e monitoramento.

4 SISTEMAS ESPECIALISTAS

4.1 Introdução

A Inteligência Artificial se destaca em vários campos de pesquisa como alternativa para a solução de problemas complexos, procurando imitar os processos de aprendizagem e compreensão dos seres humanos.

RICH (1988) define Inteligência Artificial como “o estudo de como fazer os computadores realizarem tarefas em que, no momento, as pessoas são melhores”. Para LIEBOWITZ (1995), a Inteligência artificial ocupa-se do desenvolvimento de poder computacional inteligente, compreendendo melhor como pensamos, raciocinamos e aprendemos. Desta forma, a Inteligência Artificial se caracteriza pelo estudo de técnicas que possibilitam que os computadores realizem tarefas e identifiquem e solucionem problemas de forma inteligente, simulando o processo de raciocínio, pensamento e aprendizagem humanos.

Os fundamentos básicos da Inteligência Artificial começaram a ser estabelecidos em 1950, através de teorias de lógica matemática e funções recursivas. Os pesquisadores começaram a simular o processo do pensamento humano e, posteriormente, se concentraram na resolução de problemas desenvolvendo técnicas de representação e busca. A partir da década de 60, parte dos estudos se concentraram no desenvolvimento de programas para a resolução de problemas reais. O mais conhecido é o GPS (*General Problem Solver* – Solucionador de Problemas Gerais) que se ocupava de resolver diferentes tipos de problemas.

Apesar do primeiro Sistema Especialista ter sido desenvolvido por volta nos anos 60, somente na década de 70 que foram feitas grandes pesquisas sobre o assunto. Neste ambiente, foram desenvolvidos programas com objetivos e área de conhecimentos específicos, os chamados Sistemas Especialistas. Vários projetos foram desenvolvidos nas mais diversas áreas, por exemplo: medicina (*MYCIN*), geologia (*PROSPECTOR*) e engenharia (*REACTOR*).

A seguir serão apresentados os principais conceitos sobre sistemas especialistas e como desenvolvê-los.

4.2 Principais conceitos

Existem inúmeras definições sobre Sistemas Especialistas que mostram as diversas interpretações do conceito, onde cada pesquisador dá ênfase a alguma característica particular deste tipo de sistema:

- ✓ Sistemas Especialistas são sistemas que solucionam problemas que, normalmente, apenas pessoas especialistas conseguem resolver (FEIGENBAUM, 1977).
- ✓ Sistema Especialista é um sistema de computação que opera aplicando um mecanismo de inferência a um ‘corpo’ de conhecimento ou perícia de especialista representado em algum formalismo de representação de conhecimento (BEYNON-DAVIES, 1991).
- ✓ Um Sistema Especialista codifica o conhecimento e habilidades de raciocínio de um especialista humano para diagnosticar problemas e fazer recomendações que teria requerido atenção de um especialista humano (PRASAD et al., 1996).

Nota-se que estas definições refletem principalmente a estrutura do sistema, que é uma de suas principais características, o armazenamento do conhecimento de um especialista humano. Não são citadas, contudo, as oportunidades e as potencialidades desses sistemas capazes de emular o raciocínio humano. Uma definição que aborde estes dois aspectos, estrutura e operações, e que se aplique ao trabalho da dissertação e é baseada nos conhecimentos adquiridos com a revisão bibliográfica: sistema especialista é a aplicação das técnicas de IA, o desenvolvimento destas aplicações a um determinado problema/contexto resulta em sistemas especialistas, que são programas de computador que usam conhecimento armazenado digitalmente e procedimentos de inferência para resolver problemas que são complexos, emulando a habilidade de tomada de decisão ou de raciocínio na resolução matemática de questões, ou diagnóstico, identificação ou solução de problemas ou, ainda no auxílio a dúvidas do usuário.

Há três componentes básicos que interagem em um sistema especialista típico, como mostra a FIGURA 4.1: interface com o usuário, mecanismo de inferência e base de conhecimento.

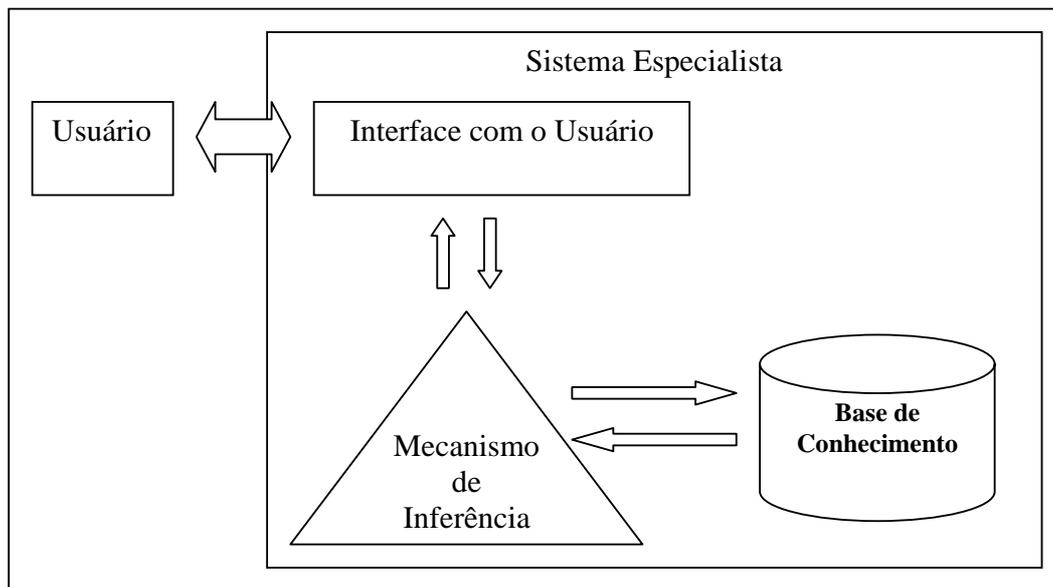


FIGURA 4.1 – Componentes básicos dos sistemas especialistas.

- ✓ A interface com o usuário permite sua interação do humano com o sistema.
- ✓ O mecanismo de inferência que fornece o raciocínio, trabalhando com a base de conhecimento.
- ✓ A base de conhecimento, onde os dados, informações e heurísticas sobre o domínio do problema são armazenados.

Outros componentes podem estar presentes em um sistema, como mecanismo de rastreamento e sistema de refinamento do conhecimento, mas isto depende da forma como foi estruturado e quais características se pretende destacar.

4.3 Base de Conhecimento

O conhecimento é composto de fatos, idéias, conceitos ou soluções obtidas através do estudo, investigação, observação ou experiência (BELHOT, 1991) sobre um domínio específico. A Base de Conhecimento (BC) contém o conhecimento sobre um domínio, para resolver, compreender e formular problemas. Pode incorporar diferentes tipos de conhecimento e em diversos formatos, desde texto até vídeos e sons.

Existem diversas categorias de conhecimento:

- ✓ Conhecimento declarativo: declara fatos do mundo, o que as coisas são e como se associam;
- ✓ Conhecimento procedural: descreve como as coisas trabalham em diferentes situações, e é feita na forma de passos sequenciais;
- ✓ Conhecimento semântico: são estruturas cognitivas dos objetos, representando significados. É uma espécie de dicionário, associando objetos e símbolos conhecidos/codificados, significando relações entre os objetos;
- ✓ Conhecimento episódico: ocorrências passadas de problemas e suas soluções;
- ✓ Meta-conhecimento: conhecimento sobre o conhecimento.

Essas diversas categorias de conhecimento deram origem às diversas formas de representação do conhecimento que serão descritas no item 4.4.1. Depois de identificado e categorizado, o conhecimento relevante para o Sistema Especialista é trabalhado em diversas etapas: (i) Aquisição; (ii) Representação e (iii) Validação.

Depois de construída, é necessário avaliar a BC para verificar se ela atende as necessidades do sistema. Uma forma de avaliação é a simulação através de situações passadas, das quais já se sabe a resposta, verificando se a partir da BC desenvolvida, se chega às conclusões certas. Passar a BC por análise com outros especialistas resulta em um bom teste de validação, mas depende da disponibilidade dos mesmos e nem sempre há tantos especialistas disponíveis.

Os dois pontos principais que envolvem a BC são como adquirir o conhecimento que vai ser armazenado e qual a técnica utilizada para representar este conhecimento. Para se tomar essas decisões deve-se ter um amplo conhecimento do domínio do problema e do próprio problema que vai ser resolvido pelo Sistema Especialista. Depois de construída a BC precisa ser validada para que possíveis erros sejam corrigidos.

4.4 Métodos de aquisição do conhecimento

A aquisição de conhecimento é o processo de acumulação, transferência e transformação do conhecimento, para a resolução de um problema, de alguma fonte para um programa de computador para a construção ou expansão da BC (LUCAS & GAAG, 1991). O conhecimento pode ser adquirido de diversas fontes, entre elas, banco de dados, livros, relatórios, modelos, conhecimento empírico e dados do próprio especialista.

Nota-se que neste processo de levantamento/aquisição do conhecimento muitas pessoas estão envolvidas, direta ou indiretamente. A Figura 4.2 ilustra a interação entre as pessoas. O engenheiro do conhecimento é pessoa responsável por estruturar o domínio do problema, relacionando perguntas e respostas, selecionando exemplos e analogias e resolvendo dificuldades no entendimento de conceitos. Outro participante é o usuário que pode ser desde um estudante até um especialista. O sistema especialista vai interagir diretamente com ele no desempenho de sua tarefa e, portanto, o conhecimento adquirido deve ser adequado aos propósitos do usuário.

Especialista é a pessoa que tem um conhecimento especial, julgamento, experiência e métodos com a habilidade de aplicar estes talentos para dar conselhos e resolver problemas. É o domínio do trabalho do especialista que fornece conhecimento sobre como ele desempenha a tarefa. Um especialista conhece quais fatos são importantes e compreende o significado das relações entre os fatos (LUCAS & GAAG, 1991).

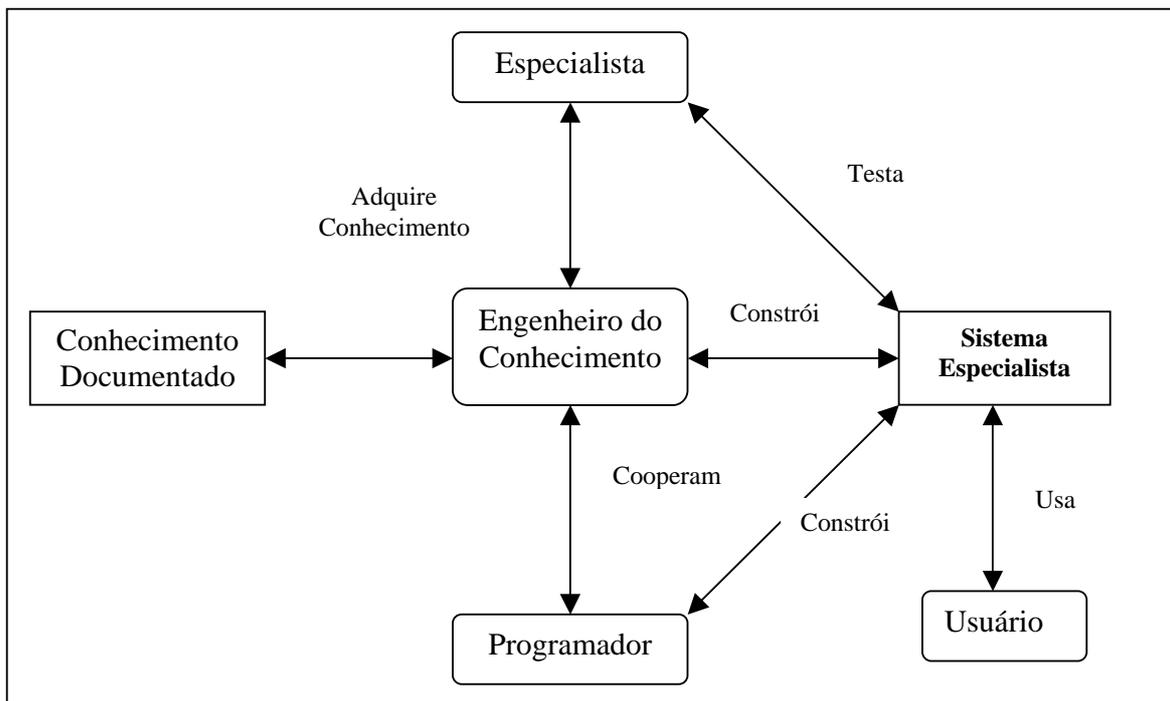


FIGURA 4.2 – Relacionamento dos participantes no desenvolvimento de um sistema especialista.

Uma forma de coletar conhecimento é por meio de entrevista com o especialista que desempenha a tarefa sobre o problema. O especialista pode não conseguir descrever claramente o processo de resolução do problema, uma vez que não está consciente de todos os processos mentais envolvidos na atividade. Com o uso de um método contínuo e bem estruturado, o engenheiro de conhecimento pode conseguir extrair partes do conhecimento para posterior seqüenciamento.

Para conduzir uma entrevista para a aquisição do conhecimento do especialista o engenheiro do conhecimento deve estar familiarizado com o domínio do conhecimento, assim, poderá fazer perguntas relevantes, mantendo as conversas dentro dos limites do conhecimento que se quer obter. Contudo deve-se ter cuidado ao conduzir uma entrevista, para que o engenheiro não tente sobrepor seu conhecimento ao do especialista.

4.4.1 Representação do conhecimento

➤ **Regras de Produção:**

As regras de produção são usadas para representar o conhecimento associado a um problema. Elas são muito apropriadas quando o domínio resulta de associações empíricas desenvolvidas através da experiência prática (BELHOT, 1991). Geralmente tem a seguinte forma:

SE <condições>
ENTÃO <conclusões ou ações>

Tal forma representa que “se” um conjunto de condições for satisfeito, “então” um conjunto de conseqüências pode ser produzido. Segundo (KUSIAK & CHEN, 1988), as regras Se-Então podem ser classificadas em duas categorias:

- ✓ Regras de primeira ordem: incluem a aplicação de regras específicas, das quais uma conclusão pode ser tirada, um modelo matemático ativado, uma ação é tomada ou comandos são executados;
- ✓ Meta-regras: são específicas de determinados problemas e as ações tomadas por essas regras são ordens para ativar e executar outras regras.

Este tipo de representação é dependente do conhecimento a ser modelado, mas tem um sistema independente para manipulação das mesmas. A atualização do conhecimento representado com este formalismo é simples e flexível, uma vez que novas regras podem ser adicionadas, sem que haja necessidade de alteração da BC e o processamento ocorre somente após a declaração.

➤ **Frames**

Um *frame* é uma estrutura que contém conhecimento sobre um conceito particular e fornece expectativas e conhecimento padrão sobre o conceito representado. Computacionalmente é representado como um conjunto de *slots* que correspondem aos atributos de conhecimento sobre o conceito representado (KASTNER & HONG, 1984). Os

principais *slots* de um objeto contêm: o identificador do objeto; a classe ou classes a que o objeto pertence; e, os atributos que descrevem o objeto e suas subclasses.

TABELA 4.1 – EXEMPLO DE UMA ESTRUTURA DE *FRAME*.

<i>Frame:</i>	
<i>SLOTS</i>	VALORES
“é-um”	Relação com outro <i>frame</i>
Código	Identificação do <i>frame</i>
E assim por diante...	...

Os *frames* podem representar objetos genéricos, sendo conhecidos como construtores, ou representarem objetos do mundo real, conhecidos como instância. Este tipo de formalismo é usado para representar fatos e conhecimentos descritivos. Todos os objetos de um sistema de *frames* devem fazer parte de uma hierarquia de especialização ou de generalização. Nela, há um *frame* inicial, que é a raiz da hierarquia. A ligação entre os *frames* é descrita através dos *slots* “é-um”. Outros tipos de relacionamento podem ser criados através de *slots* do tipo “é-parte-de” ou “causa”.

Os *frames* fornecem modularidade e uniformidade de representação, uma vez que um novo conceito pode ser representado pela inserção de um *frame* no sistema e este tipo de representação permite o encapsulamento de atributos de outro *frame* já existente. A verificação de informações ausentes é feita pela busca por *slots* vazios, facilitando a validação da BC.

➤ **Redes Semânticas**

Neste formalismo, o conhecimento é representado na forma de uma rede. Os conceitos são representados por um grupo de nós. Os arcos conectam os nós e representam relações do tipo “é-um”, “parte de” ou “instância de”. Os arcos podem também representar relações de causa, probabilidade ou simples associações entre partes do domínio do conhecimento (KASTNER & HONG, 1984).

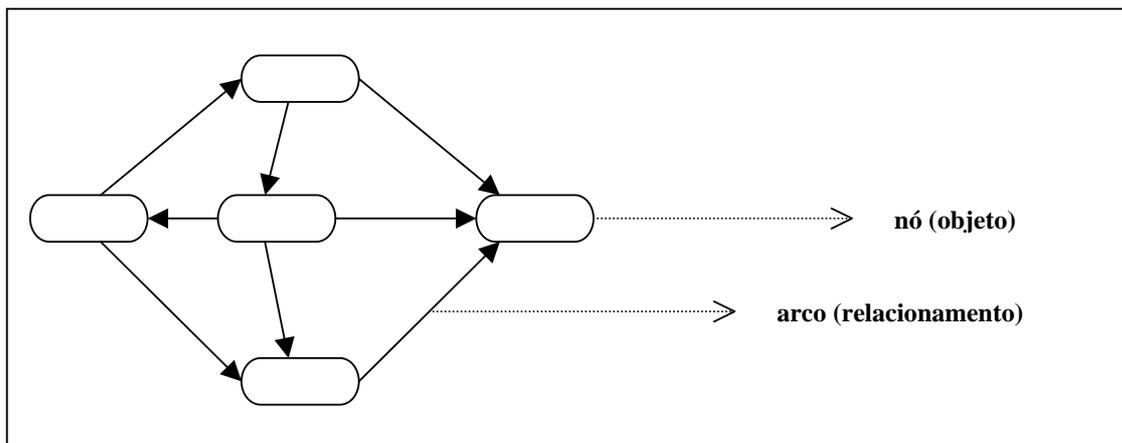


FIGURA 4.3 – Exemplo de uma rede semântica

4.4.2 Mecanismo de Inferência

Também pode ser conhecido como Máquina de Inferência (MI), este componente funciona como o “cérebro” do sistema, uma vez que é a estrutura de controle que manipula o conteúdo armazenado na Base de Conhecimento. Inferência é o processo de se tirar conclusões a partir de um conjunto de informações, seguindo um determinado raciocínio. Assim, a Máquina de Inferência pode ser vista como o mecanismo que provê a metodologia de raciocínio sobre a Base de Conhecimento. Para tanto ações são dirigidas no sentido de controlar e organizar os passos tomados para a obtenção de uma solução.

É composta basicamente de três elementos principais:

- a. Um interpretador, que aplica um determinado processo de inferência, em uma determinada ordem, para se obter uma conclusão.
- b. Um *scheduler*, que tem como função controlar o interpretador, aplicando critérios de seleção de informações da Base de Conhecimento e estimando os efeitos da utilização de tal informação.
- c. Um mecanismo que visa garantir a consistência da solução que está sendo obtida.

Um outro componente da máquina de inferência é o *Blackboard*, ou quadro negro. Este componente é uma área de memória de trabalho, para que o sistema possa gravar informações sobre o problema, os dados de entrada e como a resolução está sendo conduzida. Também armazena informações sobre potenciais ações da máquina de

inferência, quais as hipóteses de solução são candidatas e quais os cursos de ação alternativos que o sistema gerou até então (LUCAS & GAAG, 1991).

A escolha da estratégia utilizada pelo Mecanismo de Inferência depende da forma como o conhecimento foi representado na Base de Conhecimento. As principais estratégias são o encadeamento para trás, o encadeamento para frente e herança. Na estratégia de encadeamento para frente, os dados iniciais do problema são comparados com as regras mais relevantes. Aquela cuja parte condicional é satisfeita pelos dados é selecionada e avaliada. Na avaliação, a parte conseqüente da regra atualiza a memória de trabalho. A partir da atualização dos dados, outras regras se tornarão candidatas à avaliação, uma vez que suas partes condicionais podem ser satisfeitas pelos dados atualizados. Este processo de seleção e avaliação continua até que nenhuma parte condicional seja satisfeita pelos dados atualizados.

Esta estratégia é também chamada de orientada a dados, uma vez que a escolha de qual regra será avaliada a seguir depende dos dados que atualizam a memória de trabalho, partindo de evidências para conclusões intermediárias e destas para as conclusões finais. Pode-se utilizar vários critérios na escolha da regra, tais como prioridade, resolução de conflitos, fatores de certeza, entre outros.

No sistema de encadeamento para trás, as conclusões são relacionadas aos dados do problema por hipótese. Assim, com os dados iniciais se obtém uma conclusão ou objetivo. As regras, então, são avaliadas na busca por uma, cuja parte conseqüente esteja relacionada ao objetivo inicial. Um novo objetivo é estabelecido a partir da parte condicional desta regra selecionada. Com base neste novo objetivo, inicia-se a busca por outras regras cuja parte conseqüente esteja relacionada a ele. Esse processo irá continuar até que os objetivos sejam satisfeitos, confirmando a veracidade da hipótese estabelecida, ou que seja impossível satisfazer um objetivo, negando, assim, uma hipótese.

Quando há conflito sobre qual regra escolher o interpretador deve ter uma estratégia para escolher qual regra vai para avaliação. Algumas estratégias que podem ser implementadas:

1. Regras com maior prioridade: durante a construção da Base, a cada regra é atribuído um nível de prioridade de acordo com seu nível de certeza, sua importância ou

qualquer outra característica relevante. Este nível de prioridade é o critério utilizado na seleção de uma regra quando há conflito.

2. Regras com uso mais recente: ordena as regras de acordo com o uso mais recente no processamento dos mesmos dados.
3. Regras menos gerais: escolhe-se a regra que especifica um número menor de conclusões a partir de sua parte condicional.

É possível combinar estas duas estratégias, encadeamento para frente e para trás, iniciando a busca para frente, selecionando regras através de um conjunto inicial de evidências, gerando novos dados (fatos deduzidos a partir da parte conseqüente das regras). Então, a busca é feita para trás, procurando-se evidências que comprovem as hipóteses e objetivos gerados a partir dos dados obtidos.

Quando a representação do conhecimento é feita por objetos, ou *frames*, estes contêm informações sobre uma entidade e a ela se atribuem descrições de como se relaciona com as demais. Neste caso, a principal forma de inferência é por herança de atributos entre classes e entidades de classe, através do *slot* do objeto que contém informações do tipo “é-um”. As instâncias de um *frame* herdaram os atributos definidos para ele, bem como seus tipos, valores e restrições. Uma decisão é tomada ao se processar um determinado conjunto interconectado de *frames*.

Pode-se colocar exceções à herança em frames especializados, definindo explicitamente o que não é válido em determinada instanciação. Estratégias mais sofisticadas de inferência podem ser incluídas através de regras de produção associadas aos *frames*. Premissas e conclusões irão se referir aos frames, atributos e valores da Base de Conhecimento.

4.4.3 Interface com o Usuário

A interface gráfica é a forma através da qual o usuário utiliza e se comunica com o sistema. O uso recursos gráficos reduz o esforço mental necessário durante a interação e deve permitir que a comunicação seja amigável.

Uma área de pesquisa, em engenharia de *software*, é a de interfaces *user-friendly*, ou seja, amigável ao usuário, que desenvolve técnicas que podem ser utilizadas para melhorar a interação homem-máquina, através de conceitos de psicologia, programação visual e ciência da computação. A psicologia trata da forma como as pessoas interagem com um sistema, como se dá o processo de raciocínio humano, e qual a melhor forma manter a atenção das pessoas. Essas informações são úteis ao programador, pois dão indicações sobre a melhor forma de se realizar a sucessão de telas e do diálogo do sistema com o usuário.

A programação visual auxilia no processo de distribuição dos componentes pela tela, evitando que esta fique “muito cheia” e cansativa e dando destaque aos elementos mais importantes. A ciência da computação desenvolve dispositivos e softwares com maior qualidade de imagens, sons e vídeo e equipamentos com alto poder de processamento e armazenagem para suporta-los.

Normalmente a comunicação entre o usuário e o Sistema Especialista se dá na forma de texto, onde perguntas sucessivas e em linguagem natural são feitas na espera de respostas que possam conduzir o “raciocínio” do sistema. Para aumentar a flexibilidade do sistema, múltiplas respostas podem ser oferecidas aos usuários, inclusive com a incorporação de fatores de certeza (BELHOT, 1991). Mas com o avanço das técnicas de computação gráfica, o diálogo pode ser completado com o uso de menus, gráficos e mensagens.

Um componente, que pode melhorar a interação do usuário com o sistema especialista, é o mecanismo de explicação e justificativa, incorporando ainda mais o fator humano ao programa. A habilidade do sistema em oferecer algum tipo de explicação pode aumentar a confiança do usuário no resultado apresentado (BELHOT, 1991).

Os parâmetros de explicação e justificativa destinam-se a responder perguntas do tipo: (i) Por que determinada questão foi apresentada pelo sistema? (ii) Como certa conclusão foi obtida? (iii) Por que determinada alternativa foi rejeitada? e, (iv) Qual o método de obtenção da solução? (LUCAS & GAAG, 1991).

Outro aspecto importante da capacidade de explicação e justificativa é que através dela pode-se verificar a Base de Conhecimento na busca por falhas ou erros de

representação. Também pode se identificar conhecimento que pode ser acrescentado representando uma oportunidade de melhoria do sistema. Existem algumas estratégias que podem ser seguidas, como, por exemplo, a utilização de um mecanismo que armazene todos os passos tomados na busca da solução, como por exemplo, um *blackboard*, e a partir das informações nele registradas aplicar o encadeamento para trás e rastrear a solução obtida e demonstrá-la ao usuário.

4.5 Desenvolvimento de Sistemas Especialistas

O desenvolvimento de um Sistema Especialista é diferente dos sistemas convencionais, uma vez que suas características são distintas. Na engenharia de *software* convencional, baseada em linguagens de programação estruturadas, os requisitos funcionais são bem definidos e compreendidos já no início do projeto, sua aplicabilidade é conhecida desde o início de seu desenvolvimento e, a modificação de programas prontos é uma tarefa difícil. No caso de Sistemas Especialistas, os modelos tradicionais de definição de requisitos não podem ser aplicados e, portanto, estes são definidos no decorrer do projeto, enquanto sua viabilidade de uso. Além disso, o processo de desenvolvimento é altamente interativo, tanto com o especialista, quanto com o usuário e, neste caso, o uso de prototipagem se faz necessário e não é apenas uma opção. O processo de desenvolvimento está ilustrado na FIGURA 4.4.

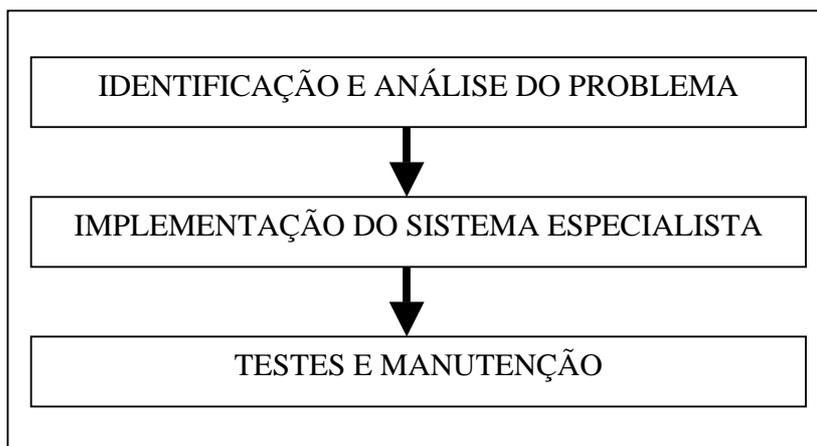


FIGURA 4.4 – Processo de desenvolvimento de um sistema especialista

A “prototipação rápida”, “construir um pouco, testar um pouco”, é usada por muitos engenheiros do conhecimento com a finalidade de especificar os requisitos. Nesta abordagem, os desenvolvedores podem utilizar quatro maneiras de estruturar a prototipação: (1) um protótipo pequeno é desenvolvido em poucas semanas e pode demonstrar a funcionalidade do sistema; (2) um protótipo maior é desenvolvido em alguns meses; (3) o processo de melhora do protótipo e testes é *repetido* até que o sistema esteja completo; e, (4) desenvolver vários protótipos em paralelo, cada um priorizando uma característica em especial (LIEBOWITZ, 1995).

4.5.1 Identificação e Análise do Problema

O primeiro passo no desenvolvimento é a escolha do problema a ser resolvido e quais os objetivos a serem atingidos pelo Sistema Especialista construído. A viabilidade do projeto é estudada, verificando se um Sistema Especialista pode ser aplicado, ou seja, problemas em uma área bem definida e que seja complexo para a modelagem matemática (KASTNER & HONG, 1984). Depois da definição da área de aplicação do sistema, se definem quais vão ser as fontes utilizadas na aquisição do conhecimento.

O processo de seleção do problema pode ser dividido em duas etapas bem definidas (LIEBOWITZ, 1988):

- a. Tipo do problema: Escolhem-se atividades que envolvem processamento simbólico e habilidades cognitivas. É necessário que a atividade tenha limites bem definidos, assim como disponibilidade de casos resolvidos para que o sistema possa ser testado. Material escrito sobre o desenvolvimento da atividade pode ser necessário para que o engenheiro do conhecimento se familiarize com o domínio do problema e o especialista responsável deve concordar com a solução proposta. A tarefa não deve gerar controvérsias para que o desenvolvimento não cause contestações.
- b. Especialista: Deve haver mais de um especialista que desenvolva a atividade e pelo menos um deve estar disposto a colaborar com o desenvolvimento do sistema. O conhecimento do especialista não deve ser baseado apenas em material escrito, mas também em experiências e julgamentos.

As categorias genéricas de problemas aos quais se aplicam Sistemas Especialistas podem ser sumarizadas na Tabela 4.2.

TABELA 4.2: Categorias de problemas para Sistemas Especialistas.

Interpretação	A partir de observações deve-se inferir conclusões
Predição	Dadas situações, infere-se quais são as conseqüências
Diagnóstico e Tratamento	Observa o mau funcionamento de alguma situação e prescreve uma atitude para correção
Reparo	Executa uma ação prescrita para corrigir um problema
Monitoração	Compara observações de comportamento de sistemas, com características consideradas necessárias para alcançar objetivos
Projeto	Configura objetos de acordo com restrições pré-estabelecidas
Planejamento	Planos são desenvolvidos para se alcançar objetivos
Ensino	Acompanha o aluno, verificando erros e os corrige
Controle	Conduz, de forma adaptativa, o comportamento de um sistema

Fonte: LUCAS & GAAG (1991).

4.5.2 Implementação do sistema especialista

Depois de identificadas as fontes, o conhecimento é adquirido e segundo suas características é representado segundo alguma estratégia. Regras de Produção são indicadas para sistemas pequenos e se o conhecimento (a) já está organizado em regras; (b) sua classificação é categórica; ou (c) não tem contexto de muita dependência (LIEBOWITZ, 1995). Já frames e redes semânticas são indicadas para casos onde o conhecimento é descritivo ou se há a necessidade de classificações complexas. A Máquina de Inferência e a *Interface* podem ser desenvolvidas ou adquiridas.

O desenvolvimento da BC e do MI deve observar as características de representação de conhecimento e a linguagem de programação escolhida deve suportar tais características. Pode-se usar linguagens estruturadas como Pascal ou C ou linguagens procedurais ou declarativas como LISP ou PROLOG, segundo a necessidade do sistema. Após a construção de alguns sistemas percebeu-se que estes possuíam algumas características em comum. Estes são construídos segundo um conjunto de representações declarativas combinadas com um interpretador dessas representações e uma interface de comunicação com o usuário. Verificou-se que seria possível separar o interpretador e a interface do conhecimento embutido no sistema e então, disponibilizá-lo para a elaboração de novos Sistemas Especialistas apenas através da adição de novos conhecimentos correspondentes ao novo domínio do problema. Estes componentes que podem ser separados do conhecimento e reaproveitados para a construção de novos sistemas são chamados de *shell*.

Segundo STYLIANOU (1995), a seleção de um *shell* depende de vários fatores, entre eles: (i) características do domínio do problema; (ii) custo; (iii) facilidades para criação e manutenção da BC; (iv) características do projeto, incluindo quais técnicas de Inteligência Artificial serão utilizadas; (v) quais são os componentes do *shell* e o que pode ser implementado utilizando esses elementos; (vi) grau de sofisticação dos usuários, implicando na necessidade de interface mais sofisticada e um melhor desempenho do sistema; (vii) facilidade de integração com *hardware* e *software* existentes; e, (viii) suporte técnico disponível.

Entre as vantagens da utilização de um shell, pode-se destacar: (a) fornece estruturas prontas, permitindo que a prototipagem do sistema seja mais rápida; e, (b) há menor necessidade de treinamento para quem vai desenvolver o sistema, já que a implementação é simplificada e as estruturas de dados e de conhecimento são pré-definidas.

4.5.3 Testes e manutenção

Depois da implementação do sistema inicia-se a fase de testes. Cabe lembrar que durante o desenvolvimento do sistema, são feitos testes, porém, nesta fase final são feitos com mais rigor e abrangência, uma vez que após esta fase, o sistema irá ser colocado em funcionamento. Os teste finais podem ser divididos em testes de verificação e validação. Estas duas fases de testes podem ser bem definidas, respectivamente, através de duas questões propostas por BOEHM (1981):

- ✓ Construimos certo, o produto?
- ✓ Construimos o produto certo?

Durante a verificação, se determina se o sistema satisfaz completamente suas especificações (ADRION et al, 1982). Os testes de verificação checam a base de conhecimento e o mecanismo de inferência, investigando se o sistema tem condições de produzir respostas corretas.

Essa checagem, terminada a implementação do sistema, é importante, pois pode produzir uma série de resultados inesperados que são gerados devido às falhas no projeto e precisam ser reparados para que o sistema opere corretamente. Estes resultados podem ser (HAYES-ROTH et al, apud LIEBOWITZ, 1995):

- ✓ Excesso de generalidade: durante o levantamento de conhecimento, casos especiais foram negligenciados;
- ✓ Excesso de especificidade: a generalidade não foi captada a partir dos casos levantados;
- ✓ Pobreza de conceitos: relacionamentos úteis entre conceitos e fatos não foram detectados, nem tampouco explorados;
- ✓ Conhecimento inválido: consequência de fatos e aproximações mal declarados;

- ✓ Conhecimento ambíguo: as dependências implícitas foram inadequadamente articuladas;
- ✓ Raciocínio inválido: o conhecimento foi transformado de forma incorreta pelo programador;
- ✓ Integração inadequada: as dependências entre as múltiplas partes de um domínio não foram completamente integradas;
- ✓ Horizonte limitado: as conseqüências de eventos passados, presentes e futuros não foram exploradas;
- ✓ Egocentrismo; deu-se pouca atenção ao significado das ações de outras pessoas.

A validação determina se o software funcionará corretamente quando colocado em funcionamento. Além da avaliação do conhecimento, a qualidade da resposta dada pelo sistema é testada, através de casos conhecidos, comparando-se a saída do sistema com as respostas certas a problemas já resolvidos e com opiniões de especialistas. Os critérios de avaliação que devem ser considerados na validação são: conteúdo de entrada e da saída, raciocínio correto, custo-benefício e facilidade no uso (LIEBOWITZ, 1995). Quando estes critérios são levados em conta, o desempenho de um Sistema Especialista será enriquecido.

A manutenção é a fase que sucede a implantação, após algum tempo de uso do sistema, para correção de erros que passaram despercebidos pelos testes e adição de novos conhecimentos. As ferramentas utilizadas durante esta fase devem suportar as tarefas de edição e atualização do conhecimento e das variáveis.

Como na maioria dos casos o time de manutenção tem acesso limitado ao domínio original do problema, pode ocorrer ambigüidade na atualização da BC. Além disso, o rastreamento do código original é complicado, uma vez que as linguagens de programação são mais complexas do que as de sistemas comuns, o que pode levar a erros durante a manutenção. Uma possível estratégia para evitar tais problemas é o treinamento de uma equipe permanente de manutenção, durante o desenvolvimento do software. Dessa maneira, a equipe vai estar familiarizada com o problema e com o programa, diminuindo o número de erros durante modificações do sistema.

4.5.4 Shells

“*Shell* é um pacote de software que contém uma máquina de inferência genérica, uma interface com o usuário e outras ferramentas que permitem ao usuário desenvolverem o sistema especialista. Usando as ferramentas do *shell*, um engenheiro do conhecimento pode desenvolver novas bases de conhecimento, estruturando, adicionando, removendo e modificando o conhecimento nelas contido. O mecanismo de inferência contém paradigmas de inferência. A interface do *shell* permite ao usuário interagir com o sistema especialista, extraindo conhecimento dele e requisitando explicações, sobre o raciocínio por trás das conclusões” (STYLIANOU, 1995, p. 143).

Após o desenvolvimento de alguns sistemas especialistas, percebeu-se que o que os diferenciava era o conhecimento representado em sua base. O mecanismo de inferência e a interface com o usuário eram desenvolvidos da mesma maneira para sistemas diferentes. O primeiro *shell* foi desenvolvido a partir do MYCIN, retirando-lhe a base de conhecimento e criando o EMYCIN (*Empty MYCIN* – *Empty* significa vazio). Com o mecanismo de inferência e a interface com o usuário, disponíveis bastava acrescentar conhecimento, representado de uma forma que pudesse ser manipulado pelo mecanismo de inferência, que um novo sistema especialista seria desenvolvido.

Desde o desenvolvimento do EMYCIN, os *shells* evoluíram muito. Com o surgimento de linguagens de programação gráficas e orientação a objeto, a interface gráfica oferecida pelo *shell* se tornou *user-friendly* e a forma de representação do conhecimento foi simplificada. Mas, apesar de toda a evolução, ainda existem controvérsias a respeito de uso de *shells*.

Segundo (STYLIANOU, 1995), para alguns pesquisadores as principais desvantagens do uso de *shells* são:

- ✓ por serem genéricos, eles têm uma visão limitada das características das aplicações desenvolvidas.
- ✓ não apresentam um modo eficaz de avaliação.

- ✓ quem desenvolve um sistema especialista fica limitado às ferramentas neles disponíveis.

Porém outros pesquisadores defendem que o uso de *shell* diminui o tempo de desenvolvimento e facilita a criação de um sistema especialista, permitindo a quem está desenvolvendo se concentrar na implementação da base de conhecimento, que é o principal elemento do sistema.

Existem muitos *shells* disponíveis no mercado e STYLIANOU (1995) propõem um método de seleção que deve ser feito levando em consideração a aplicação a ser desenvolvida:

1. Identificação das características e funções que a aplicação necessita.
2. Identificação de todos os possíveis candidatos a shell.
3. Avaliação dos candidatos baseada nas capacidades requisitadas pela aplicação e especificações técnicas. Critérios como preço, documentação e suporte podem ser levados em conta, bem como outros critérios de interesse de quem vai desenvolver o sistema especialista.
4. Seleção.

Alguns exemplos de Shell são:

- ✓ Expert SINTA: é um *shell* implementado na linguagem de programação orientada a objetos Borland Delphi, dando um suporte visual de fácil operação, inspirado na arquitetura clássica do MYCIN. O Expert SINTA permite o desenvolvimento modular de bases de conhecimento através de uma interface de fácil manipulação e de utilitários criados para depuração. A representação do conhecimento é feita com o uso de regras de produção este shell realiza inferência por busca para trás. No tratamento de incertezas, o shell utiliza algumas regras de cálculo de incertezas que utilizam, inclusive, o fator de confiança do usuário em relação às respostas dadas. O Expert SINTA é um software gratuito desenvolvido pela Universidade Federal do Ceará. O download e distribuição são permitidos, mas a engenharia reversa e revenda são proibidas. Mais informações e o download gratuito do shell podem ser feitos no site: <http://www.lia.ufc.br/~bezerra/exsinta/exsintashell.htm>.

- ✓ EMYCIN: *Shell* baseado no MYCIN. Download e tutorial gratuitos estão disponíveis no *site*: <http://www.cpes.sussex.ac.uk/faculty/raj/emycin.html>.
- ✓ VP-Expert: está disponível para *download* gratuito uma versão para estudantes, mas essa versão não tem todas as opções disponíveis e o tamanho da base de conhecimento é limitado. A representação do conhecimento é feita por meio de regras de produção. Informações disponíveis no *site*: <http://aseexpert.home.ro/tutorial.html>.
- ✓ Flex: produzido pela *Logic Programming Associates*, este *shell* é orientado para encadeamento para frente e para trás. A representação do conhecimento é feita por *frames* e herança. As linguagens de programação compatíveis com o *shell* são C e Prolog.
- ✓ NEXPERT OBJECT: é um *shell* popular produzido pela *Neuron Data*. A representação do conhecimento é feita por regras. Implementa encadeamento para frente e para trás. Suporta arquitetura cliente/servidor e GUI (*Graphic User Interface*). A linguagem C pode ser usada para acessar o *kernel* do *shell*.

4.6 Sistemas Especialistas no ambiente industrial

Existem muitas aplicações para os sistemas especialistas em um ambiente industrial. Segundo WONG & MONACO (1995) áreas de aplicação de sistemas especialistas são:

- ✓ Auditoria.
- ✓ Finanças.
- ✓ Sistemas de Informação.
- ✓ Manutenção.
- ✓ Recursos Humanos.
- ✓ Produção.

A TABELA 4.3 contém exemplos de sistemas especialistas desenvolvidos para a indústria.

TABELA 4.3 – Exemplos de sistemas especialistas na manufatura.

Sistema Especialista	Representação do conhecimento	Aplicação	Linguagem de desenvolvimento
ERSCHLER & ESQUIROL (1986)	Regras	<i>Scheduling</i> em <i>job-shop</i>	Prolog
FELLENSTEIN et al. (1985)	Regras	Planejamento da capacidade	Sylog
GENESYS (METAXIOTIS et al., 2002)	Regras	Sistema Especialista Genérico para Scheduling da Produção	Shell: Nexpert Objects
Nokia planner (KUSIAK & CHEN, 1988)	Informação não encontrada	Planejamento de projetos	Lisp, Apollo
NICAD (NURMINEN et al., 2003)	Informação não encontrada	CAD inteligente para engenharia	KEE, Symbolics

WONG & MONACO (1995) realizaram um levantamento sobre os sistemas especialistas desenvolvidos para aplicações em negócios. Algumas das áreas de aplicação dos sistemas especialistas são WONG & MONACO (1995):

- ✓ Auditoria: por exemplo, estimativa de custo, e auditoria de seguro saúde.
- ✓ Finanças: por exemplo, análise de orçamento, planejamento financeiro e análise de investimentos.
- ✓ Recursos Humanos: por exemplo, *scheduling* de mão-de-obra, seleção de pessoal e treinamento.
- ✓ Sistemas de Informação: por exemplo, análise de dados, indexação de base de dados, avaliação de softwares e projeto de software.
- ✓ Distribuição e Marketing: análise de mercado, planejamento de distribuição, gestão de vendas e marketing.
- ✓ Produção: por exemplo, controle de estoque, simulação de manufatura, controle de sistema de manufatura flexível, planejamento da produção, *scheduling*, controle de qualidade, compra e projeto de produto.
- ✓ Gestão Estratégica: suporte à negociação e previsão estratégica.

4.6.1 Sistemas especialistas para previsão de demanda

CHIU et al. (1997) descreve a utilização de um sistema especialista combinado com uma rede neural para a previsão da demanda de energia elétrica para uma empresa de fornecimento em Taiwan. Previsões de curto prazo exatas resultam em economia para as empresas, que pode ser aplicada, por exemplo, na manutenção da rede elétrica. O sistema especialista armazena o conhecimento, a experiência e o pensamento analítico dos operadores do sistema. A previsão feita pelo sistema especialista alimenta a rede neural que melhora a previsão por meio de informações sobre as condições climáticas.

SMITH & HUSEIN (1996) apresenta o impacto de um sistema especialista para a previsão de demanda na tomada de decisão. O estudo de caso foi feito na empresa *Gas Headquarters*, no Reino Unido. O gás é adquirido de diversos fornecedores, em uma taxa constante e os pedidos devem ser feitos com 12 horas de antecedência. A demanda varia ao longo do dia e o maior consumo se concentra no período das 06 às 22 horas, aumentando durante o inverno. Outros fatores que contribuem para a variação do consumo de gás são: a condição do tempo e o dia da semana. As falhas no fornecimento de gás são penalizadas com multa ou com perda da concessão de fornecimento. Como o processo de previsão de demanda envolvia variáveis complexas e os modelos matemáticos não apresentaram bons resultados, optou-se pelo desenvolvimento de um sistema especialista. Testes mostraram que o sistema especialista apresentou melhores resultados do que outras ferramentas de previsão de demanda.

KANDIL et al. (2001) relata o desenvolvimento de um sistema especialista para previsão de longo e médio prazo da demanda para um sistema de fornecimento de energia elétrica. As principais características da demanda são a dependência da temperatura e a instabilidade. Além disso, feriados e datas religiosas também influenciam a demanda por energia elétrica. Vários modelos matemáticos foram testados, mas nenhum obteve resultado satisfatório, mostrando a necessidade do desenvolvimento de uma ferramenta que pudesse armazenar o conhecimento de especialistas sobre as diversas características envolvidas no processo de previsão. O sistema desenvolvido obteve resultados melhores

do que os modelos matemáticos. Métodos de série temporal e modelos econométricos são usados como assistentes aos especialistas em planejamento.

5 PROTÓTIPOS DOS SISTEMAS ESPECIALISTAS PARA PREVISÃO DE DEMANDA

5.1 Introdução

WEBBY & O'CONNOR (1996) afirmam que o ajuste é benéfico para a previsão, pois, adiciona à previsão informações que não podem ser representadas pelos modelos matemáticos. Ainda segundo os autores, o uso de ajuste baseado em julgamento não é feito apenas com modelos simples de previsão de demanda, uma vez que, na prática, o ajuste de modelos econométricos, que são mais complexos, também é realizado.

Esta pesquisa propõe uma adaptação do método de ajuste proposto por WEBBY & O'CONNOR (1996). No método desenvolvido pela pesquisa o julgamento é utilizado em dois momentos na elaboração da previsão: (a) a partir dos dados históricos os métodos quantitativos mais adequados são indicados, para que suas previsões sejam combinadas e, (b) a previsão resultante é ajustada, com base em um conhecimento dos fatores qualitativos que podem alterar a demanda. Este método proposto está representado na FIGURA 5.1.

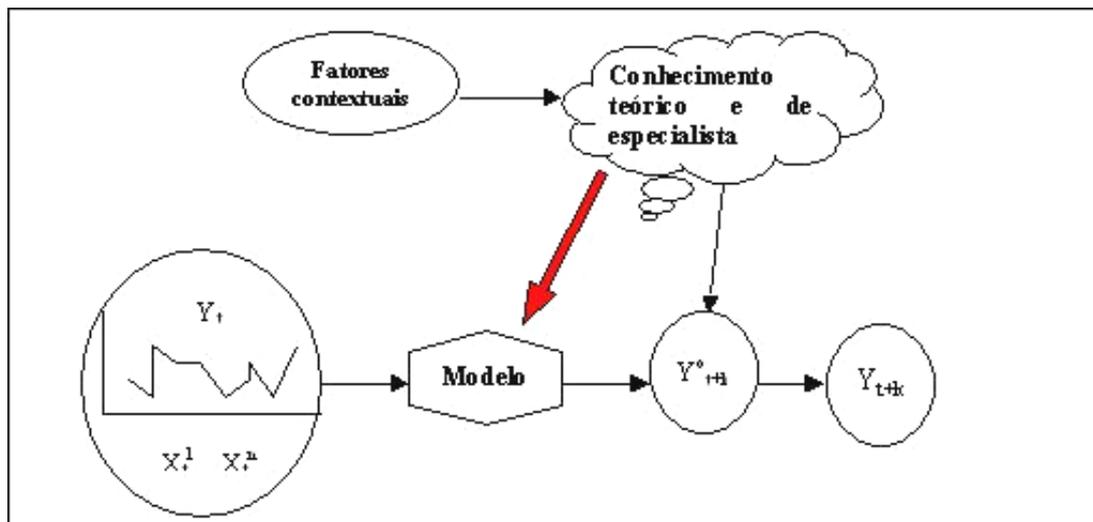


FIGURA 5.1 – Método de previsão de demanda proposto.

Os passos implementados pelo método proposto pela pesquisa são:

1. Os registros das vendas do produto são “plotados” em gráficos.
2. A partir da análise destes gráficos um primeiro sistema especialista identifica quais os métodos quantitativos são mais adequados ao comportamento apresentado pelos dados.
3. As previsões geradas pelos métodos quantitativos são combinadas resultando em uma previsão quantitativa.
4. Esta previsão quantitativa é, então, ajustada como uso de um segundo sistema especialista que armazena conhecimento sobre os fatores qualitativos que podem alterar a demanda.

O primeiro sistema especialista desenvolvido, o qual indica quais métodos quantitativos são mais indicados para um determinado comportamento da demanda, é “genérico” e pode ser aplicado para qualquer tipo de empresa. Porém o segundo sistema especialista é específico a empresa para a qual está sendo desenvolvido o sistema de previsão de demanda. Desta forma, esta pesquisa propõe uma forma de gerar uma base de conhecimento dos fatores quantitativos que pode ser utilizado por outros tipos de empresa, além daquele para o qual foi desenvolvida a solução.

5.2 Solução: sistema especialista para previsão de demanda

Para que a previsão para um determinado produto seja feita, inicialmente é necessário que sejam identificados quais os métodos de pesquisa operacional que são mais adequados, ou seja, realizarão a previsão com maior acurácia. O primeiro passo para selecionar desenvolver este sistema de previsão de demanda é identificar para qual tomada de decisão esta previsão vai ser útil e a partir daí determinar o horizonte de planejamento da previsão.

Identificou-se que a previsão resultante do sistema especialista auxiliaria decisões sobre programação da produção e controle de estoque. Desta forma, o horizonte deste tipo de previsão é de curto prazo, e existem alguns métodos que abrangem esta janela

de tempo e são mais adequados. Como já visto na TABELA3.2, os métodos com horizonte de planejamento de curto prazo são:

- ✓ Métodos Bayesianos
- ✓ Métodos de Média Móvel
- ✓ Métodos de Suavização Exponencial
- ✓ Métodos de Regressão
- ✓ Modelos de Box-Jenkins
- ✓ Métodos baseados em redes neurais
- ✓ Julgamento de Especialista

Por serem complexos e necessitarem de um grande número de dados históricos, MONTGOMERY & JOHNSON (1976) afirmam que são necessários pelo menos 50 observações históricas para o modelo possa ser construído, este método não vai ser considerado entre aqueles que serão indicados pelo primeiro sistema especialista. Os Métodos Bayesianos também não serão implementados nesta pesquisa, por serem indicados para a previsão de produtos em lançamento, com pouca ou nenhuma informação disponível e devem ser usados por um curto período de tempo. MONTGOMERY & JOHNSON (1976) afirmam que ao existirem informações históricas suficientes para se optar por outro método, a previsão feita com base nos métodos Bayesianos deve ser descartada. Métodos baseados em redes neurais não serão também implementados pela pesquisa por também serem complexos e custosos. Julgamento de especialista será efetuado pelo segundo sistema, e portanto, não está entre as indicações do primeiro sistema.

Os métodos estudados nesta pesquisa estão descritos no Capítulo 3 e podem ser facilmente implementados pelas fórmulas descritas em planilhas eletrônicas, como o *Microsoft Excel*.

5.2.1 A escolha do shell

Os dois sistemas especialistas foram desenvolvidos no Expert Sinta, um *shell* com distribuição gratuita, desenvolvido pela Universidade Federal do Ceará. Mais detalhes do *shell* estão apresentados na seção 4.5.4.

Optou-se por este *shell* para o desenvolvimento da pesquisa por três motivos:

- ✓ não houve necessidade de aquisição de licença: este software possui licença de software livre e tem distribuição gratuita;
- ✓ facilidade no uso: este *shell* é *user-friendly* e devido à facilidade de uso permite que o sistema seja desenvolvido e testado rapidamente;
- ✓ interface do sistema desenvolvido: este *software* permite a construção de sistemas especialistas que tenha uma interface amigável e ainda permite inserção de arquivos de ajuda.

Apesar das vantagens, este software não permite a realização de cálculos matemáticos complexos, portanto o primeiro sistema especialista indica os métodos, mas não calcula a previsão. Estes cálculos, no entanto podem ser facilmente realizados em algum sistema de planilha eletrônica. Nesta pesquisa utilizou-se o Microsoft Excel.

5.3 SEIMP – Sistema Especialista para Identificação dos Métodos de Previsão de Demanda

A principal finalidade deste sistema, é a partir das informações fornecidas pelo usuário identificar quais métodos de previsão de demanda são mais adequadas ao seu produto. Por meio de levantamento bibliográfico identificou-se que os métodos podem ser indicados pelo comportamento que os dados históricos apresentam.

A curva formada pelos dados históricos das vendas, quando “plotados” em um gráfico, apresentam uma tendência (por exemplo, de linearidade), através da qual é possível identificar características do produto e qual o comportamento da demanda, e então verificar qual método de previsão de demanda realiza uma previsão mais acurada. O estágio do ciclo de vida no qual o produto está também revela informações sobre o comportamento da demanda.

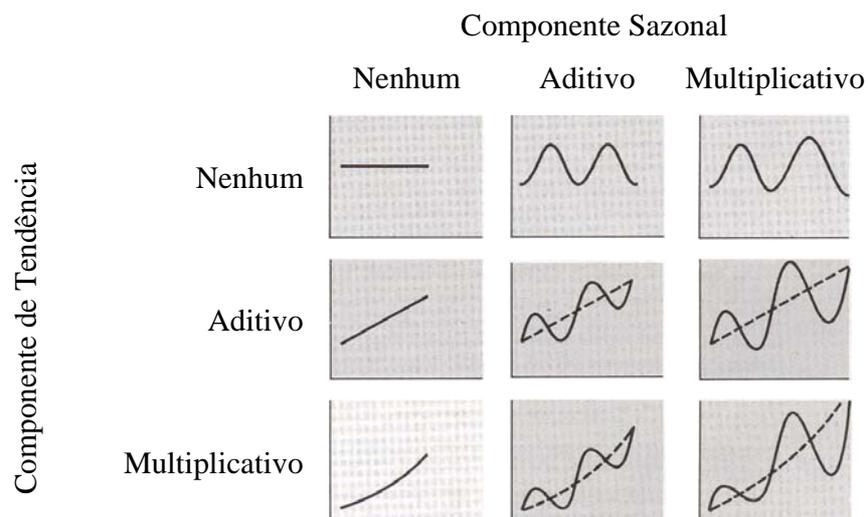
Quando um produto está no início de seu ciclo de vida, ele está sendo introduzido no mercado e, portanto, está começando a se tornar conhecido. Não se sabe ao certo se o produto será aceito pelo mercado e qual o grau de aceitação do mesmo. Neste estágio a demanda tende a ser altamente variável. Conforme a aceitabilidade do produto vai

crescendo e, através de campanhas promocionais e propaganda “boca a boca” por parte dos consumidores, ele passa a ser mais conhecido, a demanda assume uma tendência de crescimento, que pode ser multiplicativa, exponencial ou linearmente crescente.

Próximo de atingir o estágio de maturidade ou ao deixá-lo, os dados apresentam comportamento logarítmico. Ao atingir o estágio de maturidade, a demanda passa a ser constante, ou seja, variar em torno de uma média estacionária. Quando o produto atinge este estágio, diz-se que sua demanda apresenta tendência linear. Em algum momento o mercado estará saturado deste produto ou novos lançamentos irão acontecer. Como a tecnologia evolui constantemente e novos produtos, com maior valor agregado e com novas “funções, tecnologia ou características” são lançados. Neste momento, a demanda começa a apresentar uma tendência de declínio, que pode ser logarítmica, exponencial ou linear. Esta fase persiste até que o produto seja retirado do mercado ou substituído por outro com tecnologia mais avançada ou mais adequado aos desejos dos consumidores.

Além das tendências, os produtos, devidos às suas características, apresentam comportamento sazonal, ou seja, consumo é maior em determinados períodos. Sorvetes e ventiladores, por exemplo, tem seu consumo aumentado na estação do calor. A demanda também pode apresentar picos devido a campanhas promocionais, incentivos do governo ou datas específicas. Eletrodomésticos de linha branca, como geladeiras e máquinas de lavar, apresentam picos de vendas em períodos próximos ao dia das mães e natal.

Observando o comportamento dos dados de demanda “plotados” em um gráfico alguns componentes podem ser identificados: sazonalidade e tendência (BUFFA & SARIN, 1985). Os componentes sazonais e de tendência que a demanda pode apresentar estão apresentados na FIGURA 5.1. Deve se considerar que os componentes aditivo e multiplicativo também podem representar casos nos quais a demanda está em queda. Além disso, estes modelos da FIGURA 5.1 são “uma linha de base”, ao redor da qual a demanda vai variar. Esta variação, quando pequena, indica estabilidade no comportamento. Além disso a variação pode ser grande e irregular e o comportamento da demanda é dito irregular.



Fonte: BUFFA & SARIN (1985)

FIGURA 5.1 – Componentes sazonais e de tendência da demanda.

Nesta etapa então foram identificados quais métodos são mais adequados a determinado comportamento dos dados históricos por meio de levantamento bibliográfico, as conclusões obtidas estão apresentadas na TABELA 5.1.

TABELA 5.1 – Relação entre os métodos de previsão de demanda e a tendência dos dados.

Métodos de previsão de demanda	Características	Fontes
Métodos bayesianos	Indicado quando os dados históricos são insuficientes para desenvolver um sistema de previsão	MONTGOMERY & JOHNSON (1976), SIPPER & BULFIN (1998)
Média Móvel e Média Móvel Ponderada	Indicados para produtos que apresentam variação em torno de uma média estacionária. Quanto menor o período considerado,	SIPPER & BULFIN (1998), BUFFA & SARIN (1987), KRAJEWSKI & RITZMAN (1987), NAHMIA (2001), NARASIMHAN ET AL. (1995), WINSTON (1994)

	mais indicado o método se torna para um comportamento irregular	
Suavização Exponencial Simples	Indicado para comportamento linear estacionário, ou seja, que varia pouco em torno de um valor médio, ou seja, para produtos que estejam no estágio de maturidade do seu ciclo de vida	SIPPER & BULFIN (1998), BUFFA & SARIN (1987), KRAJEWSKI & RITZMAN (1987), NAHMIAS (2001), NARASIMHAN ET AL. (1995), WINSTON (1994)
Método de Holt – Suavização Exponencial Dupla	Indicado para comportamento com tendência de crescimento ou decrescimento	SIPPER & BULFIN (1998), BUFFA & SARIN (1987), NAHMIAS (2001), MONTGOMERY & JOHNSON (1976), WINSTON (1994), KRAJEWSKI & RITZMAN (1987)
Método de Winters – Suavização Exponencial Tripla	Indicado para comportamento sazonal	SIPPER & BULFIN (1998), BUFFA & SARIN (1987), NAHMIAS (2001), MONTGOMERY & JOHNSON (1976), NARASIMHAN ET AL. (1995), WINSTON (1994), KRAJEWSKI & RITZMAN (1987)
Método de Regressão	Indicado para comportamento estacionário, seja entrando, saindo ou estando no estágio de maturidade	WINSTON (1994), SIPPER & BULFIN (1998), BUFFA & SARIN (1987), MONTGOMERY & JOHNSON (1976), KRAJEWSKI & RITZMAN (1987)

A partir deste levantamento foi desenvolvido um sistema especialista que aconselha ao usuário quais os melhores métodos para o produto que ele deseja fazer previsões de demanda. Para que o usuário interaja com o sistema especialista é necessário que seja utilizado o software Microsoft Excel para “plotar” os dados históricos sobre as vendas e identificar a tendência dos dados. Optou-se Microsoft Excel pelo acesso a este software, porém pode ser utilizado qualquer software que ajuste funções matemáticas à curvas desenhadas a partir de uma massa de dados, com por exemplo, o *Origin* ou algum outro software com o qual o usuário tenha facilidade de uso.

Considerando que o Excel esteja sendo usado, o usuário deve registrar em uma planilha os dados históricos sobre as vendas do produto em um período de um ano e então construir um gráfico com base nestes dados. No gráfico, o usuário deve tentar ajustar as funções de tendência linear, exponencial, logarítmica, polinomial com grau 6 ou média móvel. A partir destes resultados o Sistema Especialista pode interagir com ele e então aconselhar sobre os métodos mais indicados.

Para adicionar uma linha de tendência ao gráfico os seguintes passos devem ser realizados:

- ✓ clicar na curva à qual se queira adicionar a tendência;
- ✓ no menu *gráfico*, a função *adicionar linha de tendência* deve ser selecionada;
- ✓ na guia *tipo*, selecionar o tipo de linha de tendência;
- ✓ na guia *opções*, selecionar as funções *exibir valor de r-quadrado no gráfico* e *exibir equação no gráfico*;

A linha de tendência linear tenta aproximar uma reta aos dados, e é útil para identificar um comportamento estável ou aumento ou diminuição em uma taxa fixa. A linha de tendência polinomial aproxima uma curva a dados que apresentam flutuação e é útil para indicar sazonalidade. A linha de tendência exponencial aproxima uma curva a dados que apresentem crescimento ou decrescimento com taxas variáveis e é útil para indicar rápido crescimento ou queda nas vendas. A linha de tendência logarítmica aproxima uma curva a dados que inicialmente apresenta alta taxa de crescimento ou decrescimento e depois se estabiliza e é útil para identificar uma estabilização depois de rápido crescimento ou decrescimento nas vendas. Média móvel aproxima uma curva que tenta apresentar o mesmo comportamento dos dados e é a aproximação indicada para dados que apresentam alta variação dos dados. A linha de tendência polinomial é indicada para aproximação de uma curva a dados que variem em uma taxa fixa. Como este tipo de comportamento dificilmente é apresentado pelas curvas de demanda, este tipo de linha de tendência não é utilizada nesta pesquisa.

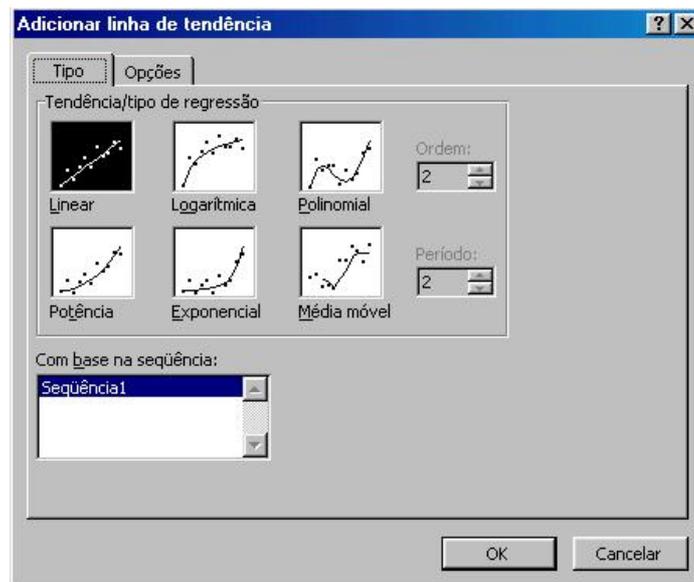


FIGURA 5.2 - Adicionar linha de tendência no Excel.

O valor r-quadrado reflete o desempenho do ajuste da linha de tendência. Quanto mais o seu valor se aproximar de 1 (um) mais a linha de tendência terá se aproximado da curva, indicando que a função escolhida para o ajuste está próxima da função que gerou a curva. A Ajuda do Microsoft Excel afirma que valores maiores do que 0,9 indicam sucesso na aproximação.

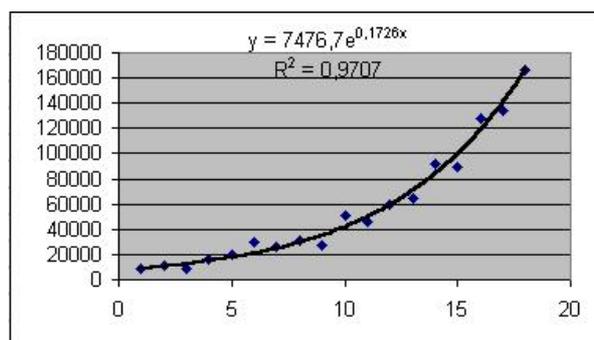


FIGURA 5.3 – Linha de tendência a um conjunto de dados.

Para tentar identificar o comportamento dos dados o Sistema inquire sobre ajuste das curvas de tendência linear, exponencial, logarítmico, polinomial e por média móvel que o usuário realizou no Excel e então indica quais são os métodos de previsão

mais adequados ao comportamento apresentado pelos dados. O conhecimento utilizado no desenvolvimento do SEIMP foi adquirido a partir de revisão de literatura sobre previsão de demanda. Inicialmente foram identificadas as possíveis fontes de informação sobre o comportamento da demanda e os métodos de previsão de demanda. As informações foram coletadas, classificadas e refinadas. O resultado deste levantamento está representado na TABELA 5.1 e a partir destas informações, as regras de produção foram desenvolvidas. Utilizou-se esta forma de representação de conhecimento pois é a forma implementada pelo *shell* escolhido. A seguir são apresentadas as regras da base de conhecimento.

Regra 1: se a tendência linear foi a melhor aproximação para a curva

SE	aproximação linear = sim
ENTÃO	tendência linear = sim

Regra 2: verifica se os dados apresentam tendência linear constante

SE	tendência linear = sim E coef angular = próximo de zero
ENTÃO	tendência linear constante = sim

Regra 3: indica os métodos de previsão para tendência linear constante

SE	tendência linear constante = sim
ENTÃO	recomenda média móvel, regressão linear e suavização exponencial simples

Regra 4: verifica se os dados apresentam tendência linear crescente

SE	tendência linear = sim E coef angular = positivo
ENTÃO	tendência linear crescente = sim

Regra 5: indica os métodos de previsão para tendência linear crescente

SE	tendência linear constante = sim
ENTÃO	recomenda média móvel ponderada e método de holt

Regra 6: verifica se os dados apresentam tendência linear de queda

SE	tendência linear = sim E coef angular = negativo
ENTÃO	tendência linear queda = sim

Regra 7: indica os métodos de previsão para tendência linear decrescente

SE	tendência linear queda = sim
ENTÃO	recomenda média móvel ponderada e método de holt

Regra 8: se a tendência exponencial foi a melhor aproximação para a curva

SE	aproximação exponencial = sim
ENTÃO	alta variação = sim

Regra 9: verifica se a alta variação é crescente

SE	alta variacao = sim E constante = positiva
ENTÃO	alto crescimento = sim

Regra 10: indica os métodos de previsão para dados com alta variação crescente

SE	alto crescimento = sim
ENTÃO	recomenda média móvel ponderada, método de holt e método de holt com alfa adaptado

Regra 11: verifica se a alta variação é decrescente

SE	alta variacao = sim E constante = negativa
ENTÃO	alta queda = sim

Regra 12: recomenda os métodos para comportamento de alta variação decrescente

SE	alta queda = sim
ENTÃO	recomenda média móvel ponderada, método de holt e método de holt com alfa adaptado

Regra 13: se a tendência logarítmica foi a melhor aproximação para a curva

SE	aproximação logarítmica = sim
ENTÃO	estabilizando = sim

Regra 14: verifica se a estabilização ocorre depois de crescimento

SE	alta variação = sim E termo = negativo
ENTÃO	crescimento e estável = sim

Regra 15: recomenda os métodos para comportamento de estabilização depois de crescimento

SE	crescimento e estável = sim
ENTÃO	recomenda média móvel ponderada e suavização exponencial

Regra 16: verifica se a estabilização ocorre depois de decrescimento

SE	alta variação = sim E termo = positivo
ENTÃO	queda e estável = sim

Regra 17: recomenda os métodos para comportamento de estabilização depois de decrescimento

SE	queda e estável = sim
ENTÃO	recomenda média móvel ponderada e suavização exponencial

Regra 18: se a tendência polinomial foi a melhor aproximação para a curva

SE	aproximação polinomial = sim
ENTÃO	sazonalidade = sim

Regra 19: verifica se mesmo dados com sazonalidade, se há alguma tendência

SE	aproximação polinomial = sim E coeficiente \leq zero
ENTÃO	sazonalidade e tendência = sim

Regra 20: verifica se mesmo dados com sazonalidade, a tendência é de estabilidade

SE	aproximação polinomial = sim E coeficiente = zero
ENTÃO	sazonalidade constante = sim

Regra 21: recomenda os métodos para comportamento sazonalidade sem tendência

SE	sazonalidade constante = sim
ENTÃO	recomenda média móvel ponderada e método de winters

Regra 22: verifica se dados com sazonalidade e tendência, se a tendência é crescente

SE	sazonalidade e tendência = sim E coeficiente = positivo
ENTÃO	sazonalidade crescente = sim

Regra 23: recomenda os métodos para comportamento sazonalidade com tendência de crescimento

SE	sazonalidade crescente = sim
ENTÃO	recomenda método de winters e método de holt

Regra 24: verifica se dados com sazonalidade e tendência, se a tendência é decrescente

SE	sazonalidade e tendência = sim E coeficiente = negativo
ENTÃO	sazonalidade decrescente = sim

Regra 25: recomenda os métodos para comportamento sazonalidade com tendência de decrescimento

SE	sazonalidade decrescente = sim
ENTÃO	recomenda método de winters e método de holt

Regra 26: se a tendência média móvel foi a melhor aproximação para a curva

SE	aproximação média = sim
ENTÃO	sem padrão = sim

Regra 27: verifica se, com dados sem padrão, para uma segunda aproximação, a tendência linear é melhor do que a polinomial e se esta tendência é constante

SE	aproximação média = sim E aprox. polinomial = não E coeficiente = zero
ENTÃO	sem padrão constante = sim

Regra 28: recomenda os métodos para comportamento sem padrão e com leve tendência constante

SE	sem padrão constante = sim
ENTÃO	recomenda média móvel e suavização exponencial

Regra 29: verifica se, com dados sem padrão, para uma segunda aproximação, a tendência linear é melhor do que a polinomial e se esta tendência é crescente

SE	aproximação média = sim E aprox. polinomial = não E coeficiente = positivo
ENTÃO	sem padrão crescente = sim

Regra 30: recomenda os métodos para comportamento sem padrão e com leve tendência crescente

SE	sem padrão crescente = sim
ENTÃO	recomenda média móvel e método de holt

Regra 31: verifica se, com dados sem padrão, para uma segunda aproximação, a tendência linear é melhor do que a polinomial e se esta tendência é decrescente

SE	aproximação média = sim E aprox. polinomial = não E coeficiente = negativo
ENTÃO	sem padrão decrescente = sim

Regra 32: recomenda os métodos para comportamento sem padrão e com leve tendência decrescente

SE	sem padrão decrescente = sim
ENTÃO	recomenda média móvel e método de holt

Regra 33: verifica se, com dados sem padrão, para uma segunda aproximação, a tendência polinomial é melhor do que a linear

SE	aproximação média = sim E aprox. polinomial = sim
ENTÃO	sem padrão sazonal = sim

Regra 34: recomenda os métodos para comportamento sem padrão e com leve tendência de sazonalidade

SE	sem padrão sazonal = sim
ENTÃO	recomenda média móvel e método de holt

As regras são encadeadas de forma a testar as tendências na seguinte seqüência: linear, exponencial, logarítmica, polinomial e média móvel. O encadeamento do *shell* é para trás e o objetivo do sistema é recomendar os métodos. A relação entre as regras está representada na FIGURA 5.4.

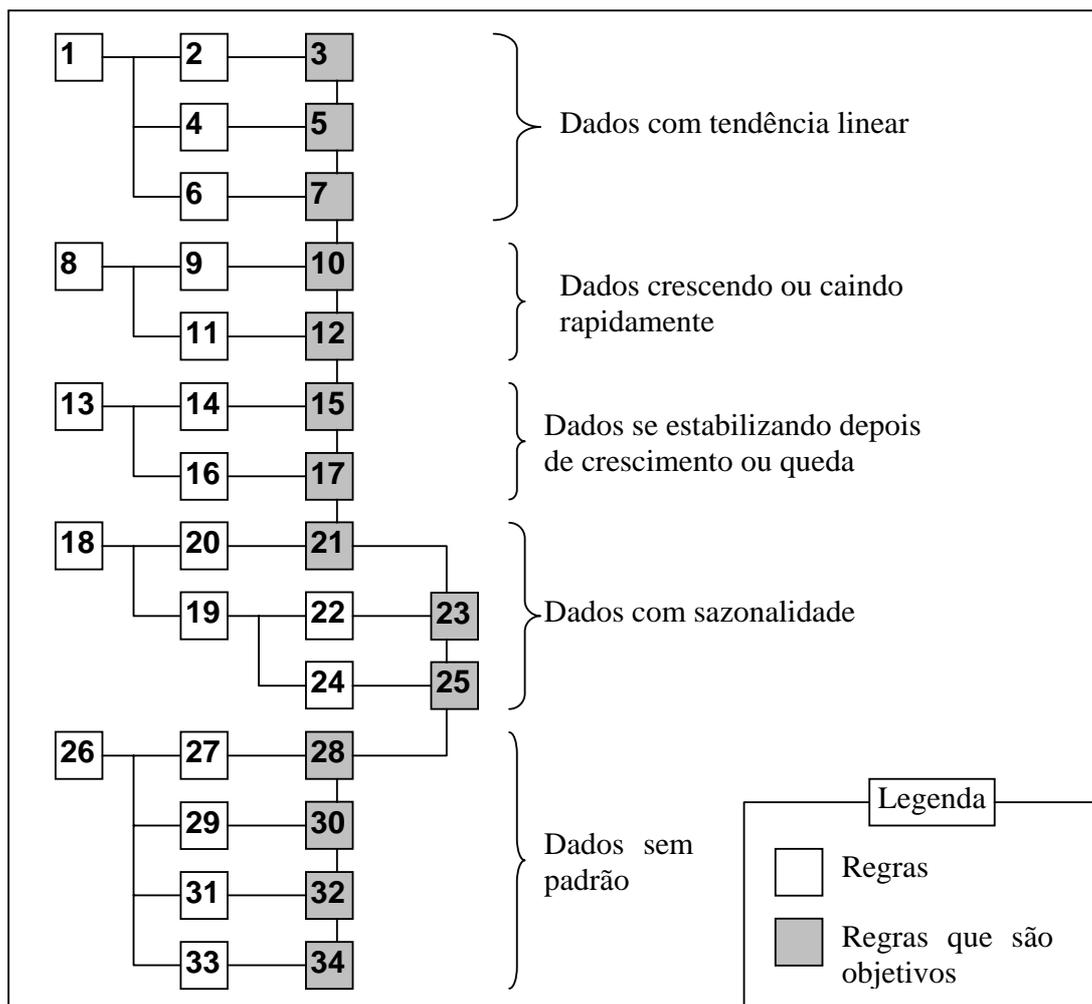


FIGURA 5.4 – Encadeamento da regras na base de conhecimento do SEIMP.

Durante a execução do sistema, o usuário irá interagir por meio de telas que permitem a escolha de opções, a inserção de valores e botões para guiar as ações. Supondo que o usuário realizasse uma consulta, para saber qual os métodos mais indicados ao seu conjunto de dados.

- ✓ Inicialmente uma tela explica o propósito do sistema.

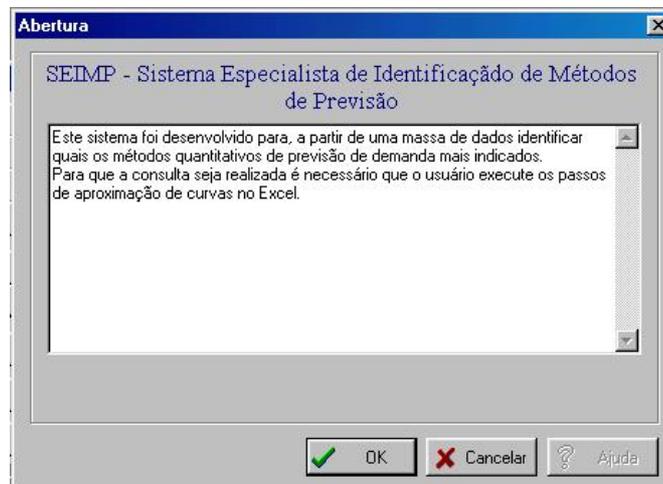


FIGURA 5.5 – Tela de abertura do SEIMP.

- ✓ Posteriormente são feitas perguntas a respeito das aproximações das linhas de tendência aos dados plotados nos gráficos. A guia grau de confiança permite que o usuário indique qual a certeza dele na resposta. O grau de confiança é utilizado no cálculo final com base em Teoria dos Conjuntos.

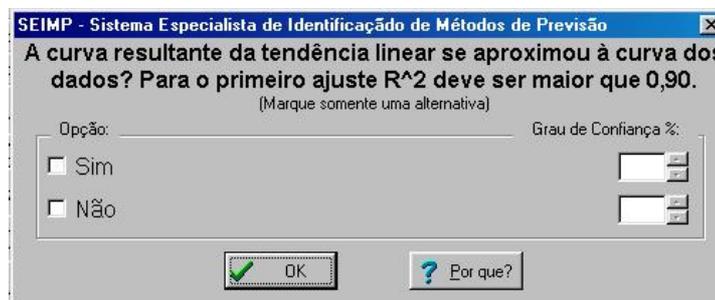


FIGURA 5.6 – Exemplo de pergunta do SEIMP.

- ✓ No botão “Por que?” é explicado ao usuário o motivo de tal pergunta, mostrando a importância daquele item para o raciocínio do sistema.

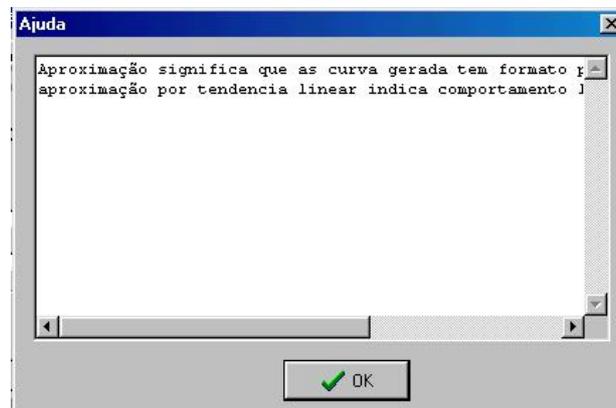


FIGURA 5.7 – Exemplo de explicação do SEIMP.

- ✓ Os métodos de previsão de demanda são indicados.

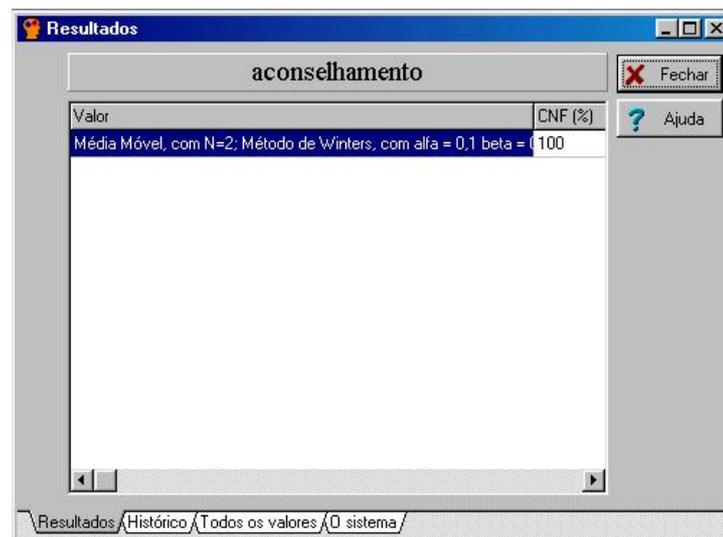


FIGURA 5.8 – Exemplo de aconselhamento do SEIMP.

- ✓ O sistema permite que o usuário verifique o caminho que o sistema percorreu para encontrar a resposta e ainda checar todas as respostas por ele dadas.

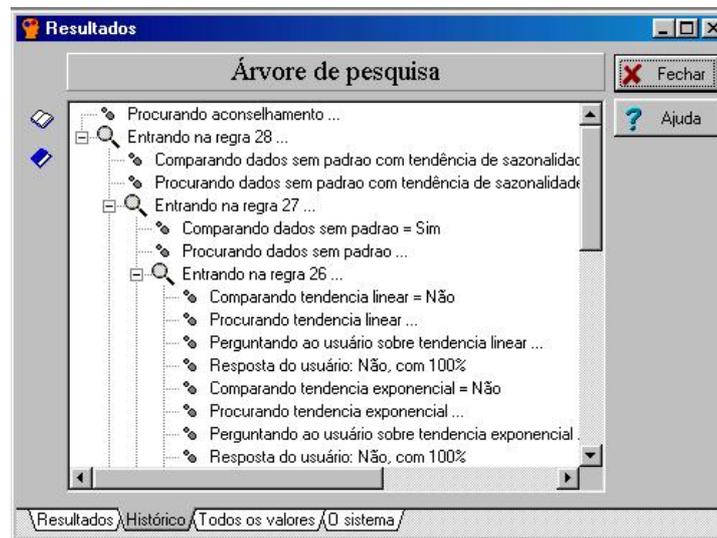


FIGURA 5.8 – Exemplo de árvore de pesquisa do SEIMP.

Este Sistema Especialista desenvolvido pode ser utilizado em qualquer segmento industrial, desde que aplicado a previsões de curto prazo. Métodos de Previsão de Demanda para médio e longo prazo são mais complexos, custosos e geralmente, quando desenvolvidos são específicos para um produto ou família de produtos, fatos que inviabilizam a implementação de mais de um método para posterior combinação de suas previsões.

5.3.1 Combinação das previsões quantitativas

As previsões obtidas pelos métodos quantitativos indicados devem ser combinadas para então serem ajustadas pelo segundo Sistema Especialista desenvolvido. SANDERS & RITZMAN (1989) afirmam que a combinação, das previsões obtidas por dois ou mais métodos de pesquisa operacional, aumentam a acurácia da previsão. Isto se deve pelo fato de que, geralmente, os dados apresentam mais de um comportamento. Por exemplo, um produto que apresente demanda sazonal pode estar em estágio de crescimento de seu ciclo de vida. Desta forma cada método pode, então, ser adequado a uma

determinada característica da demanda do produto. Desta forma, a combinação destes métodos pode enriquecer a previsão.

Segundo LACKMAN & BRANDON (1994), o método mais popular de seleção da melhor entre métodos de previsão de demanda é pela escolha daquele que produz o menor erro, o que resulta em perda de informações importantes, pois cada método captura características que são ignoradas pelos outros. Os métodos podem ser combinados por média aritmética, média ponderada ou por algum outro critério, como, por exemplo, pela análise do erro produzido. Alguns testes mostraram que a combinação por média ponderada obtém resultados melhores do que a média aritmética simples, porém o cálculo dos pesos foi feito por método de tentativa e erro, e à medida que aumenta o número de produtos a serem previstos, o tempo gasto com o método aumenta, inviabilizando sua utilização.

LACKMAN & BRANDON (1994) propõe um método de combinação de previsões no qual, ao método que produz menores erros, é dado maior peso em uma combinação de dois métodos. Os autores utilizam a combinação proposta por BRANDON et al. (1984), que descreve como computar os pesos para cada método. Os autores ainda afirmam que a fórmula de n combinações proposta por BRANDON et al. (1984) tem melhor desempenho ao combinar dois métodos e que as previsões terão maior erro à medida que mais do que dois métodos são combinados. Considerando que dois métodos de previsão serão combinados, chamando de modelo A um dos métodos e de B o outro, o método de combinação proposto por LACKMAN & BRANDON (1994) requer que os seguintes passos devem ser seguidos:

- ✓ Calcular o erro (diferença entre a previsão e as vendas) para cada método, considerando um número aleatório de previsões;
- ✓ A partir da soma dos erros, calcular o erro quadrado médio (MSE) para cada método segundo a fórmula:

$$MSE = \frac{1}{N} \times \sqrt{\sum_{t=1}^N \varepsilon_t^2} \quad (5-01)$$

onde ε^2 é o erro ao quadrado e N é o número de observações.

- ✓ Com base no MSE, calcular o desvio padrão (SD), a partir da seguinte fórmula:

$$SD = \frac{1}{N} \times \sqrt{\sum_{i=1}^N (\varepsilon^2 - MSE)^2} \quad (5-02)$$

onde ε^2 é o erro ao quadrado, MSE é o valor calculado no passo anterior e N é o número de observações.

- ✓ A partir do MSE e do SD calculados para os dois métodos a seguinte as fórmulas devem ser aplicadas para se determinar os pesos:

$$W_A = \frac{MSE_B \div SD_B}{(MSE_A \div SD_A) \div (MSE_B \div SD_B)} \quad (5-03)$$

$$W_B = 1 - W_A \quad (5-04)$$

onde MSE_A é o MSE calculado para o modelo A, MSE_B é o MSE calculado para o modelo B, SD_A é o SD calculado para o modelo A, SD_B é o SD calculado para o modelo B, W_A o peso calculado para o modelo A e W_B o peso para o modelo B.

- ✓ A previsão é então calculada da seguinte fórmula:

$$F_C = (F_A \times W_A) + (F_B \times W_B) \quad (5-05)$$

onde F_C é a previsão combinada, F_A a previsão calculada pelo modelo A, W_A o peso calculado para o modelo A, F_B a previsão calculada pelo modelo B e W_B o peso para o modelo B.

Quando mais de dois métodos foram indicados pelo sistema especialista, estes devem ser combinados dois a dois para produzir a previsão quantitativa final.

O processo de determinação dos pesos na combinação dos métodos de previsão de demanda pode ser contínuo, ou seja, a cada período novos valores de MSE e SD são calculados e, a partir destes novos valores, novos pesos são determinados para cada método.

Uma vez que os métodos de previsão de demanda não conseguem agregar todas as características do produto, e de seu mercado, para o qual está sendo desenvolvida a previsão, um ajuste da previsão obtida por métodos quantitativos para incorporar características qualitativas deve ser feito. Para tal finalidade um segundo Sistema Especialista foi desenvolvido.

5.4 SEAP – Sistema Especialista de Ajuste da Previsão

Existem alguns fatores internos e externos à empresa que podem afetar o comportamento da demanda. Campanhas publicitárias, campanhas de promoção de preço, incentivos dados ao pessoal de vendas tendem a aumentar as vendas. Existem alguns produtos de uma mesma empresa que concorrem ou vendas, ou que ainda, um aumento nas vendas de um, pode diminuir a procura por outro. Alguns eventos e inauguração de estabelecimentos comerciais podem alavancar as vendas, assim lançamentos de concorrentes e pouca aceitação dos consumidores podem diminuir a vendas. Além disso, alguns produtos apresentam diferentes comportamentos de venda durante. Essas variações podem estar associadas à temperatura ou datas comemorativas, por exemplo.

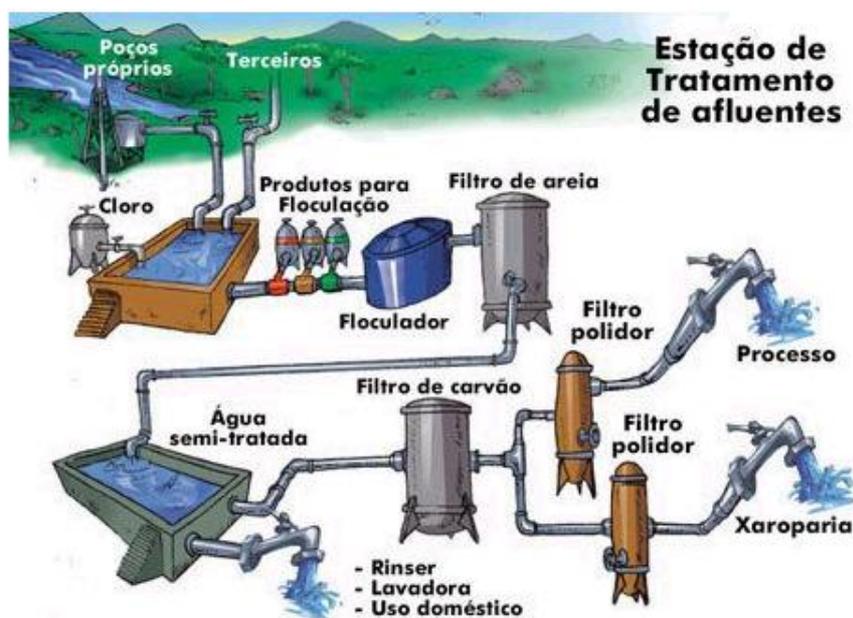
A maioria destes fatores é de difícil controle e previsão e dificilmente podem ser representados em um modelo quantitativo que utiliza equações matemáticas. Como foi descrito na seção 3.4.15, um método de previsão de demanda que consegue considerar estes e outros fatores é julgamento de especialista.

Um especialista em previsão de demanda conhece todos, ou quase todos, os métodos de previsão, suas características e aplicações. Além disso é capaz de desenvolver os métodos. Esta função foi executada pelo primeiro sistema especialista, juntamente com as planilhas desenvolvidas. Um profissional que trabalha com a previsão de demanda em uma empresa conhece as características dos produtos e de seu mercado e considera, mesmo inconscientemente, estes fatores quando calcula a previsão. É justamente este processo que a pesquisa pretende automatizar com o uso de sistemas especialistas. A base de conhecimento do segundo sistema especialista desenvolvido armazena informações sobre o mercado e os produtos para os quais a previsão está sendo realizada. Este conhecimento é específico de cada empresa, porém esta pesquisa propõe um método através do qual pode-se criar novas bases de conhecimento para outros tipos de produto.

5.4.1 Estudo de Caso

5.4.1.1 Caracterização da Empresa

O segundo sistema especialista é de ajuste de previsão de uma franquia de uma multinacional do segmento de refrigerantes, a Coca-Cola. Todas as informações foram obtidas em entrevistas com as profissionais responsáveis pela previsão de demanda e pelo PCP (Planejamento e Controle da Produção). A empresa produz refrigerantes, sucos, energético e engarrafa água purificada adicionada de sais. O processo de produção do refrigerante coca-cola está representado nas FIGURAS 5.9, 5.10, 5.11 e 5.12. Como a água é uma das bases do refrigerante, ela é inicialmente tratada para garantir determinados padrões de qualidade.



Fonte: <http://www.aquibemgelado.com.br>

FIGURA 5.9 – Tratamento da Água.

À água tratada é adicionado açúcar cristal para formar o xarope simples, que é a base dos refrigerantes, menos para os *lights* e *diets*. Ao xarope simples é adicionado um concentrado, que é fornecido pronto para a franquia e é o que determina o sabor do



refrigerante. Para alguns sabores, é possível que seja realizada ainda a adição de suco de frutas.

Fonte: <http://www.aquibemgelado.com.br>

FIGURA 5.10 – Fabricação do Xarope.

O próximo passo é a despaletização das embalagens. Depois de removido um filme plástico, cuja função é evitar contaminações, a despaletizadora envia os vasilhames para a esteira. Por meio de transporte aéreo as embalagens chegam ao *rinser*, onde são lavados com água clorada para garantir a descontaminação.



Fonte: <http://www.aquibemgelado.com.br>

FIGURA 5.11 – Despaletização.

Por um processo automatizado são enviados para a linha de produção o xarope, água e gás carbônico. Este elemento age como conservante. No proporcionador, a quantidade certa de cada componente é determinada e o refrigerante vai para o envase. A engarrafadora determina o volume certo a cada embalagem e a encapsuladora coloca a tampa plástica. Como o refrigerante é envasado gelado, as embalagens passam por um processo que baixa sua temperatura à ambiente bruscamente, evitando oxidações e perda de qualidade. As embalagens passam por uma inspeção eletrônica para retirar da linha produtos com problemas de qualidade.



Fonte: <http://www.aquibemgelado.com.br>

FIGURA 5.12 – Engarrafamento.

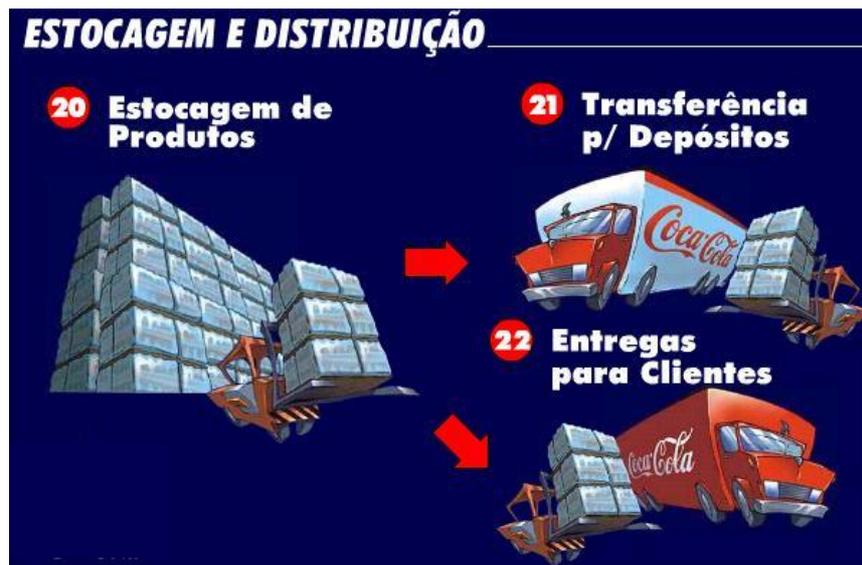
Os produtos são agrupados em 6 ou 12 unidades e recebem um plástico em alta temperatura que forma a embalagens. Os pacotes são acondicionados em *palets* e estes são envolvidos por um filme plástico para garantir maior firmeza durante o transporte e a estocagem.



Fonte: <http://www.aquibemgelado.com.br>

FIGURA 5.13 – Empacotamento.

Os produtos podem ser enviados para distribuidores, ou diretamente para os consumidores. A empresa possui uma frota própria de caminhões e toda a roteirização da distribuição é feita por um *software* chamado *Roadshow*. Os caminhões responsáveis pela



entrega aos consumidores finais possuem as portas nas laterais facilitando o acesso aos produtos e tornando mais rápidas as entregas.

Fonte: <http://www.aquibemgelado.com.br>

FIGURA 5.14– Distribuição.

5.4.1.2 Processo de Previsão de Vendas

A expectativa da venda anual é feita em conjunto com a matriz, que também relata sobre as campanhas promocionais nacionais. Estas podem ser campanhas publicitárias, promoções de preços e incentivos aos pontos de vendas. São informados os períodos e duração das campanhas, qual o objetivo, o público alvo e qual o papel da franquia. Além das campanhas promovidas pela matriz, a franquia pode realizar suas próprias campanhas, de abrangência regional, visto que as franquias não competem entre si. Com base nestas informações, a expectativa é então dividida nos meses do ano.

Além disso, a empresa conta com um sistema desenvolvido em planilha Excel, de um modelo de Box-Jenkins que fornece informações sobre a previsão de vendas. O sistema dá ao usuário a melhor previsão e retorna ainda dois valores mais otimistas que o valor ótimo e dois valores mais pessimistas. Estes valores mais otimistas e pessimistas são variações percentuais do valor ótimo.

Pelo estudo da expectativa de vendas, as características do produto e as condições do mercado, a profissional, responsável pela previsão de demanda, escolhe a previsão de vendas, fornecida pelo modelo, que mais se aproxima da expectativa de vendas e do conhecimento que ela tem sobre o produto.

A profissional, então compara a previsão com as vendas relativas ao mesmo período do ano anterior. As vendas tendem a ter comportamentos parecidos, nos mesmos períodos de anos diferentes. A previsão é então dividida em semanas e ajustada, levando em conta as campanhas da empresa, o comportamento do mercado, inaugurações de estabelecimentos comerciais e datas comemorativas. A previsão de demanda é então semanalmente passada para o profissional responsável pelo *scheduling*, que então analisa o estoque e programa a produção.

A empresa trabalha com estoque de segurança relativo a uma semana de vendas. A previsão de demanda é uma atividade importante para a empresa, uma vez que uma dos objetivos em relação à marca é a disponibilidade do produto (mínimo de falta possível). As linhas de produção não são dedicadas a um único produto, o que resulta na necessidade de *setup* entre a produção de diferentes produtos. Além disso, por se tratar de uma empresa do ramo alimentício, as linhas devem ser sanitizadas (limpas e conservadas) antes e depois da produção e a duração da sanitização está relacionada com os tipos de produtos. Por exemplo, a duração da troca de um refrigerante *light* para um “normal” é realizada na metade do tempo do que uma troca de um refrigerante “normal” para um *light* ou para um dietético. Outra restrição que ocorre é em relação a alguns sabores de produtos que deixam resíduos e resultam em um tempo de sanitização maior.

Se a previsão de um produto é mal calculada e se for verificado que o estoque não atenderá determinado pedido, a produção é interrompida para que sejam produzidas as unidades do produto que atenderão ao mercado e que serão repostas no estoque. A

necessidade de uma troca não programada representa realização de sanitizações não programadas, re-alocação de pessoal para a operação e perda de produção e perda de produção. Em uma linha que consegue produzir até 6000 latas/hora, a necessidade de um *setup* e sanitização não programados, que durem por exemplo 3 horas, representam 18000 unidades a menos produzidas no período, além do custo adicional envolvido com a operação.

Dessa forma, por seu valor estratégico em relação à marca e por seu impacto nos custos e volumes de produção, a função de previsão de demanda é de grande importância para empresa.

5.4.1.3 Aquisição do Conhecimento

O conhecimento foi adquirido através de entrevista com a profissional responsável pela previsão. Ela trabalha há muito tempo na função, e é reconhecida pela exatidão das previsões que realiza. A aquisição foi feita através de entrevista e observação realizada no ambiente de trabalho da especialista. A entrevista realizada não foi estruturada. Apenas alguns tópicos foram definidos previamente. Estes tópicos são:

- ✓ Como a previsão é realizada
- ✓ Como os produtos são agregados
- ✓ Quais métodos quantitativos são utilizados
- ✓ Como o conhecimento da especialista é agregado à previsão
- ✓ Qual o horizonte de planejamento da previsão
- ✓ Que decisões são baseadas na previsão
- ✓ Quais são as características e comportamento do mercado
- ✓ Que fatores influenciam a demanda

Durante a aquisição do conhecimento a maior dificuldade foi na explicitação dos processos mentais que a profissional realizava durante a elaboração da previsão, que muitas vezes eram automáticos e inconscientes. Depois da coleta das informações, estas foram categorizadas por produto e refinadas para representarem apenas um fator de influência na demanda. Depois deste tratamento dados às informações coletadas, procurou-

se por padrões ou características que permitissem um agrupamento de produtos, o que facilita o uso e o desenvolvimento das regras na construção do sistema.

Em virtude dos dados disponíveis e, segundo as características dos ajustes realizados, os produtos foram agrupados em quatro categorias: latas, *pet* 600ml, *pet* 2 ou mais litros e demais produtos. Na categoria latas, estão incluídos todos os refrigerantes e chás, em embalagens de 355ml. A categoria *pet* 600ml, representa os refrigerantes envasados neste tipo de embalagem. Os produtos da categoria *pet* 2 ou mais litros são os refrigerantes envasados em embalagens de 1,5 litros, 2 litros, 2,5 litros e 3 litros. Na categoria demais produtos estão incluídos os outros produtos produzidos pela empresa, como energético, água, sucos e refrigerantes em outras embalagens como retornáveis e vidros descartáveis.

Uma característica comum a todos os produtos, é que a informação sobre a previsão é comparada com o mesmo período do ano anterior e com a expectativa de vendas. Alguma campanha publicitária pode também influenciar as vendas, portanto regras para tratar estas informações são necessárias.

Outra informação relevante é sobre a divisão da previsão em semanas. Esta divisão é proporcional, sendo que as duas últimas semanas do mês são responsáveis pela maior parte das vendas. Outros fatores que influenciam a demanda são datas comemorativas e inaugurações ou grandes eventos realizados. Cada categoria de produto apresenta uma variação de demanda frente a esses fatores.

As campanhas de promoção de preço também afetam as vendas. Preços promocionais estimulam o mercado. Porém uma informação relevante é o fato que quando latas estão em promoção, a venda dos demais produtos caem. Promoções para latas e *pet* 600ml são mais significativas e o aumento das vendas destes produtos é maior em relação aos efeitos causados nas vendas durante promoções nos preços dos demais produtos. Além disso, em semanas imediatamente posteriores ao término de promoções, as vendas destes produtos caem, devido ao fato do mercado já estar bem abastecido.

5.4.2 Base de Conhecimento do SEAP

A partir das informações descritas na seção 5.4.1, as regras para a base de conhecimento do segundo sistema especialista foram construídas e estão apresentadas na seqüência.

Regra 1: verifica se o produto para o qual vai se calcular a previsão é lata

SE	produto = lata
ENTÃO	lata = sim previsão = valor

Regra 2: Aumenta a previsão em uma taxa passada pelo usuário

SE	lata = sim E comportamento = aumento
ENTÃO	Previsão = previsão + taxa

Regra 3: diminui a previsão em uma taxa informada pelo usuário

SE	lata = sim E comportamento = queda
ENTÃO	previsão = previsão - taxa

Regra 4: Mantém a previsão caso não haja necessidade de mudança

SE	lata = sim E comportamento = sem alteração
ENTÃO	previsão = previsão

Regra 5: transforma a previsão mensal em semanal – para a primeira semana

SE	lata = sim E semana = primeira
ENTÃO	previsão = 23% de previsão

Regra 6: transforma a previsão mensal em semanal – para a segunda semana

SE	lata = sim E semana = segunda
ENTÃO	previsão = 19% de previsão

Regra 7: transforma a previsão mensal em semanal – para a terceira semana

SE	lata = sim E semana = terceira
ENTÃO	previsão = 27% de previsão

Regra 8: transforma a previsão mensal em semanal – para a quarta semana

SE	lata = sim E semana = quarta
ENTÃO	previsão = 31% de previsão

Regra 9: ajusta a previsão quando há promoção

SE	lata = sim E promoção = sim
ENTÃO	previsão = previsão + 30%

Regra 10: ajusta a previsão quando a promoção acaba e então, o mercado já está abastecido

SE	lata = sim E promoção = saindo
ENTÃO	previsão = previsão - 10%

Regra 11: mantém a previsão se não há promoção

SE	lata = sim E promoção = não
ENTÃO	previsão = previsão

Regra 13: mantém a previsão, se o carnaval não está próximo

SE	lata = sim E carnaval = não
ENTÃO	previsão = previsão

Regra 15: mantém a demanda quando não há nenhum evento

SE	lata = sim E evento = não
ENTÃO	previsão = previsão

Regra 17: verifica se o produto para o qual vai se calcular a previsão é *pet* 600ml

SE	produto = <i>pet</i> 600ml
ENTÃO	<i>pet</i> 600 = sim previsão = valor

Regra 19: diminui a previsão em uma taxa informada pelo usuário

SE	<i>pet</i> 600 = sim E comportamento = queda
ENTÃO	previsão = previsão - taxa

Regra 21: transforma a previsão mensal em semanal - para a primeira semana

SE	<i>pet</i> 600 = sim E semana = primeira
ENTÃO	previsão = 23% de previsão

Regra 12: ajusta a previsão considerando que a demanda por lata aumenta na proximidade do carnaval

SE	lata = sim E carnaval = sim
ENTÃO	previsão = previsão + 70%

Regra 14: modifica a previsão quando o usuário informa algum evento que influencia a demanda

SE	lata = sim E evento = sim
ENTÃO	previsão = previsão + valor

Regra 16: retorna a previsão semanal ajustada para o usuário

SE	lata = sim E finalizar = sim
ENTÃO	previsão final = previsão

Regra 18: aumenta a previsão em uma taxa passada pelo usuário

SE	<i>pet</i> 600 = sim E comportamento = aumento
ENTÃO	previsão = previsão + taxa

Regra 20: mantém a previsão caso não haja necessidade de mudança

SE	<i>pet</i> 600 = sim E comportamento = sem alteração
ENTÃO	previsão = previsão

Regra 22: transforma a previsão mensal em semanal - para a segunda semana

SE	<i>pet</i> 600 = sim E semana = segunda
ENTÃO	previsão = 19% de previsão

Regra 23: transforma a previsão mensal em semanal – para a terceira semana

SE	<i>pet</i> 600 = sim E semana = terceira
ENTÃO	previsão = 27% de previsão

Regra 25: ajusta a previsão quando há aumento de preço

SE	<i>pet</i> 600 = sim E aumento = sim
ENTÃO	previsão = previsão - 15%

Regra 27: ajusta a previsão quando há promoção e lata não está em promoção

SE	<i>pet</i> 600 = sim E promoção = sem lata
ENTÃO	previsão = previsão + 23%

Regra 29: mantém a previsão se não há promoção

SE	<i>pet</i> 600 = sim E promoção = não
ENTÃO	previsão = previsão

Regra 31: ajusta a previsão considerando que a demanda por *pet* 600ml aumenta na proximidade do carnaval

SE	<i>pet</i> 600 = sim E carnaval = sim
ENTÃO	previsão = previsão + 20%

Regra 33: modifica a previsão quando o usuário informa algum evento que influencia a demanda

SE	<i>pet</i> 600 = sim E evento = sim
ENTÃO	previsão = previsão + valor

Regra 24: transforma a previsão mensal em semanal – para a quarta semana

SE	<i>pet</i> 600 = sim E semana = quarta
ENTÃO	previsão = 31% de previsão

Regra 26: mantém a previsão quando não há aumento de preço

SE	<i>pet</i> 600 = sim E aumento = não
ENTÃO	previsão = previsão

Regra 28: ajusta a previsão quando a promoção acaba e então, o mercado já está abastecido

SE	<i>pet</i> 600 = sim E promoção = saindo
ENTÃO	previsão = previsão - 15%

Regra 30: ajusta a previsão quando há promoção e lata está em promoção

SE	<i>pet</i> 600 = sim E promoção = com lata
ENTÃO	previsão = previsão + 13%

Regra 32: mantém a previsão, se o carnaval não está próximo

SE	<i>pet</i> 600 = sim E carnaval = não
ENTÃO	previsão = previsão

Regra 34: mantém a demanda quando não há nenhum evento

SE	<i>pet</i> 600 = sim E evento = não
ENTÃO	previsão = previsão

Regra 35: retorna a previsão semanal ajustada para o usuário

SE	<i>pet</i> 600 = sim E finalizar = sim
ENTÃO	previsão final = previsão

Regra 37: aumenta a previsão em uma taxa passada pelo usuário

SE	<i>pet</i> 2L = sim E comportamento = aumento
ENTÃO	previsão = previsão + taxa

Regra 39: mantém a previsão caso não haja necessidade de mudança

SE	<i>pet</i> 2L = sim E comportamento = sem alteração
ENTÃO	previsão = previsão

Regra 41: transforma a previsão mensal em semanal – para a segunda semana

SE	<i>pet</i> 2L = sim E semana = segunda
ENTÃO	previsão = 19% de previsão

Regra 43: transforma a previsão mensal em semanal – para a quarta semana

SE	<i>pet</i> 2L = sim E semana = quarta
ENTÃO	previsão = 31% de previsão

Regra 45: ajusta a previsão quando a promoção acaba e então, o mercado já está abastecido

SE	<i>pet</i> 2L = sim E promoção = saindo
ENTÃO	previsão = previsão – 5%

Regra 36: verifica se o produto para o qual vai se calcular a previsão é *pet* 2 litros

SE	produto = <i>pet</i> 2 litros
ENTÃO	<i>pet</i> 2L = sim E previsão = valor

Regra 38: diminui a previsão em uma taxa informada pelo usuário

SE	<i>pet</i> 2L = sim E comportamento = queda
ENTÃO	previsão = previsão – taxa

Regra 40: transforma a previsão mensal em semanal – para a primeira semana

SE	<i>pet</i> 2L = sim E semana = primeira
ENTÃO	previsão = 23% de previsão

Regra 42: transforma a previsão mensal em semanal – para a terceira semana

SE	<i>pet</i> 2L = sim E semana = terceira
ENTÃO	previsão = 27% de previsão

Regra 44: ajusta a previsão quando há promoção e lata não está em promoção

SE	<i>pet</i> 2L = sim E promoção = sem lata
ENTÃO	previsão = previsão + 15%

Regra 46: mantém a previsão se não há promoção

SE	<i>pet</i> 2L = sim E promoção = não
ENTÃO	previsão = previsão

Regra 47: ajusta a previsão quando há promoção e lata está em promoção

SE	$pet\ 2L = \text{sim E}$ promoção = com lata
ENTÃO	previsão = previsão + 7%

Regra 49: mantém a previsão, se as festas de fim de ano não estão próximas

SE	$pet\ 2L = \text{sim E}$ natal = não
ENTÃO	previsão = previsão

Regra 51: mantém a demanda quando não há nenhum evento

SE	$pet\ 2L = \text{sim E}$ evento = não
ENTÃO	previsão = previsão

Regra 53: verifica se o produto para o qual vai se calcular a previsão é para produtos que se encaixem na categoria demais produtos

SE	produto = demais produtos
ENTÃO	outros = sim previsão = valor

Regra 55: diminui a previsão em uma taxa informada pelo usuário

SE	outros = sim E comportamento = queda
ENTÃO	previsão = previsão - taxa

Regra 57: transforma a previsão mensal em semanal – para a primeira semana

SE	outros = sim E semana = primeira
ENTÃO	previsão = 23% de previsão

Regra 48: ajusta a previsão considerando que a demanda por *pet 2* litros aumenta na proximidade das festas de fim de ano

SE	$pet\ 2L = \text{sim E}$ natal = sim
ENTÃO	previsão = previsão + 20%

Regra 50: modifica a previsão quando o usuário informa algum evento que influencia a demanda

SE	$pet\ 2L = \text{sim E}$ evento = sim
ENTÃO	previsão = previsão + valor

Regra 52: retorna a previsão semanal ajustada para o usuário

SE	$pet\ 2L = \text{sim E}$ finalizar = sim
ENTÃO	previsão final = previsão

Regra 54: aumenta a previsão em uma taxa passada pelo usuário

SE	outros = sim E comportamento = aumento
ENTÃO	previsão = previsão + taxa

Regra 56: mantém a previsão caso não haja necessidade de mudança

SE	outros = sim E comportamento = sem alteração
ENTÃO	previsão = previsão

Regra 58: transforma a previsão mensal em semanal – para a segunda semana

SE	outros = sim E semana = segunda
ENTÃO	previsão = 19% de previsão

Regra 59: transforma a previsão mensal em semanal – para a terceira semana

SE	outros = sim E semana = terceira
ENTÃO	previsão = 27% de previsão

Regra 60: transforma a previsão mensal em semanal – para a quarta semana

SE	outros = sim E semana = quarta
ENTÃO	previsão = 31% de previsão

Regra 61: ajusta a previsão quando há promoção e lata não está em promoção

SE	outros = sim E promoção = sem lata
ENTÃO	previsão = previsão + 21%

Regra 62: ajusta a previsão quando a promoção acaba e então, o mercado já está abastecido

SE	outros = sim E promoção = saindo
ENTÃO	previsão = previsão - 8%

Regra 63: mantém a previsão se não há promoção

SE	outros = sim E promoção = não
ENTÃO	previsão = previsão

Regra 64: ajusta a previsão quando há promoção e lata está em promoção

SE	outros = sim E promoção = com lata
ENTÃO	previsão = previsão + 12%

Regra 65: modifica a previsão quando o usuário informa algum evento que influencia a demanda

SE	outros = sim E evento = sim
ENTÃO	previsão = previsão + valor

Regra 66: mantém a demanda quando não há nenhum evento

SE	outros = sim E evento = não
ENTÃO	previsão = previsão

Regra 67: retorna a previsão semanal ajustada para o usuário

SE	outros = sim E finalizar = sim
ENTÃO	previsão final = previsão

O encadeamento das regras está apresentado na FIGURA 5.15. As regras foram desenvolvidas e agrupadas respeitando o tipo de encadeamento que é implementado pelo *shell*. Ao se observar às regras relativas à divisão da previsão em semanas, que nesta base de conhecimento, está igual para todos os quatro grupos de produtos, poder-se-ia indicar que esta divisão fosse feita antes da identificação do produto. No entanto, na

situação real da previsão de demanda, as porcentagens das divisões em semanas variam de produto para produto, mas não se teve acesso a esta informação.

Da mesma forma as regras de alteração da previsão mensal inicial, que também, nesta base, é feita da mesma forma para os quatro grupos de produtos. Na situação real, de acordo com as características do produto, o aumento ou diminuição é checado para ver se o valor é viável. Por exemplo, propor o aumento inicial de 50% para coca-cola em lata é razoável, porém o mesmo aumento para fanta maçã em lata não é viável. Mais uma vez, não se teve acesso a esta informação para todos os produtos.

Regras que analisam a influência do aumento de preço estão presentes na cadeia que ajusta a previsão de refrigerante *pet* 600ml, pois somente para este produto a informação foi disponibilizada.

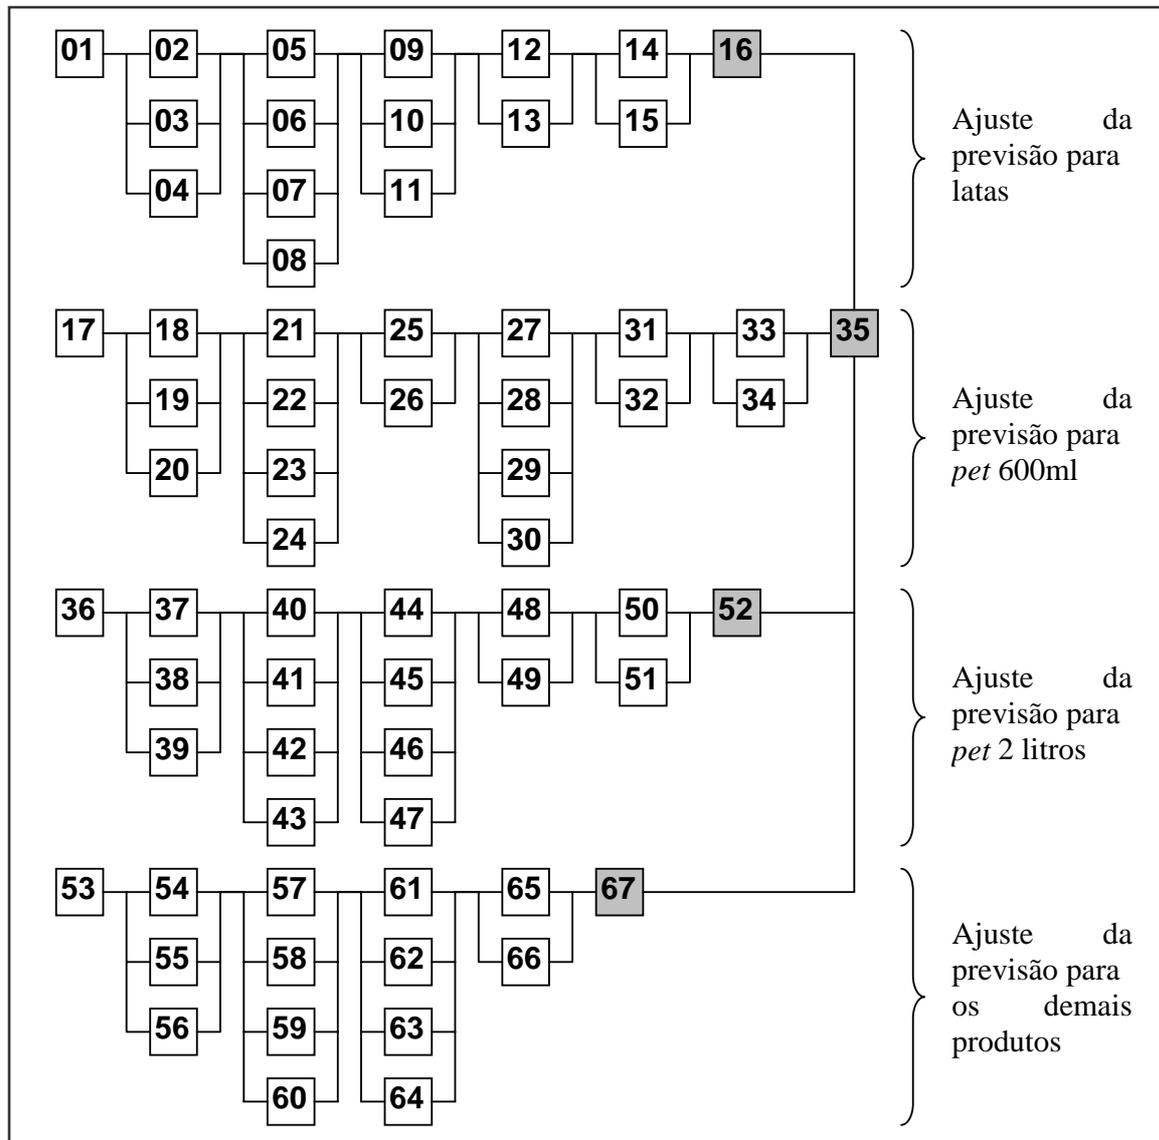


FIGURA 5.15 – Representação da Base de Conhecimento do SEAP.

As promoções de preço têm duração sempre em semanas, dessa forma as regras que representam o tratamento da influência das promoções na demanda estão localizadas depois da divisão da previsão em semanas.

Durante a aquisição de conhecimento, constatou-se que a verificação dos fatores que alteram a previsão ocorre na seguinte seqüência: avaliação de aumento de preço, existência de promoções de preço, algum feriado específico e por fim, eventos, como, a inauguração de supermercados que aumentam a demanda em um número de unidades conhecido previamente.

As regras que tratam eventos, apesar de terem a mesma estrutura para todos os grupos, em uma situação com maior disponibilização de dados para a construção do sistema apresentariam características diferentes, portanto optou-se por representar o tratamento da previsão para cada grupo, em separado. Além disso, devem ser o último fator de ajuste, por isso, estão localizadas imediatamente antes das regras que retornam a previsão ajustada ao usuário.

A interação do usuário com o SEAP para o ajuste da previsão ocorre da seguinte forma:

- ✓ Assim como o SEIMP, o SEAP exibe uma tela inicial que explica o objetivo do sistema.
- ✓ A interação do usuário com o sistema é feita por meio de perguntas de múltipla escolha.

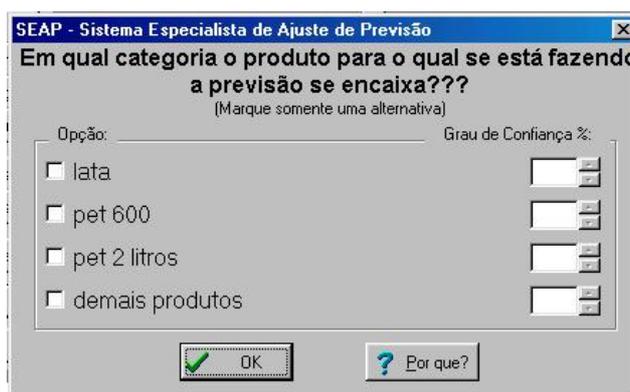


FIGURA 5.16 – Exemplo de pergunta de múltipla escolha do SEAP.

- ✓ O SEAP também oferece opção de explicar o motivo de cada pergunta.
- ✓ Em algumas vezes, é necessário que o usuário informe ao sistema algum valor, como o da previsão mensal inicial ou qual a taxa de modificação da previsão. Isto é feito por meio de um campo próprio.

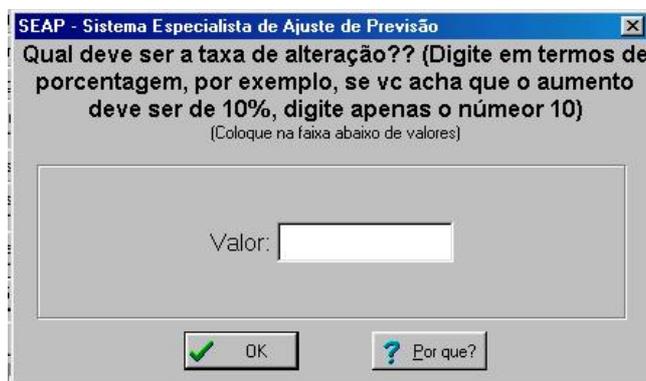


FIGURA 5.17 – Exemplo de pergunta de como o usuário informa um valor ao SEAP.

- ✓ Após ajustar a previsão o SEAP retorna a previsão semanal.

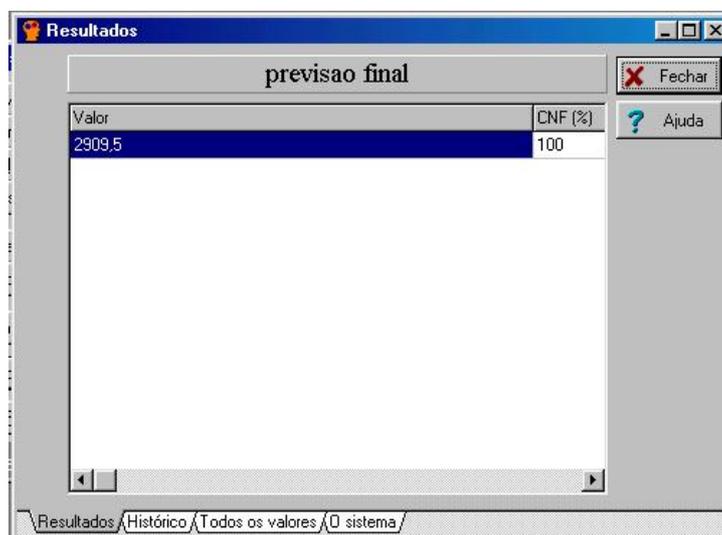


FIGURA 5.18 – Exemplo como o SEAP retorna a previsão semanal.

- ✓ Assim, como no SEIMP, neste sistema o usuário também pode consultar como o SEAP ajustou a previsão, bem como checar suas respostas às perguntas.

5.4.3 Método de Construção da Base de Conhecimento do SEAP

Para desenvolver a base de conhecimento o primeiro passo é uma pesquisa extensiva procurando identificar todos os fatores internos e externos à empresa que afetam a demanda. Depois de identificar estes aspectos, deve ser verificada a possibilidade de coleta de dados sobre estes fatores.

A seguir devem ser coletados dados sobre o sistema de previsão da empresa, como nível de detalhamento e horizonte de planejamento. As informações devem ser categorizadas e deve ser identificada a seqüência em que estes fatores afetam a demanda e sua relação com o processo de previsão de demanda.

O próximo passo é a identificação de como todas estas informações podem ser agrupadas, considerando os produtos ou famílias de produtos. A partir deste agrupamento, as regras devem ser desenvolvidas e encadeadas.

Uma atenção especial deve ser dada para o tipo de encadeamento das regras implementado pelo *shell* escolhido para o desenvolvimento do sistema. Em alguns casos existe uma relação de precedência entre os fatores que afetam a demanda, assim quando o encadeamento é para trás, o uso de variáveis garante que determinadas regras percorridas antes de outras. O processo de construção das regras está sumarizado abaixo:

- ✓ Identificar os fatores internos à empresa que afetam a demanda, como promoções e incentivos à equipe de vendas.
- ✓ Identificar os fatores internos à empresa, como fenômenos climáticos e econômicos, ações de concorrentes, proximidade a datas comemorativas.
- ✓ Coletar e categorizar informações sobre estes fatores e sobre o processo de previsão que empresa utiliza.
- ✓ Agrupar as informações, identificando a seqüência em que os fatores afetam o processo de previsão. Sugere-se que as informações sejam agrupadas segundo produtos ou famílias de produtos.
- ✓ Construção das regras.

5.5 Considerações finais

Os protótipos desenvolvidos foram testados com informações coletadas na empresa na qual se realizou o estudo de caso. Durante sua realização, preocupou-se em simular o ambiente na qual a decisão sobre a previsão de demanda seria tomada e utilizada. Os testes estão apresentados no capítulo 6.

6 TESTES E AVALIAÇÃO DOS RESULTADOS

6.1 Considerações

Foram coletados dados sobre as vendas em 22 meses, de quatro produtos, com diferentes embalagens. Os testes foram realizados em separado para cada um dos produtos. Para estes testes assumiu-se que a demanda real é maior do que as vendas registradas, por este motivo, as vendas estão relacionadas com a disponibilidade dos produtos. Assim, quando é registrada alguma parada em alguma linha de produção, assume-se que as vendas caem e a previsão deve ser reduzida proporcionalmente ao número de dias que durou a parada. Por exemplo, quando há necessidade de quatro dias para manutenção da linha de produção, a previsão calculada para esta semana é então reduzida à metade. Para estes testes considera-se então que demanda e vendas são a mesma coisa.

Dos 22 dados disponíveis para cada produto, 12 são utilizados como observações históricas da demanda e utilizados para gerar as previsões quantitativas. Os 10 dados restantes são utilizados para avaliação das previsões geradas pelo sistema desenvolvido.

O horizonte dos dados sobre as vendas é mensal. No entanto, as informações sobre promoções de preço e outros fatores que possam afetar a demanda são semanais, assim como o processo de previsão da empresa. Para os testes, inicialmente é gerada uma previsão mensal. Esta previsão é então ajustada, pelo segundo sistema especialista, e “aberta” em semanas. As previsões geradas para as quatro semanas são então, agrupadas, e é obtida uma nova previsão mensal.

Tanto a previsão inicial, gerada a partir de métodos quantitativos, quanto a previsão final, ajustada por um método qualitativo, são comparadas com a venda real no período. Três tipos de erro são calculados e são construídos gráficos para melhor visualização do comportamento das previsões.

Dessa forma, as etapas realizadas nos testes foram:

- ✓ Os 12 primeiros dados sobre as vendas de um produto são plotados em um gráfico.

- ✓ As curvas de tendência são adicionadas e os respectivos valores de r-quadrado são registrados.
- ✓ O usuário então interage com o SEIMP, respondendo perguntas sobre o ajuste à curva de dados.
- ✓ Os métodos de previsão aconselhados são implementados e as previsões combinadas pelo método de LACKMAN & BRANDON (1994).
- ✓ A previsão resultante é então ajustada pelo SEAP, a partir da interação do sistema com o usuário.
- ✓ Os resultados são comparados com as vendas reais e com a previsão que a empresa havia feito. Os erros são calculados e é feita uma análise sobre o desempenho dos sistemas.

6.2 Refrigerante lata: coca-cola 350ml

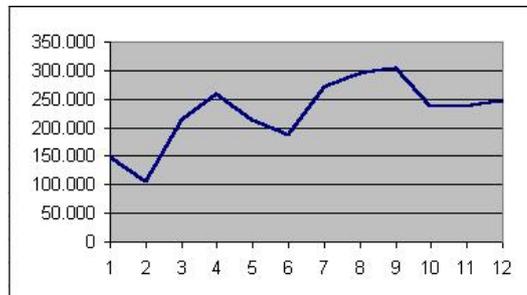
As vendas registradas um refrigerante em lata no ano de 2002 estão apresentadas na TABELA 6.1.

TABELA 6.1 – Vendas de um tipo de refrigerante em lata no ano de 2002.

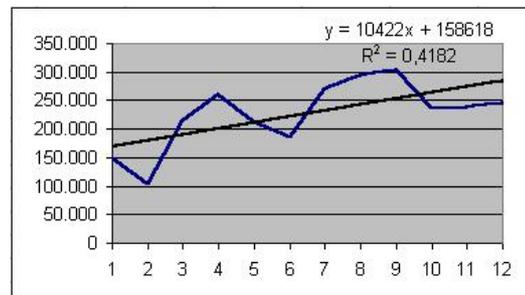
Mês	Vendas
Janeiro	149.275
Fevereiro	104.418
Março	214.159
Abril	259.845
Maio	212.634
Junho	185.905
Julho	270.739
Agosto	294.537
Setembro	303.560
Outubro	236.309
Novembro	238.131
Dezembro	246.834

Estes dados foram colocados em uma planilha do Excel e o processo de previsão foi iniciado. Foram construídos gráficos e as linhas de tendência foram adicionadas. Os gráficos resultantes são:

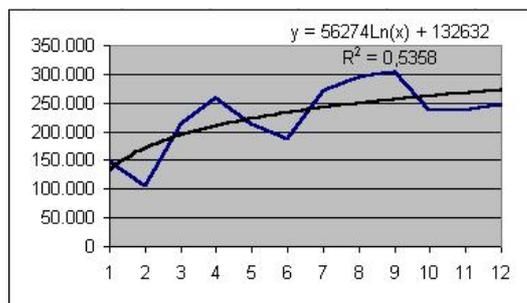
Vendas no ano de 2002



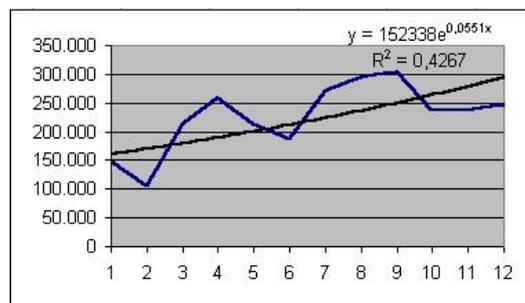
Linha de tendência linear



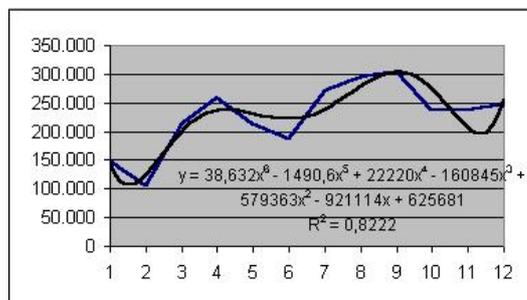
Linha de tendência logarítmica



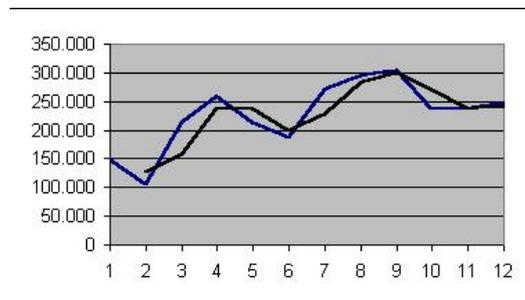
Linha de tendência exponencial



Linha de tendência polinomial com ordem 6



Linha de tendência por média móvel



O SEIMP foi utilizado para que os métodos de previsão de demanda mais aconselhados para o comportamento dos dados acima representados fossem indicados. A linha de tendência que melhor se aproximou foi a de média móvel e para uma segunda aproximação a linha que apresentou menor R-quadrado foi a de tendência polinomial. Os métodos de previsão indicados foram:

- ✓ Média Móvel
- ✓ Método de Winters

As previsões foram calculadas para os dois métodos e então combinadas pelo método proposto por LACKMAN & BRANDON (1994). Os resultados estão apresentados na tabela abaixo:

TABELA 6.2 – Cálculo das previsões quantitativas para refrigerante em lata.

Mês	Previsão calculada por Média Móvel	Previsão calculada pelo método de Winters	Previsão Resultante
Janeiro	240.424,67	242.636	242.414
Fevereiro	241.534,00	274.570	271.266
Março	276.479,00	288.491	287.290
Abril	299.411,33	292.130	292.858
Maio	285.033,67	287.999	287.702
Junho	236.552,33	286.937	281.899
Julho	196.802,00	277.123	269.091
Agosto	186.130,33	263.006	255.318
Setembro	288.625,33	276.452	277.669
Outubro	298.873,33	272.063	274.744

Para que o ajuste da previsão fosse realizado com uso do segundo sistema especialista, fatores que pudessem ter influenciado a demanda em 2002 e 2003 foram identificados. As informações disponibilizadas foram:

- Janeiro de 2002: promoção de preço nas duas últimas semanas do mês.
- Fevereiro de 2002: promoção de preço na última semana do mês.
- Abril de 2002: promoções realizadas na primeira e última semana do mês e linha parada por 3 dias para manutenção na terceira semana.
- Março de 2003: promoção nas duas últimas semanas do mês.
- Abril de 2003: linha parada durante 4 dias na terceira semana e promoção de preço na última semana.
- Maio de 2003: promoção de preço na terceira semana.
- Julho de 2003: linha parada por quatro dias na última semana.
- Agosto de 2003: promoção de preço nas últimas duas semanas do mês.
- Setembro de 2003: promoção de preço na terceira semana.

Considerando estas informações e o fato da demanda ter alta variabilidade e apresentar sazonalidade, a análise dos dados históricos, permitiu concluir que:

- Apesar de janeiro e fevereiro apresentarem baixas vendas, a alta demanda de janeiro em 2002 pode ser explicada pelas promoções realizadas o que deixou o mercado abastecido para fevereiro, que apresentou demanda mais baixa que o normal. Deve-se considerar um aumento das vendas na última semana do mês de fevereiro pelo fato do carnaval ocorrer no início de março.
- O aumento da demanda em março de 2002 deve ser levado em conta na previsão para 2003, aumentando-a em 10%.
- As altas vendas em abril de 2002 são justificadas pelas promoções. Tal fato também explica as vendas mais baixas no mês seguinte.
- Junho de 2002 apresentou uma queda em relação a maio, desta forma a previsão para junho de 2003 pode ser reduzida em 10%.
- Julho, agosto de 2002 apresentar oscilações que podem ser consideradas normais.
- As quedas de venda em outubro de 2002 devem ser consideradas, assim a previsão para 2003 pode ser reduzida em 10%.

Com base em todas estas informações, o segundo sistema especialista foi então utilizado para ajustar as previsões quantitativas. Os resultados estão apresentados na TABELA 6.3.

TABELA 6.3 – Previsões ajustadas pelo SEAP para refrigerante em lata.

Mês	Previsão	Mês	Previsão
Janeiro	55.755	Junho	58.353
	46.059		48.205
	65.452		68.501
	75.148		78.650
Total	242.414	Total	253.709
Fevereiro	62.391	Julho	61.891
	51.541		51.127
	73.242		72.655
	142.957		41.709
Total	330.131	Total	227.382
Março	72.684	Agosto	58.723
	60.044		48.510
	85.325		82.723
	97.966		94.978
Total	316.019	Total	284.935
Abril	67.357	Setembro	57.478
	55.643		47.481
	39.536		89.965
	108.943		77.470
Total	271.479	Total	272.394
Maio	59.554	Outubro	56.872
	54.663		46.981
	93.215		66.763
	80.269		76.654
Total	287.702	Total	247.270

Para facilitar a comparação entre as previsões, elas estão reunidas na TABELA 6.4.

TABELA 6.4 – Previsões para refrigerante em lata.

Mês	Previsão Empresa	Previsão Quantitativa	Previsão Ajustada	Vendas
Janeiro	363.555	242.414	242.414	239.637
Fevereiro	296.299	271.266	330.131	342.966
Março	328.113	287.290	316.019	315.631
Abril	215.874	292.858	271.479	196.504
Maio	208.807	287.702	287.702	197.522
Junho	212.097	281.899	253.709	196.380
Julho	164.730	269.091	227.382	164.489
Agosto	540.534	255.318	284.935	505.007
Setembro	239.058	277.669	272.394	227.124
Outubro	240.230	274.744	247.270	257.314

Pode ser observado que em relação à previsão obtida pela combinação de métodos quantitativos, a previsão ajustada só obteve pior desempenho em 1 mês e empatou

em outros 2, resultando em valores melhores para 7 meses, se mostrando dessa forma, mais eficiente para a previsão deste produto. Porém, em relação à previsão gerada pela empresa, a previsão ajustada obteve melhores resultados em 4 meses, acredita-se que este desempenho deve a dois motivos:

- ✓ a especialista da empresa dispunha de pouco tempo livre, o que limitou a aquisição de conhecimento e não permitiu que se abrangesse todo o seu conhecimento causal.
- ✓ a empresa disponibilizou poucas informações relativas à previsão de demanda e comportamento dos produtos e mercados.

Levando em conta estas limitações, o desempenho do ajuste pode ser considerado satisfatório em relação ao processo de previsão utilizado pela empresa e, de desempenho superior em relação à previsão quantitativa. No gráfico mostrado na FIGURA 6.1, pode ser observado que a curva formada pela previsão ajustada acompanha melhor as variações da curva de vendas.

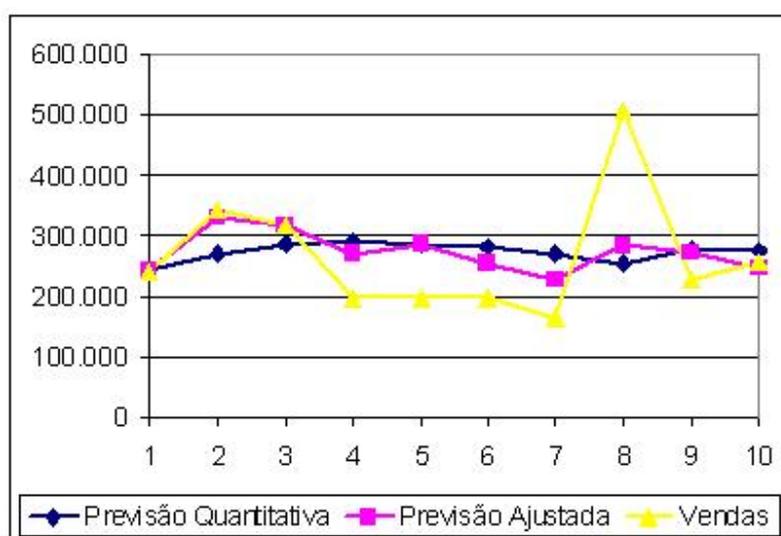


FIGURA 6.1 – Gráfico de comparação entre as previsões e a venda de refrigerante em lata.

Na TABELA 6.5 estão apresentados os cálculos de erro mensal e três métodos de análise de erro: erro médio (AE), desvio absoluto da média (MAD) e erro percentual absoluto médio (MAPE). O melhor desempenho da previsão ajustada pode ser

comprovado pelos resultados dos três métodos. A previsão quantitativa obteve um MAPE de 31%, enquanto que o MAPE da previsão ajustada é 22%, o que permite concluir que as previsões ajustadas geram, em média, erros 41% menores do que a previsão obtida por métodos quantitativos.

TABELA 6.5 – Comparação dos erros das previsões para refrigerante em lata.

Mês	Erro Absoluto		Erro Percentual	
	Previsão Quantitativa	Previsão Ajustada	Previsão Quantitativa	Previsão Ajustada
Janeiro	2.777	2.777	1	1
Fevereiro	-71.700	12.835	-21	-4
Março	-28.341	388	-9	0
Abril	96.354	74.975	49	38
Maio	90.180	90.180	46	46
Junho	85.519	57.329	44	29
Julho	104.602	62.893	64	38
Agosto	-249.689	-220.072	-49	-44
Setembro	50.545	45.270	22	20
Outubro	17.430	-10.044	7	-4
AE	9.767	9.086		
MAD	79.714	57.676		
MAPE			31	22

6.3 Refrigerante em embalagem *pet* de 600ml: coca-cola light

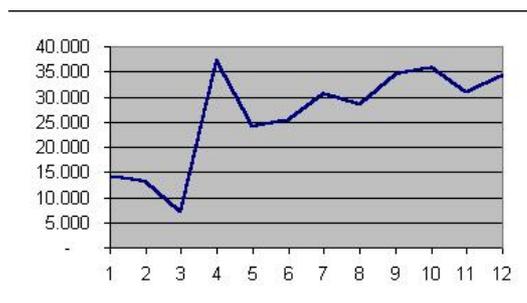
As vendas registradas para este produto no ano de 2002 estão apresentadas na TABELA 6.6.

TABELA 6.6 – Vendas de refrigerante *pet* 600ml em 2002.

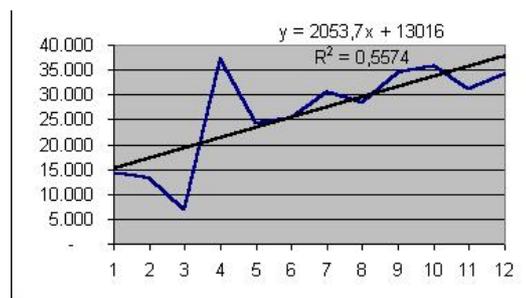
Mês	Vendas
Janeiro	14.329
Fevereiro	13.170
Março	7.005
Abril	37.201
Maio	24.236
Junho	25.486
Julho	30.702
Agosto	28.460
Setembro	34.607
Outubro	35.812
Novembro	31.076
Dezembro	34.295

Estes dados foram colocados em uma planilha do Excel e o processo de previsão foi iniciado. Foram construídos gráficos e as linhas de tendência foram adicionadas. Os gráficos resultantes são:

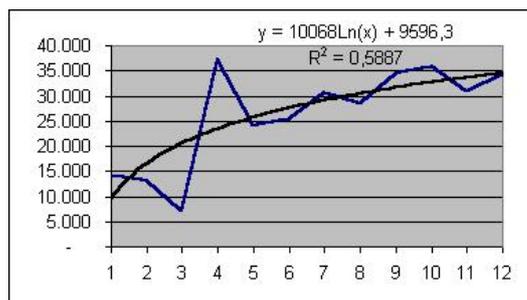
Vendas no ano de 2002



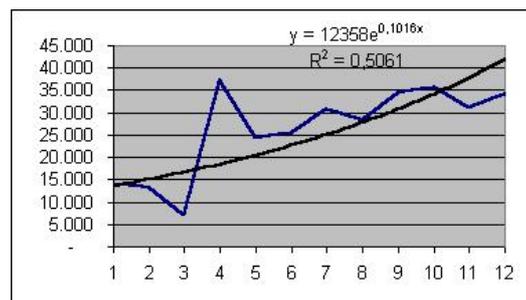
Linha de tendência linear



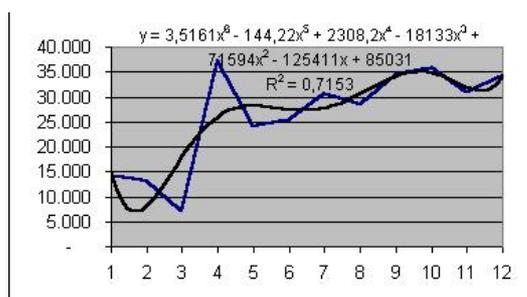
Linha de tendência logarítmica



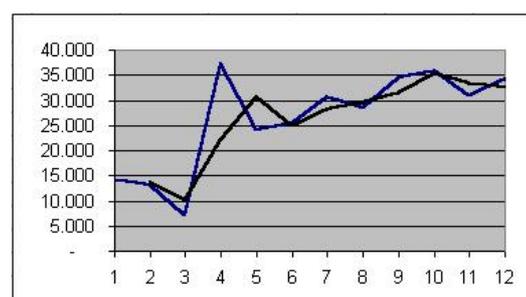
Linha de tendência exponencial



Linha de tendência polinomial com ordem 6



Linha de tendência por média móvel



Como para o outro produto, o primeiro sistema especialista foi utilizado para que os métodos de previsão de demanda fossem indicados. Também como para o outro produto, a linha de tendência que melhor se aproximou foi a de média móvel e para uma

segunda aproximação a linha que apresentou menor R-quadrado foi a de tendência polinomial. Os métodos de previsão indicados foram:

- ✓ Média Móvel
- ✓ Método de Winters

As previsões calculadas pelos dois métodos foram combinadas pelo método proposto por LACKMAN & BRANDON (1994). Os resultados estão apresentados na tabela abaixo:

TABELA 6.7 – Cálculo das previsões quantitativas para refrigerante *pet* 600ml.

Mês	Previsão calculada por Média Móvel	Previsão calculada pelo Método de Winters	Previsão Resultante
Janeiro	33.728	30.406	30.408
Fevereiro	31.259	33.684	32.872
Março	31.746	44.081	41.480
Abril	33.017	43.723	41.439
Maio	33.088	43.687	41.526
Junho	49.813	49.517	48.069
Julho	58.398	51.744	50.884
Agosto	74.319	55.531	55.713
Setembro	56.491	53.757	52.633
Outubro	50.213	53.043	51.548

As informações disponibilizadas permitiram que os seguintes fatores que pudessem influenciar a demanda fossem identificados:

- Março de 2002: linha parada na primeira semana do mês.
- Março de 2003: aumento de preço na última semana do mês.
- Abril de 2003: promoção de preço na terceira semana.
- Maio de 2003: promoção de preço na última semana.

Considerando estas informações e o fato da demanda ter alta variabilidade e apresentar sazonalidade, a análise dos dados históricos, permitiu concluir que:

- Os meses de janeiro e fevereiro apresentam baixas vendas, mas como há uma tendência de crescimento da demanda, pode ser considerada uma diminuição de apenas 5% para as previsões. Além disso, na última semana de fevereiro deve ser considerado o aumento na demanda, devido ao carnaval que ocorre no início de março.

- A parada na linha justifica, em parte, a queda nas vendas em março de 2002. Porém a diminuição não será levada em conta na previsão pois o consumo nas primeiras semanas de março de 2003 tende a ser alto devido ao aumento que ocorre na última semana do mês.
- O aumento de preço na última semana de março de 2003 acarreta uma queda nas vendas do mês de abril. Pode-se considerar queda em torno de 20%.
- Junho de 2002 apresentou um ligeiro aumento em relação às vendas de maio do mesmo ano, desta forma a previsão para junho de 2003 pode ser aumentada em 5%.
- Julho de 2002 apresenta alta, em relação a junho do mesmo ano. Esta alta pode ser refletida na previsão de julho de 2003 por meio de um aumento de 10%. Já a queda da demanda de agosto de 2002 pode ser refletida com uma diminuição de 10% na previsão para 2003.
- Setembro e outubro apresentaram oscilações consideradas normais, pois se trata de um refrigerante com baixo valor calórico, cujo consumo aumenta com a proximidade do verão.

Com base em todas estas informações, o segundo sistema especialista foi então utilizado para ajustar as previsões quantitativas. Os resultados estão apresentados na TABELA 6.8.

TABELA 6.8 – Previsões ajustadas pelo SEAP para refrigerante *pet* 600ml.

Mês	Previsão	Mês	Previsão
Janeiro	6.644	Junho	9.868
	5.489		9.590
	7.800		13.627
	8.955		15.646
Total	28.887	Total	48.732
Fevereiro	7.183	Julho	12.874
	5.933		10.635
	8.432		15.113
	11.132		32.352
Total	32.680	Total	70.973
Março	9.540	Agosto	11.533
	7.881		9.527
	11.200		13.538
	10.929		15.544
Total	39.550	Total	50.142
Abril	7.625	Setembro	12.106
	6.299		10.000
	10.114		14.211
	8.735		16.316
Total	32.772	Total	52.633
Maio	9.551	Outubro	11.856
	7.890		9.794
	11.212		13.918
	14.547		15.980
Total	43.200	Total	51.548

Para facilitar a comparação, as previsões obtidas pela combinação métodos quantitativos e pelo ajuste, além das vendas e da previsão utilizada pela empresa no mesmo período estão apresentados na TABELA 6.9.

TABELA 6.9 – Previsões para refrigerante *pet* 600ml.

Mês	Previsão da Empresa	Previsão Quantitativa	Previsão Ajustada	Vendas
Janeiro	31.275	30.408	30.408	28.405
Fevereiro	28.712	32.872	32.680	32.538
Março	38.133	41.480	39.550	38.109
Abril	29.502	41.439	32.772	28.617
Maio	85.873	41.526	43.200	82.713
Junho	69.005	48.069	48.732	63.864
Julho	72.408	50.884	70.973	76.380
Agosto	30.993	55.713	44.570	29.230
Setembro	37.320	52.633	52.633	45.028
Outubro	38.200	51.548	48.971	38.070

Em relação à previsão quantitativa, a previsão ajustada gerou melhores previsões em 8 meses e empatou em 2, apresentando um desempenho ligeiramente melhor do que para refrigerante em lata. Porém, em relação às previsões utilizadas pela empresa, o método de ajuste obteve apenas 3 resultados melhores. Os motivos que justificam este desempenho estão apresentados na seção 6.3. A FIGURA 6.2 apresenta um gráfico que permite uma melhor visualização do comportamento das previsões quantitativas e ajustadas, em relação às vendas.

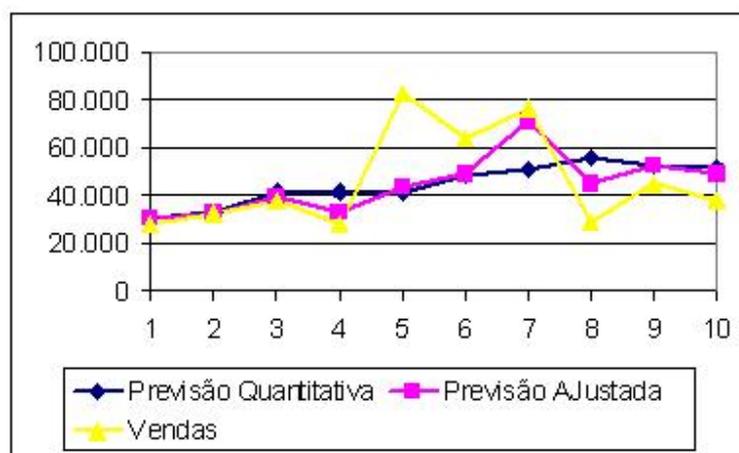


FIGURA 6.2 – Gráfico de comparação entre as previsões e a venda de refrigerante *pet* 600ml.

Na TABELA 6.10 os métodos de análise de erro, AE, MAD e MAPE estão calculados, bem como os erros mês a mês. Pela análise do MAPE pode ser observado que, em média, a previsão ajustada gera previsões 55% melhores do que a combinação dos métodos quantitativos.

TABELA 6.10 – Comparação dos erros das previsões para refrigerante *pet* 600ml.

Mês	Erro Absoluto		Erro Percentual	
	Previsão Quantitativa	Previsão Ajustada	Previsão Quantitativa	Previsão Ajustada
Janeiro	2.003	2.003	7	7
Fevereiro	334	142	1	0
Março	3.371	1.441	9	4
Abril	12.822	4.155	45	15
Maio	-41.187	-39.513	-50	-48
Junho	-15.795	-15.132	-25	-24
Julho	-25.496	-5.407	-33	-7
Agosto	26.483	15.340	91	52
Setembro	7.605	7.605	17	17
Outubro	13.478	10.901	35	29
AE	-1.638	-1.846		
MAD	14.857	10.164		
MAPE			31	20

6.4 Refrigerante em embalagem *pet* de 2000ml: coca-cola

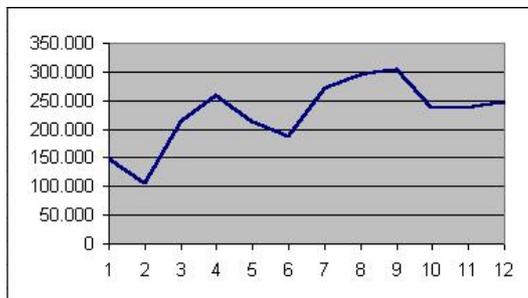
As vendas registradas para este produto no ano de 2002 estão apresentadas na TABELA 6.11.

TABELA 6.11 – VENDAS PARA REFRIGERANTE *PET* 2 LITROS EM 2002.

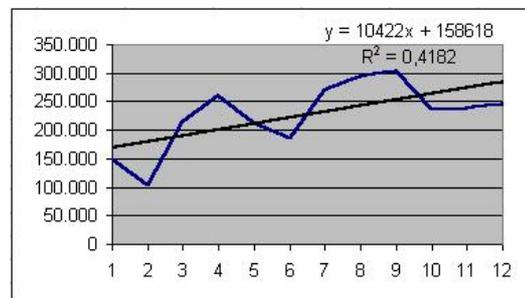
Mês	Vendas
Janeiro	357.522
Fevereiro	367.345
Março	408.582
Abril	533.144
Maio	374.712
Junho	512.327
Julho	476.198
Agosto	529.250
Setembro	671.073
Outubro	604.478
Novembro	659.927
Dezembro	684.383

Estes dados foram colocados em uma planilha do Excel e o processo de previsão foi iniciado. Foram construídos gráficos e as linhas de tendência foram adicionadas. Os gráficos resultantes são:

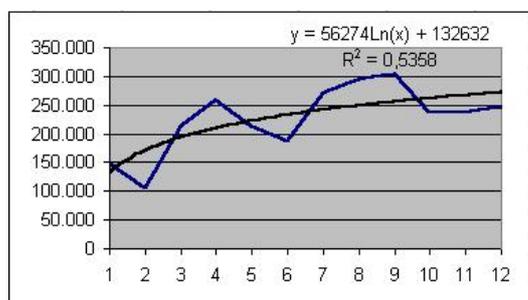
Vendas no ano de 2002



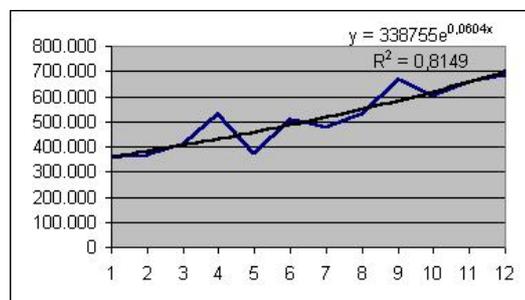
Linha de tendência linear



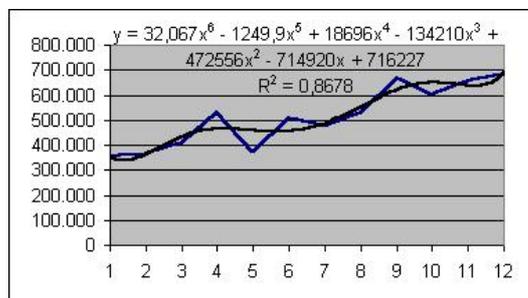
Linha de tendência logarítmica



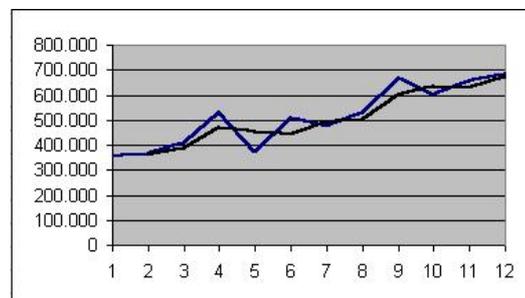
Linha de tendência exponencial



Linha de tendência polinomial com ordem 6



Linha de tendência por média móvel



Mais uma vez, o primeiro sistema especialista foi utilizado para que os métodos de previsão de demanda fossem indicados. Da mesma forma, a linha de tendência que melhor se aproximou foi a de média móvel e para uma segunda aproximação a linha que apresentou menor R^2 foi a de tendência polinomial. Os métodos de previsão indicados foram:

- ✓ Média Móvel
- ✓ Método de Winters

As previsões calculadas pelos dois métodos foram combinadas pelo método proposto por LACKMAN & BRANDON (1994). Os resultados estão apresentados na tabela abaixo:

TABELA 6.12 – Cálculo das previsões quantitativas para refrigerante *pet* 2 litros.

Mês	Previsão calculada por Média Móvel	Previsão calculada pelo Método de Winters	Previsão Resultante
Janeiro	649.596	566.695	641.306
Fevereiro	627.200	591.910	623.671
Março	615.151	619.844	615.621
Abril	627.771	636.905	628.684
Maio	614.275	651.231	617.971
Junho	564.276	641.724	572.021
Julho	497.535	641.222	511.904
Agosto	490.794	628.917	504.607
Setembro	520.354	612.659	529.584
Outubro	577.526	613.728	581.146

As informações disponibilizadas permitiram que os seguintes fatores que pudessem influenciar a demanda fossem identificados:

- Abril de 2002: promoção de preço nas três últimas semanas do mês.
- Junho de 2002: promoção de preço durante todo o mês.
- Dezembro de 2002: campanha promocional do natal.
- Abril de 2003: promoção de preço na última semana e linha parada para manutenção na terceira semana do mês.

Considerando estas informações e o fato da demanda ter alta variabilidade e apresentar sazonalidade, a análise dos dados históricos, permitiu concluir que:

- As vendas estão apresentando uma ligeira tendência de crescimento, contudo para janeiro espera-se uma queda na demanda, em torno de 10% para janeiro de 2003, pelo fato do mercado já estar abastecido considerando a campanha de natal de dezembro de 2002. Para fevereiro, no entanto, esta queda não é esperada.
- Para março de 2003 espera-se um aumento de 15%.
- As altas vendas em abril de 2002 são resultado das semanas de promoção, por isso, a previsão para 2003 não vai ser alterada.

- Maio de 2002 apresentou uma grande queda, desta forma a previsão para maio de 2003 deve ser diminuída em 15%.
- Como abril e maio de 2003 estão apresentando baixas vendas, a previsão para o mês de junho de 2003 deve ser diminuída em 5%. Para julho de 2003, espera-se o mesmo comportamento, portanto a previsão também deve ser diminuída na mesma proporção.
- OS meses de agosto e setembro de 2002 apresentaram aumento nas vendas. Tal fato será considerado nas previsões para estes meses em 2003 por meio de um aumento de 10 e 20%, respectivamente.
- Em outubro de 2003 as vendas tiveram uma ligeira queda, ocasionando uma diminuição de 5% na previsão para 2003.

Em seguida, o segundo sistema especialista foi então utilizado para ajustar as previsões quantitativas. Os resultados estão apresentados na TABELA 6.13.

TABELA 6.13 – Previsões ajustadas pelo SEAP para refrigerante *pet* 2 litros.

Mês	Previsão	Mês	Previsão
Janeiro	132.750	Junho	124.987
	109.663		103.250
	155.837		146.723
	178.924		168.460
Total	577.175	Total	543.420
Fevereiro	143.444	Julho	111.851
	118.497		92.399
	168.391		131.303
	193.338		150.756
Total	623.671	Total	486.309
Março	162.832	Agosto	127.665
	134.513		105.463
	191.150		149.868
	219.469		172.071
Total	707.964	Total	555.067
Abril	144.597	Setembro	146.165
	119.450		120.745
	76.385		171.585
	187.681		197.005
Total	528.113	Total	635.501
Maio	114.772	Outubro	126.980
	101.083		104.897
	143.644		149.064
	164.925		171.148
Total	524.425	Total	552.089

A TABELA 6.14 apresenta todas as previsões quantitativas, ajustas e utilizadas pela empresa para o período de janeiro a outubro de 2003.

TABELA 6.14 – Previsões para refrigerante *pet* 2 litros.

Mês	Previsão da Empresa	Previsão Quantitativa	Previsão Ajustada	Vendas
Janeiro	419.204	641.306	577.175	537.290
Fevereiro	606.715	623.671	623.671	623.781
Março	681.728	615.621	707.964	722.241
Abril	495.633	628.684	528.113	496.804
Maiο	520.095	617.971	524.425	473.784
Junho	428.077	572.021	543.420	522.018
Julho	494.609	511.904	486.309	476.581
Agosto	594.075	504.607	555.067	562.462
Setembro	719.900	529.584	635.501	693.535
Outubro	641.139	581.146	552.089	468.965

Observando os valores da TABELA 6.14 pode-se concluir que o desempenho do método de ajuste foi muito bom para este produto pois conseguiu superar as previsões quantitativas e 9 meses e empatou em um, e gerou previsões melhores que as da empresa em 6 meses, apesar de contar com menos informações do que a especialista para realizar a previsão.

A FIGURA 6.3 traz um gráfico comparativos entre as previsões ajustadas e as quantitativas.

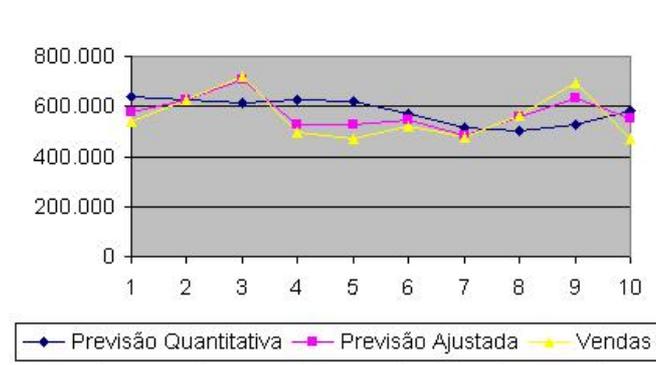


FIGURA 6.3 – Gráfico de comparação entre as previsões e a venda de refrigerante *pet* 2 litros.

A TABELA 6.15 apresenta as medidas de erro calculadas para as previsões ajustadas e quantitativas. Pela análise do MAPE, nota-se que o método de ajuste gerou previsões 3 vezes mais exatas do que as resultantes da combinação dos métodos quantitativos.

TABELA 6.15 – Comparação dos erros das previsões para refrigerante *pet* 600ml.

Mês	Erro Absoluto		Erro Percentual	
	Previsão Quantitativa	Previsão Ajustada	Previsão Quantitativa	Previsão Ajustada
Janeiro	104.016	39.885	19	7
Fevereiro	-110	-110	0	0
Março	-106.620	-14.277	-15	-2
Abril	131.880	31.309	27	6
Mai	144.187	50.641	30	11
Junho	50.003	21.402	10	4
Julho	35.323	9.728	7	2
Agosto	-57.855	-7.395	-10	-1
Setembro	-163.951	-58.034	-24	-8
Outubro	112.181	83.124	24	18
AE	24.905	15.627		
MAD	90.613	31.591		
MAPE			15	5

6.5 Refrigerante em embalagem de vidro retornável de 290ml (KS): coca-cola

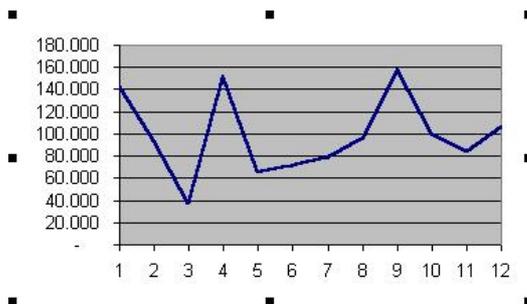
As vendas registradas para este produto no ano de 2002 estão mostradas na TABELA 6.16.

TABELA 6.16 – VENDAS DE REFRIGERANTE EMBALAGEM KS EM 2002.

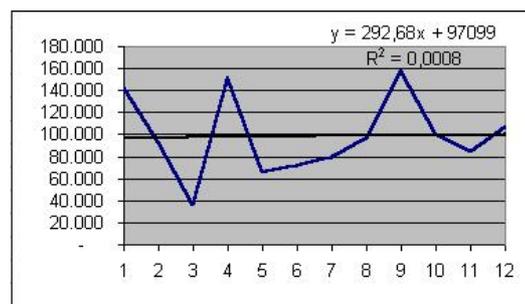
Mês	Vendas
Janeiro	143.144
Fevereiro	93.652
Março	36.569
Abril	151.958
Mai	65.932
Junho	72.029
Julho	79.395
Agosto	96.657
Setembro	158.219
Outubro	100.221
Novembro	83.935
Dezembro	106.303

Estes dados foram colocados em uma planilha do Excel e o processo de previsão foi iniciado. Foram construídos gráficos e as linhas de tendência foram adicionadas. Os gráficos resultantes são:

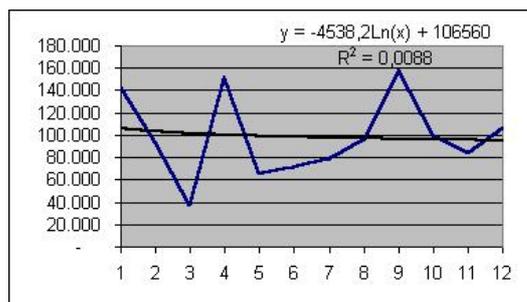
Vendas no ano de 2002



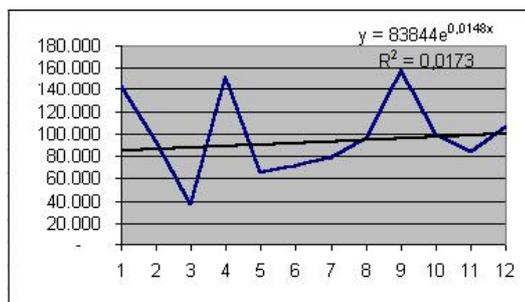
Linha de tendência linear



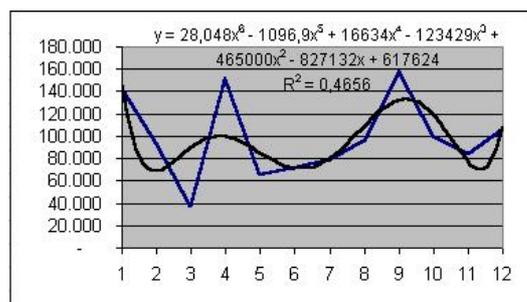
Linha de tendência logarítmica



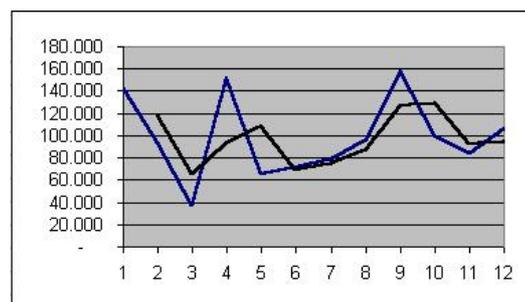
Linha de tendência exponencial



Linha de tendência polinomial com ordem 6



Linha de tendência por média móvel



Mais uma vez, o primeiro sistema especialista foi utilizado para que os métodos de previsão de demanda fossem indicados. Da mesma forma, a linha de tendência que melhor se aproximou foi a de média móvel e para uma segunda aproximação a linha que apresentou menor R^2 foi a de tendência polinomial. Os métodos de previsão indicados foram:

- ✓ Média Móvel
- ✓ Método de Winters

As previsões calculadas pelos dois métodos foram combinadas pelo método proposto por LACKMAN & BRANDON (1994). Os resultados estão apresentados na tabela abaixo:

TABELA 6.17 – Cálculo das previsões quantitativas para refrigerante ks.

Mês	Previsão calculada por Média Móvel	Previsão calculada pelo Método de Winters	Previsão Resultante
Janeiro	96.820	96.198	96.758
Fevereiro	96.666	96.962	96.696
Março	103.569	117.296	104.941
Abril	110.694	115.245	111.149
Mai	111.810	120.959	112.725
Junho	110.913	124.823	112.304
Julho	100.784	126.385	103.344
Agosto	92.245	123.126	95.333
Setembro	85.051	116.556	88.201
Outubro	90.901	116.928	93.504

As informações disponibilizadas permitiram que os seguintes fatores que pudessem influenciar a demanda fossem identificados:

- Janeiro e Abril de 2002: campanhas promocionais para alavancar as vendas.
- Setembro de 2002: linha parada na terceira semana para manutenção.
- Outubro de 2002: campanha para aumentar as vendas e linha parada para manutenção na segunda semana.
- Novembro de 2002: campanha promocional.
- Janeiro de Fevereiro de 2003: campanha promocional.
- Março de 2003: venda excepcional de 80.000 unidades nas duas últimas semanas.
- Abril, Maio e Junho de 2003: foco na distribuição de ks. Em junho de 2003 a linha ficou parada uma semana.
- Setembro e Outubro de 2003: campanha promocional.

Considerando estas informações e o fato da demanda ter alta variabilidade e apresentar sazonalidade, a análise dos dados históricos, permitiu concluir que:

- As campanhas promocionais devem aumentar as vendas em janeiro e fevereiro de 2003, para considerar este fato, as previsões para estes meses devem ser aumentadas em 5%.
- Em março de 2002 houve uma queda acentuada nas vendas, portanto assume-se que a previsão para março de 2003 deve ser reduzida em 50%.
- Campanha com foco em distribuição para abril, maio e junho. Como as previsões quantitativas para estes meses já estão otimistas, elas devem ser mantidas.
- Considerando que o mercado está abastecido pela campanha anterior, deve-se reduzir a previsão para julho de 2003 em 10%.
- Considerar um aumento de 5% na previsão de agosto de 2003, pois é esperado que as vendas tenham um aumento, como ocorreu no mesmo período do ano anterior.
- Com a campanha promocional em setembro e outubro de 2003, com maior intensidade em setembro de 2003, é esperado que as vendas aumentem. Para considerar este fato, as previsões de setembro e outubro devem ser aumentadas em 20 e 10% respectivamente.

Com base em todas estas informações, o segundo sistema especialista foi então utilizado para ajustar as previsões quantitativas. Os resultados estão apresentados na TABELA 6.18.

TABELA 6.18 – Previsões ajustadas pelo SEAP para refrigerante ks.

Mês	Previsão	Mês	Previsão
Janeiro	23366,95	Junho	25830
	19303,13		21337,83
	27430,76		0
	31494,58		34814,35
Total	101595,4	Total	81982
Fevereiro	23351,99	Julho	21392,29
	19290,77		17671,9
	27413,21		25112,69
	31474,42		28833,09
Total	101530	Total	93010
Março	12068,27	Agosto	23022,87
	9969,437		19018,89
	54167,09		27026,85
	56265,92		31030,82
Total	132471	Total	100099
Abril	25564,22	Setembro	24343,54
	21118,27		20109,88
	30010,18		28577,19
	34456,13		32810,85
Total	111149	Total	105841
Maio	25926,72	Outubro	23656,51
	21417,73		19542,33
	30435,72		27770,68
	34944,71		28986,24
Total	112725	Total	99956

Pela TABELA 6.19 podem ser feitas comparações entre as previsões quantitativas, as ajustadas e as utilizadas pela empresa.

TABELA 6.19 – Previsões para refrigerante ks.

Mês	Previsão da Empresa	Previsão Quantitativa	Previsão Ajustada	Vendas
Janeiro	81.442	96.758	101.595	99.760
Fevereiro	84.412	96.696	101.530	104.643
Março	131.758	104.941	132.471	127.678
Abril	97.583	111.149	111.149	103.109
Maio	111.062	112.725	112.725	101.953
Junho	86.202	112.304	81.982	97.291
Julho	80.931	103.344	93.010	77.490
Agosto	84.670	95.333	100.099	80.371
Setembro	111.736	88.201	105.841	114.843
Outubro	103.136	93.504	99.956	100.314

Pode ser visto que em comparação com às previsões quantitativas, o método de ajuste conseguiu gerar 7 previsões mais acuradas, empatou em duas observações e gerou

uma previsão pior. Em comparação às previsões utilizadas pela empresa, as previsões ajustadas foram mais acuradas em 3 meses. Mais uma vez, acredita-se que este desempenho se deve ao pouco acesso às informações da empresa, como explicitado no item 6.3. A FIGURA 6.4 permite analisar melhor o comportamento das previsões quantitativas e ajustadas.

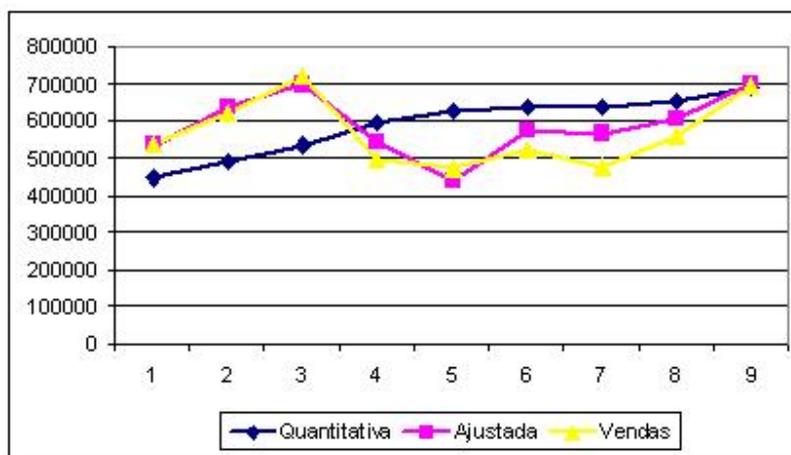


FIGURA 6.4 – Gráfico de comparação entre as previsões e a venda de refrigerante ks.

A análise do MAPE, apresentado na TABELA 6.20, permite concluir que em média, o método de ajuste gera previsões 55% mais exatas do que a combinação das previsões quantitativas.

TABELA 6.15 – Comparação dos erros das previsões para refrigerante ks.

Mês	Erro Absoluto		Erro Percentual	
	Previsão Quantitativa	Previsão Ajustada	Previsão Quantitativa	Previsão Ajustada
Janeiro	-3.002	1.835	-3	2
Fevereiro	-7.947	-3.113	-8	-3
Março	-22.737	4.793	-18	4
Abril	8.040	8.040	8	8
Maio	10.772	10.772	11	11
Junho	15.013	-15.309	15	-16
Julho	25.854	15.520	33	20
Agosto	14.962	19.728	19	25
Setembro	-26.642	-9.002	-23	-8
Outubro	-6.810	-358	-7	0
AE	7.503	32.907		
MAD	14.178	8.847		
MAPE			14	9

7 CONCLUSÕES

Uma vez que existe uma diferença entre o fornecimento e a demanda e que existe um *gap* de tempo entre o início da produção de um produto e sua disponibilização do mesmo para os consumidores, as empresas devem recorrer à previsão de demanda para antecipar o comportamento do mercado e permitir que seus consumidores encontrem seus produtos no momento em que desejarem.

A instabilidade do mercado e as necessidades de tempo e recursos que as empresas devem dispor para ajustar sua capacidade são as principais justificativas para a existência de um setor responsável pela previsão.

Considerando que a previsão de demanda tem impacto direto sobre o planejamento e controle da produção, a alocação de recursos humanos, o controle de estoque e o marketing e que estas são funções vitais para a empresa, previsões que sejam muito incorretas têm conseqüências desastrosas. As principais delas são: falta de produtos e conseqüente perda de vendas e insatisfação dos consumidores e, em um outro extremo, excesso de mercadorias não vendidas que se deterioram nos estoques.

CORRÊA et al. (2001) afirma que, entre outros fatores, para se realizar uma boa previsão é necessário:

- ✓ saber analisar os dados históricos, detectando certos comportamentos dos consumidores e eliminando anormalidades que poderiam induzir a erros;
- ✓ conhecer os produtos, identificando como suas características, usos e estágio no ciclo de vida afetam a demanda, e
- ✓ considerar fatos, documentando eventos e seus impactos na demanda, sua *repetição* pode facilitar o processo de previsão de demanda.

Para levar em consideração estes fatores esta pesquisa propõe um método de previsão de demanda que combina métodos qualitativos e quantitativos, pelo uso de Sistemas Especialistas juntamente com um sistema de planilha eletrônica. O primeiro sistema especialista – SEIMP – contém em sua base conhecimento causal e identifica, a partir de um conjunto de dados históricos, quais os métodos qualitativos de curto prazo são mais adequados. Com o uso de planilhas eletrônicas é possível realizar os cálculos de cada método. As previsões geradas por estes métodos são combinadas de forma ponderada pelo

método proposto por LACKMAN & BRANDON (1994). Esta previsão qualitativa é então ajustada pelo segundo sistema especialista – SEAP – que armazena em sua base o conhecimento de uma especialista em previsão de demanda. Para a construção da solução foi realizado um estudo de caso em uma empresa de refrigerantes. A seguir as hipóteses sugeridas pela pesquisa são confirmadas, com base em uma análise dos resultados dos testes:

- ✓ H1: A utilização do julgamento como forma de ajuste de previsão de demanda obtida por meio de métodos quantitativos melhora a qualidade da previsão.
 - Os resultados dos testes realizados e apresentados no Capítulo 6 permitem concluir que o método de ajuste gera previsões melhores do que a combinação dos métodos quantitativos, permitindo que a hipótese H1 seja confirmada. Pode ser observado pela comparação entre as previsões geradas pelos métodos quantitativos e a previsão ajustada que, em 40 observações, esta só obtém resultados piores em 3 observações.
- ✓ H2: Os métodos tradicionais da Pesquisa Operacional para Previsão de Demanda não atendem a todas as expectativas dos tomadores de decisão em um ambiente industrial.
 - Na indústria na qual se realizou o estudo de caso, a previsão que é gerada pelos modelos de Box-Jenkins é ajustada por uma especialista, confirmando a hipótese H2. Além disso, com base nos testes realizados pode-se concluir que, uma formalização na combinação de métodos quantitativos com julgamento de especialista permite uma melhora ainda maior das previsões.
- ✓ H3: O conhecimento utilizado no julgamento de uma previsão gerada por métodos quantitativos permite, por si só, a construção de uma Base de Conhecimento de um Sistema Especialista.
 - Apesar do pouco acesso a informações da empresa e pouca disponibilidade da especialista, o conhecimento adquirido na pesquisa de campo, permitiu que se construísse o sistema especialista SEAP, que obteve desempenho satisfatório, confirmando a hipótese H3. Além disso, pode-se afirmar que se a aquisição de

conhecimento puder ser continuada, possibilitando a elaboração de novas regras, o desempenho do SEAP tende a melhorar.

Analisando todos os resultados obtidos, pode-se concluir que a pesquisa atingiu seu objetivo e conseguiu, por meio da solução proposta, melhorar a qualidade da previsão de demanda com o uso conjugado de métodos quantitativos e qualitativos.

Para finalizar este trabalho, algumas considerações são feitas para indicar possíveis direcionamentos a pesquisas futuras:

- ✓ Novos estudos de caso podem ser realizados para o método de previsão de demanda desenvolvido na pesquisa, combinação de conhecimentos teóricos e práticos, seja considerado uma nova metodologia de previsão de demanda.
- ✓ Algumas circunstâncias limitaram a coleta de dados sobre a previsão e o comportamento da demanda da empresa estudada, portanto, uma continuação possível seria a coleta e análise de mais dados e informações para enriquecer a base de conhecimento do SEAP e então verificar se os resultados obtidos podem ser melhorados.
- ✓ Não estava no escopo desta pesquisa mensurar os possíveis impactos da melhoria das previsões em outras áreas como estoques e *scheduling*. Uma contribuição seria dada se fosse possível coletar e analisar dados sobre o volume de estoques, o número de duração de *set-ups* e as vendas, quando a previsão é melhorada.
- ✓ O estudo de caso foi realizado em uma empresa do segmento de refrigerantes. Outros estudos poderiam ser realizados em diversos segmentos industriais para constatar a validade do método proposto.
- ✓ Os sistemas especialistas foram desenvolvidos em separado e há a necessidade de recorrer ao uso de planilhas eletrônicas para realizar cálculos mais complexos. Outra sugestão é a integração dos dois sistemas especialistas e desenvolvimento dos cálculos matemáticos pelo próprio sistema resultante. Para tanto, é necessário considerar o uso de outros *shells*, como por exemplo o NEXPERT OBJECT.
- ✓ Inicialmente esta pesquisa pretendia analisar os módulos de previsão de demanda existentes para as soluções ERP disponíveis no mercado e propor uma forma de integração do método proposto com os ERP's. Contudo devido ao baixo retorno das

empresas desenvolvedoras dos ERP's aos questionários iniciais, enviados para avaliação, este objetivo foi eliminado da pesquisa e fica então, como sugestão a pesquisas futuras.

- ✓ Neste trabalho foi realizada uma pesquisa, considerando uma amostra modesta, para avaliar como a previsão de demanda é realizada em diversos segmentos industriais. Propõe-se, então, a extensão desta pesquisa, que considerando uma amostra maior de empresas, poderia avaliar questões como a lacuna entre a teoria sobre a previsão de demanda e a prática nas empresas, e além disso, a possibilidade de se utilizar julgamento de um especialista, de maneira formal, para ajustar as previsões.
- ✓ Por fim, um tema atual e que vem ganhando destaque é a Gestão de Conhecimento. A utilização de sistemas especialistas pelas empresas é uma forma de automatizar a gestão de conhecimento. Uma proposta é que seja desenvolvido um sistema especialista para previsão de demanda que contenha em sua base conhecimentos de outras áreas, como marketing, PCP e controle de estoques, realizando a integração entre estas diversas áreas funcionais. Uma interessante observação é o impacto do uso de tal sistema na realização das operações e no comportamento dos funcionários.

8 REFERÊNCIAS BIBLIOGRÁFICAS

ALVES-MAZZOTTI, A. J., GEWANDSZNAJDER, F. **O método nas ciências naturais e sociais: pesquisa quantitativa e qualitativa.** São Paulo: Pioneira, 1998.

ARMSTRONG, J. S. & GROHMAN, M. C. A comparative study of methods for long-range marketing forecasting. **Management Science**, 19, 2, 211-221, 1972.

ARMSTRONG, J. S. Forecasting by extrapolation: conclusions from 25 years of research. **Interfaces**, v. 14, p. 52-66, 1984.

ARMSTRONG, J. S. & YOKUN, J. T. Potential diffusion of expert systems in forecasting. **Technological Forecasting and Social Change**, v. 67, p. 93-103, 2001.

ASHER, R. On the relative worth of recent macroeconomic forecasts. **International Journal of Forecasting**, n. 4, p. 363-376, 1978.

AUTOBOX. **AFS - Automatic Forecasting Systems Inc.** Disponível em: <<http://www.autobox.com>>. Acesso em: 10 e 14 de fevereiro de 2003.

BARBOSA, E. P. **Dynamic bayesian models for vector time series analysis and forecasting.** Warwick: 1989. Apresentada para obtenção do grau de Doutorado – University of Warwick.

BEASLEY, J. E. Forecasting by environmental protection legislation using cross-impact analysis. **Long Range planning**, v.17, p. 132-138, 1984.

BELHOT, R. V. **Concepção de uma base de conhecimento de um sistema especialista: uma aplicação.** São Paulo, 1991. Tese de Doutorado – Escola Politécnica, Universidade de São Paulo.

BERRY, W. L. & BLIEMEL, F. W. Selecting exponential smoothing constants: an application of pattern search. **International Journal of Production Research**, v. 12, n. 4, p. 483-500, july, 1974.

BERTO, R. M. V. S. & NAKANO, D. N. Metodologia da Pesquisa e a Engenharia de Produção. In: ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO (ENESEP), XVIII e INTERNATIONAL CONGRESS OF INDUSTRIAL ENGINEERING (ICIE), IV, Outubro 1998, Niterói, RJ. **Anais ...**, Rio de Janeiro: UFF/ABEPRO, 1998. (CD-ROM).

BOX, G. E. P. & JENKINS, G. M. **Time series analysis, forecasting and control**. San Francisco: Holden Day, 1970.

BOWERMAN, B. L. & O'CONNELL, R. T. **Forecasting and time-series: an applied approach**. Belmont, California: Duxbury Press, 1993.

BRANDON, C. FRITZ, R. & XANDER, J. Combining Time Series and Econometric Forecasts of Tourism Activity. **Annual of Tourism Research**, v. 2, p.219-229, 1984.

BROEMELING, L. D. **Bayesian analysis of linear models**. New York: Marcel Dekker, 1985.

BROWN, R. G. **Smoothing, forecasting and prediction of discrete time series**. Englewood Cliffs, NJ: Prentice Hall, 1962.

BRYMAN, A. **Research methods and organization studies**. London: Routledge, 1995. 281 páginas.

BUFFA, E. S. & SARIN, R. K. Forecasting for operations. In: **Modern production/operations management**. New York: John Wiley & Sons, 1987, 53-98.

BUNGE, M. **Epistemologia: curso de atualização**. São Paulo: T. A. Queiroz/EDUSP, 1980.

BUNN, D. & WRIGHT, G. Interaction of judgemental and statistical forecasting methods: Issues and analysis. **Management Science**, v. 37, n. 5, p. 501–515, 1991.

CERVO, A. L. & BERVIAN, P. A. **Metodologia científica: para uso dos estudantes universitários**. São Paulo: McGraw Hill, 1983. 249 páginas.

CHAMBERS, J. C.; MULLICK, S. K. & SMITH, D. D. How to choose the right forecasting technique. **Harvard Business Review**, p. 45-74, july-august 1971.

CHANG, P. C.; WANG, C. P.; YUAN, B. J. C. & CHUANG, K. T. Forecast of development trends in Taiwan's machinery industry. **Technological Forecasting & Social Change**, v. 69, p. 781-802, 2002.

CHIU, C. C.; KAO, L. J. & COOK, D. F. Combining a neural network with a rule-based expert system approach for short-term power load forecasting in Taiwan. **Expert Systems with Applications**, v. 13, n. 4, p. 299-305, 1997.

COMPANHIA DE BEBIDAS SOROCABA. **Visita Virtual ao Processo de Produção da Coca-Cola**. Disponível em: <<http://www.aquibemgelado.com.br/>>. Acesso em 10 de janeiro de 2004.

CORRÊA, H. L.; GIANESI, I. G. N. & CAON, M. **Planejamento, programação e controle da produção: MRP II – ERP, conceitos, uso e implantação**. São Paulo: Atlas, 1997.

CORRÊA, H. L.; GIANESI, I. G. N. & CAON, M. **Planejamento, programação e controle da produção: MRP II – ERP, conceitos, uso e implantação**, 4^a ed. São Paulo: Atlas, 2001.

DECISION PRO. **Vanguard Software Corporation - Decision Technology Experts**. Disponível em: <<http://www.vanguardsw.com/>>. Acesso em: 10 e 14 de fevereiro de 2003.

DELURGIO, S. A. **Forecasting principles and applications**. New York: Irwin-McGraw Hill, 1998.

DIEBOLD, F. X. **Elements of forecasting**. Ohio: South-Western College Publishing, 1998.

DRAPER, N. R. & SMITH, H. **Applied Regression Analysis**. New York: John Wiley & Sons, 1968.

EMYCIN. **Emycin – Expert System Shell.** Disponível em: <<http://www.cpes.sussex.ac.uk/faculty/raj/emycin.html>>. Acesso em: 26 de fevereiro de 2003.

ERSCHLER, J. & ESQUIROL, P. Decision-aid in job shop scheduling: A knowledge based approach. **Proceedings of the 1986 IEEE International Conference on Robotics and Automation**, São Francisco, p.1651-1656, abril, 1986.

ETO, H. The suitability of technology forecasting/foresight methods for decision systems and strategy: a japanese view. **Technological Forecasting & Social Change**, v. 70, p. 231-249, 2003.

EXPERT SINTA. **Expert Sinta Shell – Laboratório de Inteligência Artificial.** Disponível em: <<http://www.lia.ufc.br/~bezerra/exsinta/>>. Acesso em: 26 de fevereiro de 2003.

FEIGENBAUM, E. In: HARMON & KING. **Expert Systems: intelligence in business.** New York: Ed. Wiley, 1985.

FELLENSTEIN, C., GREEN, C. O., PALMER, L. M., WALKER, A. & WYLEY, D. J. A prototype manufacturing knowledge base in Syllog. **IBM Journal of Research and Development**, v. 29, n. 4, p. 413-421, 1985.

FORECAST PRO. **Forecast Pro Home Page - Software for sales forecasting, inventory planning, demand planning and collaborative planning.** Disponível em: <<http://www.forecastpro.com/>>. Acesso em: 10 e 14 de fevereiro de 2003.

FORECAST X. **John Galt Solutions - Sales forecasting, demand planning and collaborative software.** Disponível em: <<http://www.forecastx.com/>>. Acesso em: 10 e 14 de fevereiro de 2003.

GAUSS. **Aptech Web Home.** Disponível em: <<http://www.aptech.com/>>. Acesso em: 10 e 14 de fevereiro de 2003.

GOODE, W. J. & HATT, P. K. **Métodos em pesquisa social.** Sétima Edição. São Paulo: Companhia Editora Nacional, 1979.

GOODWIN, P. Integrating management judgment and statistical methods to improve short-term forecasts. **Omega**, v. 30, p. 127-135, 2002.

HELMER, O. **Systematic use of experts**. Santa Monica, CA: Rand Corporation, 1967.

HOLT, C. C. Forecasting seasonal and trends by exponentially weighted moving averages. **Office of Naval Research Memorandum**, n. 52, 1957.

HSU, C. C. & CHEN, C. Y. Regional load forecasting in Taiwan: applications of artificial neural networks. **Energy Conversion and Management**, v. 44, p. 1941-1949, 2003.

JOHNSON, L. A. & MONTGOMERY, D. C. Forecasting systems. In: **Operations research in production planning, scheduling and inventory control**. New York, John Willey & Sons Inc., 1974, 399-477.

KANDIL, M. S.; EL-DEBEIKY, S. M. & HASANIEN, N. E. Overview and comparison of long-term forecasting techniques for a fast developing utility: part I. **Electric Power Systems Research**, v. 58, p. 11-17, 2001.

KANDIL, M. S.; EL-DEBEIKY, S. M. & HASANIEN, N. E. The implementation of long-term forecasting strategies using a knowledge-based expert system: part-II. **Electric Power Systems Research**, v. 58, p. 19-25, 2001.

KASTNER, J. K. & HONG, S. J. A review of expert systems. **European Journal of Operational Research**, v. 18, p. 285-292, 1984.

KRAJEWSKI, L. J. & RITZMAN, L. P. **Operations Management**. USA: Addison-Wesley Publishing Company, 1993.

KUSIAK, A. & CHEN M. Expert system for planning and scheduling manufacturing systems. **European Journal of Operational Research**, v. 34, n. 2, p. 113-130, março de 1988.

LACKMAN, C. & BRANDON, C. Forecasting using relative errors weights. **Managing Intelligence & Planning**, v. 12, n.1, p 37-41, 1994.

LAKATOS, E. M. & MARCONI, M. A. **Metodologia científica**: ciência e conhecimento científico, métodos científicos, teoria, hipóteses e variáveis. Segunda Edição. São Paulo: Editora Atlas S. A., 1995.

LIEBOWITZ, J. **Introduction to expert systems**. Watsonville: Mitchell Publishing - McGraw Hill, 1998.

LEIBOWITZ, J. Expert Systems: A Short Introduction. **Engineering Fracture Mechanics**, v. 50, n. 5/6, p. 601-607, 1995.

LINSTONE, H. A. & TUROFF, M. **The delphi method**: techniques and applications. Reading, MA: Addison-Wesley, 1975.

LÜDKE, M. & ANDRE, M. E. D. A. **Pesquisa em educação**: abordagens qualitativas. São Paulo: EPU, 1986.

MAKRIDAKIS, S.; WHEELWRIGHT, S. C. & MCGHEE, V. E. **Forecasting**: methods and applications. Segunda Edição. New York: John Wiley & Sons, 1983.

METAXIOTIS, K. S., PSARRAS, J. E. & ASKOUNIS, D. T. GENESYS: an expert system for production scheduling. **Industrial Management & Data Systems**, v. 102, n. 6, p. 309-317, 2002.

MONTGOMERY, D. C. & JOHNSON, L. A. **Forecasting and time series analysis**. New York: McGraw Hill, 1976.

NAHMIAS, S. Forecasting. In: **Production and operations analysis**. New York: McGraw-Hill, 2001, 55-112.

NARASIMHAN, S; MCLEAVEY, D. W.; BILLINGTON, P. **Production Planning and Inventory Control**. New Jersey: Prentice Hall, 1995.

NASR, G.E.; BADR, E.A. & JOUN, C. Backpropagation neural networks for modeling gasoline consumption. **Energy Conversion and Management**, v. 44, p. 893-905, 2003.

NEURALWORKS PREDICT. **NeuralWare**. Disponível em: <<http://www.neuralware.com/>>. Acesso em: 10 e 14 de fevereiro de 2003.

NURMINEN, J. K., KARONEN, O., HÄTÖNEN, K. What makes expert systems survive over 10 years: empirical evaluation of several engineering applications. **Expert Systems with Applications**, v. 24, p. 199–211, 2003.

PILZ, J. **Bayesian estimation and experimental design in linear regression models**. Segunda Edição. New York: John Wiley, 1983.

POLE, A.; WEST, M. & HARRISON, J. **Applied bayesian forecasting and time series analysis**. New York: Chapman & Hall, 1994. Texts in Statistical Science Series.

POSSL, G. W. **Production and Inventory Control: Principles & Techniques**. New Jersey: Prentice Hall, 1985.

PRASAD, S.; BABBAR, S. & CALIS, A. International operations management and operations management research: a comparative analysis. **Omega**, v. 28, p. 97-110, 1996.

PROFILLIDIS, V. A. Econometric and fuzzy models for the forecast of demand in the airport of Rhodes. **Journal of Air Transport Management**, v. 6, p. 95-100, 2000.

RICH, E. **Inteligência artificial**. São Paulo: McGraw Hill, 1988.

ROBERTSON, R. **Globalização**. Petrópolis: Vozes, 1996.

SÁNCHEZ, A.M. & PÉREZ, M.P. Flexibility in new product development: a survey of practices and its relationship with the product's technological complexity. *Technovation*, 23, p. 139–145, 2003.

SANDERS, N. R. Managing the forecasting function. **Industrial Management and Data Systems**, v. 95, n. 4, p. 12-18, 1995.

SANDERS, N. R. & RITZMAN, L. P. Some empirical findings on short-term forecasting: technique complexity and combinations. **Decision Sciences**, v. 20, p. 635-640, 1989.

SHOBRYS, D. E. & WHITE, D. C. Planning, scheduling and control systems: why can they not work together. **Computers and chemical engineering**, 24, p. 163-173, 2000.

SIPPER, D. & BULFIN, R. L. Jr. Forecasting. In: **Production: planning, control and integration**. New York: McGraw Hill, 1998. 88-161.

SMART FORECASTS. **Smart Software**. Disponível em: <<http://www.smartcorp.com/>>. Acesso em 10 e 14 de fevereiro de 2003.

SMITH, B. **Focus forecasting**: computer techniques for inventory control. Boston: CBI Publishing Inc., 1978.

SMITH, P. & HUSSEIN, S. Forecasting short-term regional gas demand using an expert system. **Expert Systems with Application**, v. 10, n. 2, p. 265-273, 1996.

STYLIANOU, A. C. An empirical model for the evaluation and selection of expert system shells. **Expert Systems with Applications**, v. 8, n. 1, 143-155, 1995.

TIME TRENDS FORECAST. **TimeTrends® Demand Forecasting Computer Software**. Disponível em: <<http://www.alt-c.com/>>. Acesso em 10 e 14 de fevereiro de 2003.

TUBINO, D. F. **Manual de planejamento e controle da produção**. São Paulo: Atlas, 1997.

VERGARA, S. C. **Projetos e relatórios de pesquisa em administração**. Terceira Edição. São Paulo: Editora Atlas, 2000.

VOLLMANN, T. E, BERRY, W. L. WHYBARK, D.C. **Manufacturing and control systems**. Boston: McGraw-Hill, 1997.

VP-EXPERT. **Tutorial**. Disponível em: <<http://assexpert.home.ro/tutorial.html>>. Acesso em 26 de fevereiro de 2003.

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

WEST, M. & HARRISON, J. **Bayesian forecasting and dynamic models**. Segunda Edição. New York: Springer Verlag, 1997. Springer Series in Statistics.

WILSON, J. H. & KEATING, B. **Business forecasting**. Homewood, IL: Richard D. Irwin, 1990.

WINKLHOFER, H.; DIAMANTOPOULOS, A. & WITT, S. F. Forecasting Practice: a review of the empirical literature and an agenda for future research. **International Journal of Forecasting**, 12, p. 193-221, 1996.

WINSTON, W. L. **Operations Research: applications and algorithms**. Belmont: Duxbury Press, 1993.

WINTERS, P. R. Forecasting sales by exponentially weighted moving averages. **Management Science**, v. 6, n. 3, p. 324-42, 1960.

WRIGHT, G., LAWRENCE, M. J. & COLLOPY, F. The role validity of judgment in forecasting. **International Journal of Forecasting**, v. 12, p. 1-8, 1996.

WONG, B. K. & MONACO, J. A. Expert systems applications in business: a review and analysis of the literature (1977-1993). **Information and Management**, v. 29, p. 141-152, 1995.

WRIGHT, G.; LAWRENCE, M. J. & COLLOPY, F. The role and validity of judgment in forecasting. **International Journal of Forecasting**, v. 12, p. 1-8, 1996.

YIN, R. K. **Case study research: design and methods**. Segunda Edição. Thousand Oaks: Sage Publications, 1994.

ZHANG, G.; PATUWO, B. E. & HU, M. Y. Forecasting with artificial neural networks: the state of the art. **International Journal of Forecasting**, v. 14, p. 35-62, 1998.

8.1 BIBLIOGRAFIA

ANDRADE, M. M. **Introdução à metodologia do trabalho científico**. 3ª Edição. São Paulo: Editora Atlas S. A., 1998. 151 páginas.

ASHRAFI, N. et al. Expert systems reliability: A life cycle approach. **Information & Management**, v. 28, p. 405-414, 1995.

BAILEY, J. E. & BEDWORTH, D. D. **Integrated production control systems: Management, Analysis, Design**. Second Edition. John Wiley & Sons, 1987.

BAILS, D. G. & PEPPERS, L. C. **Business fluctuations: forecasting techniques and applications**. Englewood Cliffs: Prentice-Hall, 1982.

BARTEZZAGHI, E.; VERGANTI, R. & ZOTTERI, G. A simulation framework for forecasting uncertain lumpy demand. **International Journal of Production Economics**, 1999. n. 59, p. 499–510.

CAMPBELL, A. J. Creating customer knowledge competence: managing customer relationship management programs strategically. **Industrial Marketing Management**, v. 5554, p. 1– 9, 2003.

CHIAVENATO, I. **Administração de empresas**. São Paulo: McGraw Hill, 1987.

DIAS, A. S. & FERREIRA, D. Sistemas especialistas nas organizações. In: SIMPÓSIO DE ENGENHARIA DE PRODUÇÃO, VI, 1999, Bauru. **Anais...** Bauru: Ed. Unesp, 1999.

GODOY, A. S. Introdução à pesquisa qualitativa e suas possibilidades. **Revista de Administração de Empresas**, 1995.

GROSS, C. W. & PERTERSON, R. T. **Business forecasting**. Segunda Edição. New York: John Wiley & Sons, 1983.

HAJIME E. The suitability of technology forecasting/foresight methods for decision systems and strategy – A Japanese view. **Technological Forecasting & Social Change**, v. 70, p. 231-249, 2003.

HAX, A. C.; CANDEA, D. **Production and Inventory Management**. New Jersey: Prentice- Hall Inc., 1984

HUMPHREY, J. Industrial reorganization in developing countries: from models to trajectories. **World Development**, v. 23, n.1, p.149-162, 1995.

KADANE, J. B. **Robustness of bayesian analysis**. Amsterdam: North-Holland, 1984.

KELLER, R. **Tecnologia de sistemas especialistas: desenvolvimento de uma aplicação**. São Paulo: Makron Books, 1991.

KNIGHT, K. & RICH, E. **Inteligência artificial**. São Paulo: Makron Books, 1997.

LEE, J. K.; KWON, S. B. ES*: an expert system development planner using a constraint and rule-based approach. **Expert Systems with Applications**, v. 9, n. 1, p. 3-14, 1995.

MCCLELLAND, M. K. & WAGNER, H. M. Location of inventories in an MRP environment. **Decision Sciences**, v. 19, p. 535–553, 1988.

NELSON, C. R. **Applied time series analysis for managerial forecasting**. San Francisco: Holden Day, 1973.

OSTROWSKY, B.; OBER, J.; WENZEL, R.; EDMOND, M. The case of the cold thermometers. **American Journal of Infection Control**, v. 31, n. 1, p. 57-59, february 2003.

PRESSMAN, R. **Engenharia de Software**. Makron Books, 1998.

SALOMON, D. V. **Como fazer uma monografia**. São Paulo: Livraria Martins Fontes, 1991.

SUBRAMANIAN, G. H.; YAVERBAUM, G. An empirical evaluation of factors influencing expert systems effectiveness. **Journal of System Softwares**, v. 38, p. 255-261, 1997.

TURBAN, E. **Expert systems and applied artificial intelligence**. USA: Macmillan Publishing Company, 1992.

VENKATRAMAN, R.; VENKATRAMAN, S. **Rule-Based System Application for a Technical Problem in Inventory Issue**. *Artificial Intelligence in Engineering* 14, pp 143-152, 2000.

WEISS, S. M. et al. **Computer systems that learn**: classification and prediction methods from statistics, neural nets, machine learning and expert systems. San Mateo: Morgan Kaufmann Publishers Inc., 1991.

WEMMERLÖV, U., A time-phased order-point system in environments with and without uncertainty: A comparative analysis of non-monetary performance variables. **International Journal of Production Research**, v. 24, n. 2, 1986.

WHYBARK, D.C. & WILLIAMS, J.G. Material requirements planning under uncertainty. **Decision Sciences**, v. 7, n. 4, p. 595-606, 1976.

WOLFGRAM, D. D. et al. **Expert systems for technical professional**. New York: John Wiley, 1987.

ZELLNER, A. **An introduction to bayesian inference in econometrics**. New York: John Wiley, 1971. Wiley Series in Probability and Mathematical Statistics.

APÊNDICES

APÊNDICE A

Exemplo A-01: Métodos Bayesianos

Considerando um caso em que não há informação histórica disponível e uma densidade razoável para a é $N(50,4)$ e $\sigma_\varepsilon^2 = 9$. Para o período $t = 1$, a previsão da demanda é $F_1 = 50$. Supondo que neste período inicial tenha sido $d_1 = 56$. A estimativa de a , pela equação 3-02, será:

$$a_1 = \frac{1}{(9/4) + 1} \cdot 56 + \frac{(9/4)}{(9/4) + 1} \cdot 50 \cong 52$$

e a previsão será $F_2 = a_1 = 52$. Supondo que a demanda tenha sido $d_2 = 58$, pela equação 3-02 $a_2 = 53$ e $F_3 = 53$. E o procedimento continua até que se tenham dados históricos suficientes para que se adote outro método de previsão.

Exemplo A-02: Métodos de Media Móvel

Supondo que a demanda de um item em um período seja:

Período	Demanda
1	200
2	250
3	175

A previsão de média móvel de três períodos para o instante $t = 4$ será:

$$F_4 = (1/3)(200 + 250 + 175) = 208$$

Supondo que a demanda em $t = 4$ tenha sido $d_4 = 186$, a previsão para o período $t = 5$ é:

$$F_5 = (1/3)(250 + 175 + 186) = 204$$

Exemplo A-03: Métodos de Suavização Exponencial

Supondo que a demanda em um período tenha sido $d_1 = 200$, assumindo que a previsão seja $F_1 = 200$ e $\alpha = 0,1$, a previsão para o próximo período será:

$$F_2 = (0,1)(200) + (0,9)(200) = 200$$

Supondo que a demanda em $t = 2$ tenha sido de 250. A previsão para o próximo período será:

$$F_3 = (0,1)(250) + (0,9)(200) = 205$$

Exemplo A-04: Método de Holt

Assumindo $\alpha = \beta = 0,1$, inicialmente deve-se estimar S_0 e G_0 . Supondo $S_0 = 200$ e $G_0 = 10$, a previsão para $t = 1$ será:

$$F_1 = 200 + 10 = 210$$

Considerando que no período $t = 1$ a demanda tenha sido $d_1 = 200$, a previsão para o período $t = 2$ será:

$$S_1 = 0,1(200) + 0,9(210) = 209$$

$$G_1 = 0,1(209 - 200) + 0,9(10) = 9,9$$

$$F_2 = 209 + 9,9 = 218,9$$

Exemplo A-05: Método de Winters

Supondo que a demanda de um item, em uma estação, tenha sido:

Período	Demanda	Período	Demanda	Período	Demanda
1	4	5	11	9	9
2	2	6	13	10	6
3	5	7	18	11	5

4
8
8
15
12
4

A estimativa fator sazonal para cada período dada por

$c_t = \left(N / \sum_{i=1}^n d_i \right) \cdot d_t$ é de $c_1 = 0,48$, $c_2 = 0,24$, $c_3 = 0,60$, $c_4 = 0,96$,
 $c_5 = 1,32$, $c_6 = 1,56$, $c_7 = 2,16$, $c_8 = 1,80$, $c_9 = 1,08$, $c_{10} = 0,72$, $c_{11} = 0,60$,
 $c_{12} = 0,48$. Assumindo que as estimativas iniciais são $S_0 = 8,3$ e $G_0 = 0$, e que as
 constantes de suavização usadas são: $\alpha = 0,2$, $\beta = 0,1$ e $\gamma = 0,5$. Para o primeiro
 período da próxima estação, $t = 13$, a previsão é:

$$F_{13} = (8,3 + 0)(0,48) = 3,98 \cong 4$$

Supondo que a demanda tenha sido $d_{13} = 5$, das equações 3-08, 3-09 e 3-10 obtêm-se:

$$S_{13} = (0,2)(5/0,48) + (0,8)(8,3) = 8,72$$

$$G_{13} = (0,1)(8,72 - 8,3) + (0,9)(0) = 0,043$$

$$c_{13} = 0,5(5/8,72) + (0,5)(0,48) = 0,53$$

A previsão para o segundo período, $t = 14$ é:

$$F_{14} = (8,72 + 0,043)(0,24) = 2,1 \cong 2$$

Exemplo A-06: Métodos de Regressão

Supondo que a demanda por um item em um determinado período seja:

Período	Demanda
1	200
2	250
3	175
4	186
5	225
Total	1036

Os parâmetros de regressão serão:

$$S_{xy} = 5[200 + (2 \cdot 250) + (3 \cdot 175) + (4 \cdot 186) + (5 \cdot 225)] - [(5 \cdot 6) / 2][1036]$$

$$S_{xy} = -70$$

$$S_{xx} = [(25 \cdot 6 \cdot 11) / 6] - [25 \cdot (6^2) / 4] = 50$$

$$b = -70 / 50 = -1.4$$

$$a = 207,2 - [-1,4 \cdot (6) / 2] = 221,4$$

$$F_t = 211,4 - (1,4 \cdot t)$$

F_t vai ser a previsão feita no período 6 para o período t , que pode ser usado para estimar qual vai ser a demanda em qualquer período posterior. A previsão para o período $t = 8$ será:

$$F_8 = 211,4 - (1,4 * 8) = 200,2$$

Porém, para calcular no período 7 a previsão para o período $t = 9$, as estimativas de a e b devem ser recalculadas, assim como a nova F_t , que será usada

então para o cálculo da previsão.

Exemplo A-07: Modelo de Box-Jenkins

Supondo que as vendas de um determinado produto estejam representadas na tabela abaixo (todas as tabelas de dados são do tipo “*Read-Across*”, ou seja, a seqüência dos dados é da esquerda para direita, do começo para o fim da linha):

TABELA A.1 – Dados do problema.

Série temporal com 300 observações														
592	1208	1864	2508	3160	3792	4419	5023	5626	6250	6903	7564	8223	8900	9569
10226	10823	11304	11785	12252	12724	13339	13940	14514	15102	15648	16212	16725	17217	17839
18463	19094	19718	20342	20966	21563	22167	22802	23431	24044	24562	25131	25676	26205	26718
27215	27767	28389	28974	29502	30022	30542	31044	31556	32092	32636	33196	33772	34347	34915
35502	36078	36643	37219	37804	38381	38974	39513	40044	40634	41237	41853	42430	42977	43529
44081	44657	45277	45917	46517	47100	47692	48241	48802	49399	49992	50601	51214	51855	52499
53127	53763	54387	54979	55591	56219	56843	57491	58127	58767	59264	59777	60298	60779	61348
61942	62521	63041	63576	64082	64550	65074	65594	66168	66664	67204	67711	68272	68837	69414
70012	70617	71211	71701	72214	72740	73283	73889	74509	75115	75743	76351	76971	77585	78169
78745	79309	79918	80563	81184	81761	82318	82855	83384	83921	84476	85028	85647	86275	86889
87493	88097	88737	89361	90017	90668	91313	91938	92575	93156	93669	94182	94695	95201	95679
96183	96783	97397	97989	98603	99223	99839	100478	101095	101724	102333	102902	103516	104157	104784
105411	106026	106626	107214	107806	108418	109048	109688	110321	110961	111586	112211	112828	113437	114038
114663	115288	115904	116519	117121	117688	118280	118916	119548	120130	120647	121210	121773	122350	122947
123540	124102	124705	125255	125769	126325	126893	127501	128133	128769	129402	129994	130491	130996	131565
132142	132719	133280	133863	134435	134997	135587	136187	136812	137424	138024	138648	139272	139909	140534
141171	141768	142329	142878	143423	144000	144585	145168	145738	146294	146832	147364	147920	148520	149128
149744	150342	150902	151407	151895	152396	152885	153390	153939	154520	155129	155742	156374	157006	157648
158295	158951	159655	160339	161039	161723	162410	163050	163698	164366	165031	165680	166321	166934	167559
168193	168882	169580	170277	170954	171602	172220	172852	173500	174136	174764	175364	175956	176560	177197

Fonte: JOHNSON & MONTGOMERY (1974)

Percebe-se que a série apresenta um comportamento explosivo. A função de autocorrelação amostral para a série é calculada pela seguinte fórmula:

$$\rho_k = \frac{E[(x_t - \mu) \cdot (x_{t+k} - \mu)]}{\sigma_x^2}, k = 0, 1, \dots \quad (\text{A-01})$$

onde σ_x^2 é a variância da série de dado e μ é a média aritmética dos valores da série. Os resultados estão na TABELA A.2.

TABELA A.2 – Função de autocorrelação amostral da série

0,99	0,98	0,97	0,97	0,96	0,95	0,95	0,94	0,93	0,92	0,92	0,91	0,90	0,90	0,89
------	------	------	------	------	------	------	------	------	------	------	------	------	------	------

0,88	0,87	0,87	0,86	0,85	0,84	0,84	0,83	0,82	0,81	0,81	0,80	0,79	0,78	0,78
0,77	0,76	0,75	0,74	0,74	0,73	0,72	0,71	0,70	0,70	0,69	0,68	0,67	0,66	0,66
0,65	0,64	0,63	0,62	0,61	0,60	0,59	0,59	0,58	0,57	0,56	0,55	0,54	0,53	0,52
0,51	0,50	0,50	0,49	0,48	0,47	0,46	0,45	0,44	0,43	0,42	0,41	0,40	0,39	0,38

Plotando os resultados em um gráfico observa-se um comportamento: “*die down slowly*” e conclui-se que a série não apresenta um comportamento estacionário:

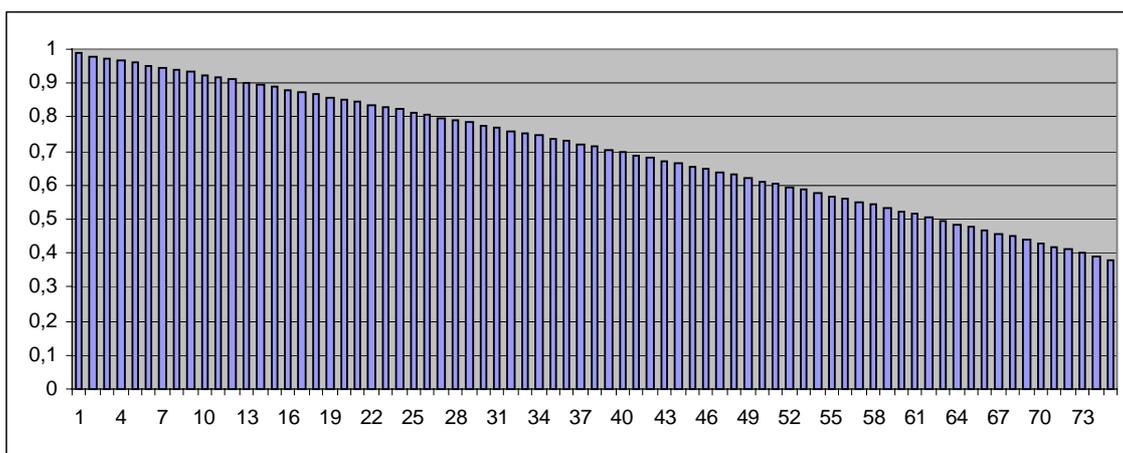


FIGURA A.1 – Gráfico da função de autocorrelação.

Assim, como não se observa um comportamento estacionário, é necessária a utilização de técnicas de diferenciação para produzir “estacionaridade” na série. A diferenciação deve ser aplicada quantas vezes forem necessárias, até produzir a “estacionaridade”, e é dada por:

$$\nabla x_t = x_t - x_{t-1} \quad (\text{A-02})$$

A primeira diferenciação da série é mostrada na TABELA A.3.

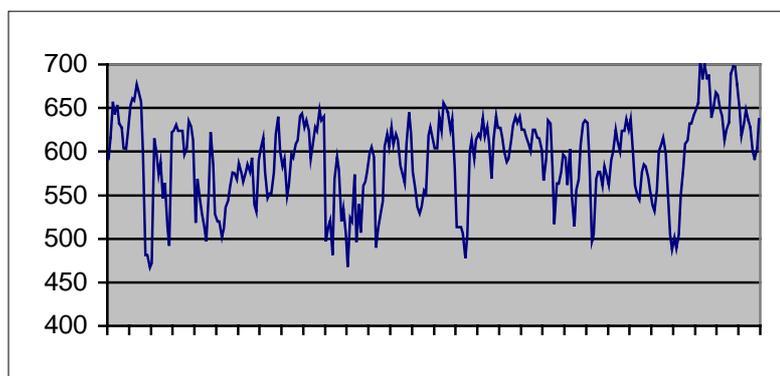
TABELA A.3 – Resultados da diferenciação da série.

Primeira Diferenciação														
592	616	656	644	652	632	627	604	603	624	653	661	659	677	669
657	597	481	481	467	472	615	601	574	588	546	564	513	492	622
624	631	624	624	624	597	604	635	629	613	518	569	545	529	513
497	552	622	585	528	520	520	502	512	536	544	560	576	575	568

587	576	565	576	585	577	593	539	531	590	603	616	577	547	552
552	576	620	640	600	583	592	549	561	597	593	609	613	641	644
628	636	624	592	612	628	624	648	636	640	497	513	521	481	569
594	579	520	535	506	468	524	520	574	496	540	507	561	565	577
598	605	594	490	513	526	543	606	620	606	628	608	620	614	584
576	564	609	645	621	577	557	537	529	537	555	552	619	628	614

(... continua...)

604	604	640	624	656	651	645	625	637	581	513	513	513	506	478
504	600	614	592	614	620	616	639	617	629	609	569	614	641	627
627	615	600	588	592	612	630	640	633	640	625	625	617	609	601
625	625	616	615	602	567	592	636	632	582	517	563	563	577	597
593	562	603	550	514	556	568	608	632	636	633	592	497	505	569
577	577	561	583	572	562	590	600	625	612	600	624	624	637	625
637	597	561	549	545	577	585	583	570	556	538	532	556	600	608
616	598	560	505	488	501	489	505	549	581	609	613	632	632	642
647	656	704	684	700	684	687	640	648	668	665	649	641	613	625
634	689	698	697	677	648	618	632	648	636	628	600	592	604	637
634	689	698	697	677	648	618	632	648	636	628	600	592	604	637



Os dados da TABELA A.3 estão *plotados* no gráfico da FIGURA A.2.

FIGURA A.2 – Gráfico da primeira diferenciação.

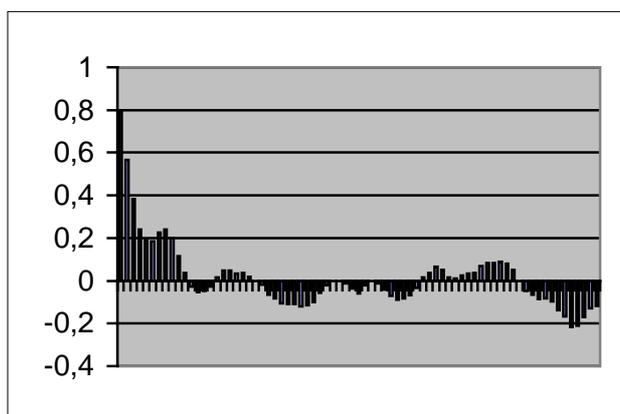
Observando-se o gráfico percebe-se que o comportamento “não-estacionário” da série foi eliminado pela diferenciação isso é confirmado pela função de autocorrelação amostral, calculada pela equação A-01. Os resultados estão na tabela abaixo:

TABELA A.4 – Função de autocorrelação amostral para a série diferenciada.

0,79	0,57	0,38	0,24	0,19	0,18	0,23	0,24	0,20	0,11	0,04	-0,03	-0,05	-0,05	-0,03
------	------	------	------	------	------	------	------	------	------	------	-------	-------	-------	-------

0,02	0,05	0,05	0,03	0,04	0,02	0,00	-0,02	-0,07	-0,08	-0,11	-0,11	-0,11	-0,12	-0,12
-0,10	-0,06	-0,02	0,00	0,00	-0,01	-0,04	-0,06	-0,02	0,00	-0,01	-0,04	-0,07	-0,09	-0,08
-0,07	-0,03	0,02	0,04	0,06	0,05	0,02	0,01	0,02	0,03	0,04	0,07	0,08	0,08	0,09
0,08	0,05	0,00	-0,05	-0,06	-0,08	-0,08	-0,10	-0,14	-0,17	-0,22	-0,21	-0,17	-0,13	-0,12

Os dados da TABELA A.4 estão *plotados* no gráfico da FIGURA A.3, que



apresenta comportamento de “*dies down quickly*”.

FIGURA A.3 – Gráfico da função de autocorrelação da primeira diferenciação da série.

A seguir é calculada a função de autocorrelação parcial amostral pela seguinte fórmula:

$$\nabla x_t = x_t - x_{t-1} \quad (\text{A-03})$$

Os dados resultantes estão na tabela abaixo:

TABELA A.5 – Função de autocorrelação parcial para a série diferenciada.

0,7901	-0,151	0,117	-0,167	0,2712	-0,23	0,3908	-0,48	0,4936	-0,706	0,7628	-0,914	1,0936	-1,2	1,437
-1,5628	1,675	-2,02	2,169	-2,375	2,32	-2,31	2,41	-2,409	3,2819	-3,026	3,8631	-3,215	2,632	-2,167
1,6807	-1,615	1,219	-1,273	1,0772	-0,93	0,9465	-0,75	0,8762	-0,742	0,6074	-0,629	0,4597	-0,553	0,44
-0,4673	0,455	-0,32	0,49	-0,349	0,571	-0,585	0,76	-0,733	0,6898	-0,6998	0,6861	-0,764	0,683	-0,683
0,6588	-0,661	0,682	-0,698	0,822	-0,85	0,9267	-0,84	0,7868	-0,706	0,5879	-0,551	0,4835	-0,478	0,312

O comportamento da função de autocorrelação parcial está apresentado na FIGURA A.4.

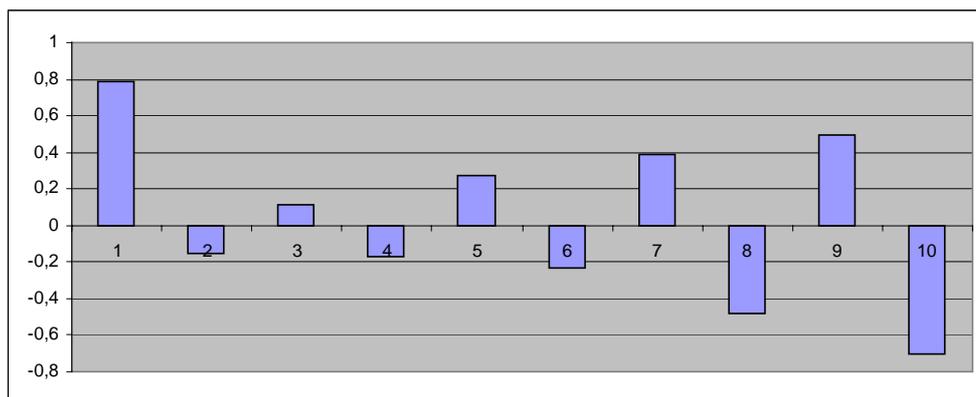


FIGURA A.4: Gráfico da função de autocorrelação parcial para a série diferenciada.

O comportamento apresentado pelo gráfico da FIGURA A.4 é de “*cut off*”. Como foi necessário um grau de diferenciação, deve-se selecionar um modelo apropriado da classe: ARIMA(p,1,q). A função de autocorrelação amostral apresenta comportamento “*die down quickly*” e a função de autocorrelação parcial amostral apresenta comportamento “*cut off*”, indicando, pela TABELA 3.1, um processo AR (2), representado pela equação A-04.

$$\tilde{w}_t = \varepsilon_t + \phi_1 + \tilde{w}_{t-1} + \phi_2 \tilde{w}_{t-2} \quad (\text{A-04})$$

onde \tilde{w}_t , são os valores de w e $\nabla x_t = w_t$ corrigidos pela média. Obtendo as estimativas de mínimos quadrados acha-se os parâmetros do modelo:

$$\begin{aligned}\phi_1 &= 0.93 \\ \phi_2 &= -0.17\end{aligned}$$

Como foi necessário o uso de diferenciação, o processo escolhido é ARIMA (2,1,0), dado pela equação A-05.

$$x_t = x_{t-1} + 0.93(x_{t-1} - x_{t-2}) - 0.17(x_{t-2} - x_{t-3}) + \varepsilon_t \quad (\text{A-05})$$

Os resultados calculados para x_t estão na TABELA A.6.

TABELA A.6 – Resultados para a série, considerando o modelo ARIMA (2,1,0)

184	139	165	135	150	128	148	166	175	160	155	177	151	150	100
37	135	101	119	255	109	120	156	97	156	81	111	252	129	156
143	151	150	123	155	175	141	136	55	191	104	119	114	110	177
193	100	90	128	126	107	134	145	133	145	148	135	131	157	127
129	148	145	131	156	86	131	188	145	156	107	115	141	132	156
178	161	110	134	152	98	151	169	133	159	147	174	152	138	161
139	120	168	159	144	174	139	159	10	160	128	84	210	147	123
83	150	97	88	175	112	179	51	176	89	181	129	147	157	147
133	40	158	132	141	190	149	132	170	127	161	141	118	137	128
182	175	125	109	126	117	124	136	146	127	200	146	135	140	147
181	131	184	147	151	136	165	95	81	135	123	116	95	145	213
142	123	168	150	144	172	127	164	129	110	188	167	135	153	138
135	135	147	161	161	158	145	160	137	153	142	141	140	170	146
141	148	135	112	167	182	141	102	83	181	127	149	156	136	112
181	85	105	171	138	174	163	152	149	70111	-135046	77143	-11716	134	137
122	159	125	129	165	147	167	133	137	170	146	163	139	164	111
114	129	130	163	141	137	127	125	118	126	153	173	145	153	128
109	86	114	133	106	135	162	156	162	145	165	148	162	157	163
204	141	184	149	170	117	170	174	154	144	150	127	164	157	206
165	165	147	137	130	167	165	141	147	124	141	155	176		

Em seguida são calculados os resíduos gerados pelo modelo, pela equação A-06 e, então é calculada a função de autocorrelação amostral para os resíduos, o que é mostrado na TABELA A.7.

$$e_t = x_t - \hat{x}_t \quad (\text{A-06})$$

TABELA A.7 – Função de autocorrelação amostral dos resíduos gerados pelo modelo

-0,713	0,241	-0,029	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000
-0,001	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000
0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000
0,000	0,000	0,000	0,000	-0,001	0,000	0,000	0,000	0,000	0,000	-0,001	0,000	0,000	0,000	0,000
0,000	0,000	0,000	-0,001	0,000	0,000	0,000	0,000	0,001	0,000	0,000	0,000	0,000	0,000	0,000

Os resultados da TABELA A.7 estão *plotados* no gráfico da na FIGURA A.5.

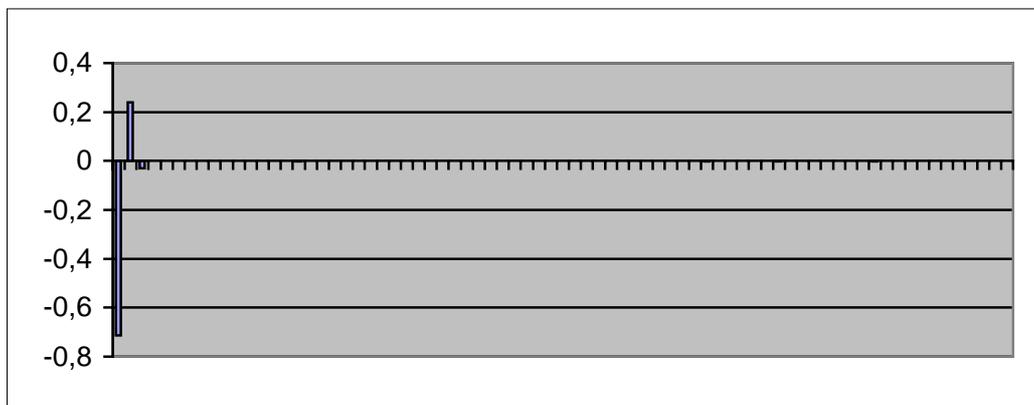


FIGURA A.5 – Gráfico da função de autocorrelação dos resíduos gerados pelo modelo.

Observa-se no gráfico da FIGURA A.5 um comportamento de ruído branco, ou seja, os valores variam pouco e em torno de zero, demonstrando que o ARIMA(2,1,0) é um modelo apropriado. As previsões podem ser obtidas pela equação A-07.

$$F_T = x_{T-1} + 0.93(x_{T-1} - x_{T-2}) - 0.17(x_{T-2} - x_{T-3}) \quad (\text{A-07})$$

As previsões para os próximos 14 períodos estão na TABELA A.8.

TABELA A.8: Previsões para os próximos 14 períodos.

T	Previsão em t
301	177892,09
302	178646,81
303	179466,87
304	210498,84
305	269662,59
306	360152,79
307	489724,96
308	670915,85
309	922031,99
310	1268874,46
311	1747329,48
312	2407044,89
313	3316563,74
314	4570440,38

Exemplo A-08: Modelos Econométricos

Examinando um caso de um aeroporto na ilha de Rhodes, na Grécia, por um período, observou-se os níveis de demanda do aeroporto dados pela FIGURA A.6.

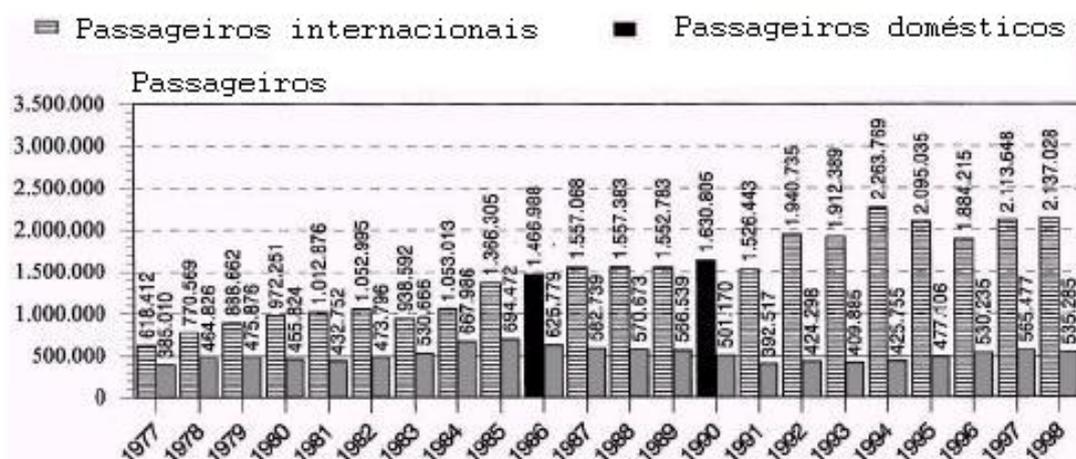


FIGURA A.6 – Demanda no aeroporto de Rhodes

Após análise, se concluiu que a variável crítica que influencia demanda dos passageiros internacionais é a taxa de câmbio, ou seja, a equivalência da moeda grega (dracma) com as outras moedas (dos países de origem dos passageiros). Foi quantificado que por um indicador de equivalência que representa a evolução da equivalência da taxa de câmbio estrangeira em relação à moeda grega. Identificando a evolução da taxa como sendo:

Ano	1986	1987	1988	1989	1990	1991	1992	1993	1994	1995	1996	1997
Taxa de equivalência	100.0	111.3	122.2	127.4	137.6	158.8	178.0	186.5	195.9	192.1	172.7	202.9

o modelo econométrico estimado foi:

$$P = 1/2 \cdot [(e^{(0.0039953 \cdot D)} \cdot 925.332) + D \cdot (0.174746 \cdot D^2 - 43.2117 \cdot D + 7548.47) + 906.696]$$

onde P é o número de passageiros internacionais do aeroporto e D a taxa de câmbio grega anual comparado com as taxas de câmbio dos países de origem dos passageiros do aeroporto.

O método de simulação consiste na definição da previsão de demanda em função de um determinado número de variáveis e no desenvolvimento de um programa de computador que vai simular essas variáveis que influenciarão a demanda e, conseqüentemente sua previsão. O programa simula uma série de valores para as variáveis e quais os impactos dessas variações no valor da previsão. Os resultados são *plotados* em gráficos e a partir de análises, o melhor valor é escolhido.

Considerando um exemplo que tem como variáveis:

- ✓ Quantidade (n) de consumidores potenciais no mercado;
- ✓ Tamanho (h) dos consumidores (tamanho dos centros de distribuição, por exemplo);
- ✓ Frequência (f) com que os pedidos são feitos;
- ✓ Variedade (v) do tamanho dos pedidos;
- ✓ Correlação (ρ_{ij}) entre dois pedidos, ou seja, se um influencia o outro;

Os valores de simulação podem ser (por alguma estimativa ou devido à determinada influência que se queira estudar):

- ✓ $n = 5, 20$ e 50 ;
- ✓ $h = 1$ (mercado homogêneo) e $h = 8.07$ (mercado altamente heterogêneo);
- ✓ $f = 0.05, 0.1$ e 0.2 (número de pedidos por um período e é considerado igual para todos os consumidores);
- ✓ $v = 0$ (sem variação, ou seja, o cliente pede sempre a mesma quantidade) e $v = 0.5$ (há variação);
- ✓ $\rho_{ij} = 0$ (sem correlação) e $\rho_{ij} = 0.22$ e 0.48 .

Pode-se ainda considerar outras variáveis que podem influenciar o modelo, como por exemplo:

- ✓ Autocorrelação (ρ_t): qual a correlação entre duas demanda consecutivas, por exemplo $\rho_t = 0$ e $\rho_t = 0.4$;
- ✓ Taxa com que os consumidores que antecipam seus pedidos (EB), com $EB = 20\%$ e 40% ;

- ✓ Disponibilidade de informações que permite estimar os pedidos futuros de um consumidor (EI), com EI = baixa, média e alta.

A demanda é modelada segundo algum critério (WHYBARK & WILLIAMS (1976), WEMMERLÖV (1986) e MCCLELLAND & WAGNER (1988)). E o modelo é construído. Por exemplo, a simulação pode ser feita para:

- ✓ Simular o processo de compra de um único consumidor;
- ✓ Agregar os pedidos de um único consumidor para obter a demanda para o Programa Mestre de Produção (MPS);
- ✓ Estimar a demanda para alguns períodos futuros segundo algumas técnicas previamente definidas;
- ✓ Calcular e comparar os erros médios das técnicas.

Normalmente a simulação é feita para as possíveis combinações entre as variáveis e os resultados podem ser *plotados* em gráficos para análises e comparações.

Um exemplo de gráfico para análise poderia ser:

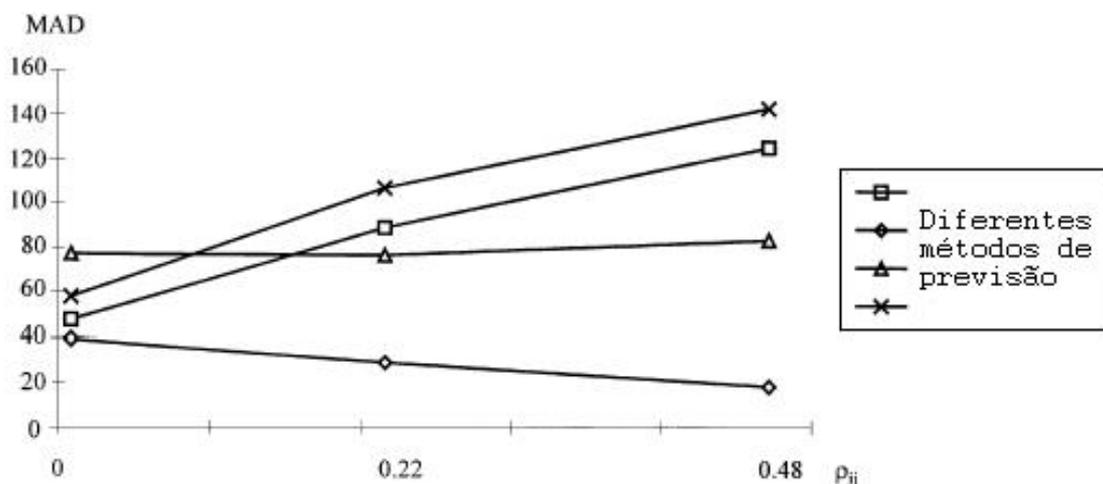


FIGURA A.7 – Exemplo de gráfico de simulação

Mais informações, sobre esse exemplo, pode ser obtidas em VERGANTI & ZOTTERI (1999).

Exemplo A-10: Focus Forecasting

Considerando 5 métodos de previsão como:

- ✓ Met. 01: Demanda do último período;
- ✓ Met. 02: 90% da demanda do último período;
- ✓ Met. 03: 110% da demanda do último período;
- ✓ Met. 04: Média móvel dos últimos três períodos;
- ✓ Met. 05: Suavização exponencial simples.

Esses métodos são usados para dar a previsão no período t , e então é calculada a diferença absoluta entre a demanda e a previsão, resultando em:

Método	F_t	d_t	$t F_t - d_t $
Met. 01	52.0	58	6.0
Met. 02	46.8	58	11.2
Met. 03	57.2	58	0.8
Met. 04	47.3	58	10.7
Met. 05	49.8	58	8.2

Como a menor diferença absoluta foi obtida pelo método de 110% da demanda do último período, este será o método adotado para realizar a previsão no método $t + 1$

Exemplo A-11: Redes Neurais

O procedimento computacional de uma rede BP é descrito na equação A-08.

$$Y_j = f\left(\sum_i w_{ij} X_{ij}\right) \quad (\text{A-08})$$

onde Y_j é a saída do nó j , $f(\circ)$ é a função de transferência, w_{ij} o peso de conexão entre o nó j e o nó i na camada anterior e X_i o sinal de entrada que vem do nó i da camada anterior. O algoritmo de BP tenta aumentar a performance da rede reduzindo o erro total,

reduzindo os pesos e minimizando o quadrado dos erros, o que pode ser calculado pela equação A-09.

$$E = 1/2 \sum_p \sum_j [O_j^p - Y_j^p]^2 \quad (\text{A-09})$$

onde E é o quadrado dos erro, p o índice do padrão (que a rede é treinada para reconhecer), O é a saída real (objetivo) e Y a saída da rede. Sendo $\Delta w_{ij}^p(n)$ o peso sináptico de conexão da saída do neurônio i à entrada do neurônio j na p -ésima camada durante a n -ésima iteração. O ajuste de $\Delta w_{ij}^p(n)$ para $w_{ij}^p(n)$ é dado por:

$$\Delta w_{ij}^p(n) = -\eta \cdot (n) \cdot \frac{\partial E(n)}{\partial w_{ij}^p} \quad (\text{A-10})$$

onde $\eta(n)$ é a taxa de aprendizagem. Pela regra da cadeia, o peso da rede com a regra de aprendizagem é dado por:

$$\Delta w_{ij}^p(n) = \eta \cdot (n) \cdot \delta_j^p(n) \cdot X_i^{p-1}(n) + m(n) \cdot \Delta w_{ij}^p(n-1), \quad (\text{A-11})$$

$$\Delta w_{ij}^p(n+1) = w_{ij}^p(n) + \Delta w_{ij}^p(n+1) \quad (\text{A-12})$$

onde $\delta_j^p(n)$ é o n -ésimo sinal de erro, no j -ésimo neurônio da p -ésima camada e $X_i^{p-1}(n)$ é o sinal de saída do neurônio i da camada anterior e m é o fator de momento. As constantes η, m determinam o começo do treinamento e a velocidade e estabilidade da rede.

Exemplo A-12: Cenários

O primeiro passo na construção de um cenário é definir qual a variável a ser projetada Y e qual sua unidade de medida. A seguir devem ser identificados os fatores que influenciam a projeção, que são X_1, X_2, \dots, X_n . Considerando um caso em que Y diz respeito à capacidade das fontes de energia solar instaladas em 2005. Exemplos dos fatores X :

$$X_1 = \text{Custo da energia solar no ano 2005}$$

X_2 = **Demanda de energia**

X_3 = **Custo de fontes alternativas de energia**

X_4 = **Embargo do óleo**

X_5 = **Diminuição da energia nuclear**

X_6 = **Tendência de descentralização da sociedade**

Os fatores selecionados X_1, X_2, \dots, X_n devem refletir todos aspectos relevantes sobre o futuro e devem estar bem definidos. Com o auxílio de um especialista, análise de dados históricos ou analogias, combinações entre níveis específicos desses fatores e as projeções de Y resultantes podem ser feitas. Técnicas de regressão linear podem ser usadas para estabelecer o relacionamento entre os fatores X_1, X_2, \dots, X_n e a projeção Y . A projeção de Y irá variar de acordo com a combinação dos fatores e seus níveis, o que é chamado de cenário. Além de saber o resultado da combinação de alguns fatores, os tomadores de decisão podem estar interessados em quais cenários futuros têm mais chance de ocorrer. Para tanto, deve-se determinar a probabilidade de ocorrência de um determinado fator e então combinar a probabilidade de todos os fatores envolvidos em uma projeção, para então se determinar qual a probabilidade do cenário. Por exemplo, se existem apenas dois fatores e cada fator pode assumir dois valores, sendo que se um ocorre, o outro valor não. Assim existem quatro possíveis cenários. Se a probabilidade de ocorrência do primeiro fator é de 0.8 e do segundo é de 0.5, a probabilidade de ocorrerem os dois fatores em um cenário é de 0.40, assumindo que os fatores são independentes.

Exemplo A-13: Análise de Impacto Cruzado

Uma empresa pretende lançar um tipo de painel solar (usado para produzir energia), mas a produção por um novo processo se a demanda crescer pelo menos 30% ao ano, nos próximos 3 anos. Considerando 3 eventos: motor elétrico mais eficiente (MEM), descontos em impostos pelo uso de energia solar (GTC) e aumento nos custos de outros combustíveis (HCF). Se um novo motor é criado, menor vai ser a demanda por energia alternativa, baixando seu custo. Redução do uso de combustível fóssil melhora as condições

ambientais e, portanto, aumentando a chance de descontos nos impostos. A matriz vai analisar esses impactos. A matriz é preenchida por especialistas.

	MEM	GTC	HCF
MEM	—	↓	↓
GTC	↑	—	↑
HCF	↑	—	—

A probabilidade de um motor mais eficiente ser desenvolvido é de 0.2. Se houverem descontos nos impostos, mais pesquisadores tentarão desenvolver esse motor, subindo a probabilidade de criação para 0.3. Aumento nos custos de combustíveis alternativos também estimula a pesquisa e a probabilidade de criação sobe para 0.4. A matriz de probabilidades pode ser representada da seguinte forma:

	Prob.	MEM	GTC	HCF
MEM	0.2	—	0.2	0.6
GTC	0.3	0.3	—	0.7
HCF	0.8	0.4	—	—

A matriz pode ser simulada para explorar várias saídas. O uso de diferentes probabilidades pode determinar a sensibilidade dos resultados.

Exemplo A-14: Survey de Mercado

Considerando um caso onde um determinado hospital quer saber se deve ou não comprar um determinado tipo de termômetro, com uma nova tecnologia de medição da temperatura do corpo, chamado “termômetro frio” e qual a demanda por esse tipo de aparelho (quantidade de casos em que pacientes apresentam febre) para determinar a quantidade a ser adquirida. Foi elaborado um documento para medição da temperatura nos pacientes. Três *surveys* foram conduzidas:

- ✓ Agosto de 2000: avaliação inicial com o uso do novo termômetro.

- ✓ Setembro de 2000: após treinamento sobre o uso.
- ✓ Dezembro de 2000: após a remoção da nova tecnologia e uso de termômetros com outras tecnologias.

Para registro de dados de cada paciente, era necessária a medição de temperatura em 2 ou 3 dias seguidos. Foi feita uma análise estatística para decidir sobre a aquisição.

O primeiro levantamento mostrou um número muito baixo de pacientes com febre e em alguns casos que a leitura da temperatura com termômetros tradicionais, a leitura feita pelo “termômetro frio” indicava uma temperatura menor do que a que o paciente realmente apresentava. O produtor do termômetro alegou que os erros de medição eram ocasionados por mau uso dos termômetros. Porém em um segundo levantamento, após treinamento dado pelo produtor, os erros de medição em relação à medição feita com instrumentos tradicionais, pouco diminuiu, indicando que o problema era com os “termômetros frios”. Em um terceiro levantamento, após a retirada dos “termômetros frios”, foram introduzidos termômetros eletrônicos orais e anais. A taxa de erro foi muito pequena.

Após análise dos dados, foi constatado que o problema dos erros era com a nova tecnologia de “termômetro frio” e o tratamento estatístico indicou qual a necessidade de novos termômetros.

Exemplo A-15: *Delphi*

O método *Delphi* foi aplicado para prever a demanda sobre futuros produtos potenciais na indústria de máquinas de Taiwan no ano de 2010. A pesquisa foi conduzida entre Setembro de 1998 e Abril de 1999. Os passos foram os seguintes:

1. Inicialmente o questionário foi desenvolvido, contendo perguntas sobre quais oportunidades futuras, quais os possíveis problemas, indicação de índices de necessidade para determinadas tecnologias, etc.
2. Uma lista com especialistas foi elaborada e eles foram convidados. Para ser considerado em especialista o profissional deveria ter mais de 10 anos de experiência, ter pelo menos grau de bacharel.
3. O primeiro questionário foi aplicado entre 14 de Outubro e 15 de Novembro de 1998. Os especialistas tiveram acesso a informações como taxas de exportação de

máquinas, dados sobre crescimento e produção anual. Cada especialista formulou sua previsão, sem que houvesse contato entre eles.

4. O segundo questionário foi aplicado entre 01 e 31 de Dezembro de 1998. Os pesquisadores sumarizaram os resultados do primeiro questionário e os resultados foram colocados em tabelas. Baseados nesses resultados os especialistas formularam outras previsões.
5. O terceiro questionário foi aplicado entre 16 de Janeiro e 10 de Fevereiro de 1999, baseado nas idéias diferentes existentes nos resultados do segundo questionário.

Uma conclusão foi obtida a partir do terceiro questionário.

OBSERVAÇÃO: Os exemplos ilustrados neste apêndice foram retirados da bibliografia referenciada no Capítulo 3.

APÊNDICE B – PESQUISA SOBRE PREVISÃO DE DEMANDA NAS EMPRESAS

O questionário foi enviado via e-mail para um grupo de pesquisa sobre ERP e para um grupo sobre Sistemas de Informação. Alguns dos participantes dos grupos encaminharam para empresas com as quais tinham contato e empresas 10 responderam os e-mails com o questionário preenchido.

As questões estão descritas na TABELA B.1 e parte das respostas estão na TABELA B.2. A idéia da pesquisa é fazer um levantamento de como as empresas fazem o cálculo da previsão de demanda e se utilizam os módulos do ERP para isso. Apenas uma das empresas diz que vai implantar o módulo de previsão de demanda da JD Edwards. As demais empresas realizam a previsão de demanda com pouca ou nenhuma automatização, sem a utilização de um sistema específico para a função. Embora negligenciada, as empresas que produzem para estoque, consideram a previsão de demanda importante, tendo impacto direto no desempenho da gestão da produção e dos estoques.

TABELA B.1 – Questionário

QUESTIONÁRIO	
01	Nome na empresa
02	Localização
03	Ramo de atividade e mercado atingido
04	Número de funcionários
05	Possui ERP, MRP ou outro sistema de administração da produção? Qual? Em caso negativo, há projeto para instalação? Quando?
06	Como é feita a previsão de demanda? Há projeto de melhoria nesse processo?
07	Qual o papel da previsão de demanda para a empresa?

TABELA B.2 – Respostas

Atividade	Número de funcionários	ERP	Como é feita a Previsão de Demanda
Peças injetadas de plástico para indústria automotiva	300	SAP	É planejada de acordo com o nível de produção do cliente
Bebidas	1180	SAP	Baseada no histórico de vendas, campanhas promocionais e pedidos dos clientes
Bens de Capital	950	Baan	Não há (produção contra pedido)
Ramo de floresta e jardim	43	BPCS	Previsão baseada nos dados históricos e necessidade de mercado
Eletromecânico	6500	MRP II	Baseado em histórico de consumo
Móveis	270	ERP (próprio ²)	Feita com base na curva ABC
Embalagens <i>PET</i>	400	Magnus	Feita através de gestão mercadológica
Calçados	1200	ERP (próprio)	Analisa dados históricos a partir de gráfico
Indústria química	350	Visual Omega	Não existe (produção contra pedido)

² ERP desenvolvido por equipe própria.