

**ESCOLA POLITÉCNICA DA UNIVERSIDADE DE SÃO PAULO**  
**DEPARTAMENTO DE ENGENHARIA DE PRODUÇÃO**

**TRABALHO DE FORMATURA**

**APLICAÇÃO DE MODELOS DE PREVISÃO DE DEMANDA EM**  
**EMPRESA COM VENDAS SAZONAIS**

**AUTOR: LEANDRO KIYUZATO**

**ORIENTADOR: PROF. DR. MIGUEL CEZAR SANTORO**

**2001**

HF. 2001  
K.658a

## ***Agradecimentos***

A Deus e a minha Família, por me darem condições de chegar até aqui.

Ao Prof. Santoro, por sua valiosa orientação durante o desenvolvimento deste trabalho.

A Andrea Yaegashi e toda a equipe de Planejamento Logístico, pela experiência e aprendizado profissional e pessoal, proporcionados durante meu período de Estágio na Unilever Brasil Kibon.

## ***Sumário***

Este trabalho consiste na aplicação de Modelos de Quantitativos de Previsão de Demanda baseados em Séries Temporais, na Unilever Brasil Kibon, cujas vendas apresentam clara característica de Sazonalidade. A partir da definição da Metodologia de desenvolvimento deste Trabalho, faz-se uma breve descrição da Empresa e do problema inicialmente encontrado, a fim de se definir claramente os objetivos e a abrangência deste Trabalho.

Em seguida, é feita uma pesquisa bibliográfica, visando encontrar os modelos de Previsão mais adequados às necessidades da Empresa. Os modelos são testados para que sejam selecionados os mais adequados para cada item específico e implementados em planilhas eletrônicas. Faz-se também uma preparação para futuras implementações de sistemas dedicados de Previsão de Demanda, definindo-se possíveis tabelas e algoritmos.

Por fim, nas considerações finais são abordados aspectos organizacionais observados na mudança do sistema de Previsão de Demanda na Unilever Brasil Kibon.

## ***Índice Analítico***

<b>1. INTRODUÇÃO</b>	<b>1</b>
1.1. RESUMO DO TRABALHO	1
<b>2. METODOLOGIA</b>	<b>3</b>
2.1. DESCRIÇÃO DAS PRINCIPAIS ETAPAS DE DESENVOLVIMENTO DO TRABALHO	3
<b>3. APRESENTAÇÃO DA EMPRESA</b>	<b>6</b>
3.1. TIPO DE NEGÓCIO	6
3.2. PLANTAS NO BRASIL	6
3.3. PORTFÓLIO DE PRODUTOS	6
3.5. UNIDADES DE NEGÓCIO - UNILEVER BRASIL	7
3.6. ESTRUTURA ORGANIZACIONAL INTERNA - UNILEVER BRASIL KIBON	8
3.7. DETALHAMENTO DAS FUNÇÕES DA ÁREA DE PLANEJAMENTO	9
3.7.1. FUNÇÕES DA ÁREA DE PLANEJAMENTO DE DEMANDA	9
3.8. DESCRIÇÃO DAS ATIVIDADES DE ESTÁGIO	10
<b>4. DESCRIÇÃO DO PROBLEMA E DEFINIÇÃO DOS OBJETIVOS DO PROJETO</b>	<b>11</b>
4.1. MECANISMO ATUAL DE PREVISÃO DE DEMANDA	11
4.1.1. ESTRUTURA DA PREVISÃO DE DEMANDA	11
4.1.2. PARTICIPANTES DO PROCESSO DE ESTIMATIVA	12
4.1.3. DESCRIÇÃO DO PROCESSO DE ESTIMATIVA	12
4.1.4. ANÁLISE DO PROCESSO DE ESTIMATIVA	13
4.2. DESCRIÇÃO DOS OBJETIVOS DO TRABALHO	13
4.3. IMPACTOS DO PROCESSO DE ESTIMATIVA / RELEVÂNCIA DO TRABALHO	14
4.4. ABRANGÊNCIA DO TRABALHO	16
<b>5. REVISÃO BIBLIOGRÁFICA – MODELOS DE PREVISÃO DE DEMANDA</b>	<b>20</b>
5.1. TIPOS DE PREVISÃO	20

<b>5.2. SÉRIES TEMPORAIS: COMPONENTES BASE, TENDÊNCIA, SAZONALIDADE, CICLICIDADE</b>	<b>21</b>
<b>5.3. MEDIDAS DE ERRO DE PREVISÃO</b>	<b>22</b>
5.3.1. OBJETIVOS DE UM INDICADOR DE DESEMPENHO – CONCEITO DE DESVIO	22
5.3.2. INDICADORES DE DESEMPENHO EM USO NA UNILEVER BRASIL KIBON	25
<b>5.4. ESTATÍSTICA U DE THEIL</b>	<b>27</b>
<b>5.5. INTERVALOS DE CONFIANÇA DAS PREVISÕES</b>	<b>28</b>
<b>5.6. SÉRIES TEMPORAIS – PRINCÍPIOS DE DECOMPOSIÇÃO</b>	<b>29</b>
<b>5.8. ETAPAS PARA APLICAÇÃO DE UM MODELO DE PREVISÃO</b>	<b>30</b>
<b>5.9. ABORDAGENS PARA PREVISÃO DE DEMANDA – SÉRIES TEMPORAIS</b>	<b>33</b>
5.9.1. MÉDIA	33
5.9.2. MÉTODOS DE SUAVIZAÇÃO EXPONENCIAL	35
5.9.3. MÉTODO BASEADO EM SÉRIES DE FOURIER	42
<b>5.10. TRACKING</b>	<b>45</b>
5.10.1. MODELOS DE RESPOSTA ADAPTATIVA	45
5.10.2. TRACKING SIGNAL	46
<b>5.11. MODELOS DE PREVISÃO CAUSAIS</b>	<b>46</b>
5.11.1. REGRESSÃO LINEAR SIMPLES	47
5.11.2. REGRESSÃO LINEAR MÚLTIPLA	49
<b>5.12. MODELOS AVANÇADOS DE PREVISÃO DE DEMANDA</b>	<b>49</b>
5.12.1. BOX-JENKINS	49
<b>5.13. MODELOS QUALITATIVOS DE PREVISÃO DE DEMANDA</b>	<b>51</b>
<b>5.14. CONSIDERAÇÕES A RESPEITO DOS MODELOS APRESENTADOS</b>	<b>53</b>
<b>5.15. MODELOS ESCOLHIDOS PARA A PRÓXIMA ETAPA</b>	<b>53</b>
<b>5.16. COMBINAÇÃO DE MODELOS DE PREVISÃO DE DEMANDA</b>	<b>54</b>
<b><u>6. TESTES DOS MODELOS APRESENTADOS</u></b>	<b><u>56</u></b>
6.1. METODOLOGIA DE TESTE	56
6.2. ITENS / SKU'S "PILOTOS" (A SEREM TESTADOS)	57
6.3. COLETA DE DADOS DE VENDAS	58
6.4. MODELOS A SEREM TESTADOS	59
<b><u>7. ANÁLISES COMPARATIVAS</u></b>	<b><u>60</u></b>

<b>7.1. ANÁLISE DOS DADOS OBTIDOS PARA CADA MODELO APLICADO – RECOMENDAÇÃO DE MODELOS A SEREM UTILIZADOS</b>	<b>60</b>
<b>7.2. CONSIDERAÇÕES SOBRE CADA MODELO</b>	<b>63</b>
<b><u>8. APLICAÇÃO PRÁTICA DOS MODELOS</u></b>	<b><u>66</u></b>
<b>8.1. ETAPA DE VALIDAÇÃO</b>	<b>66</b>
<b><u>9. CONSIDERAÇÕES FINAIS</u></b>	<b><u>72</u></b>
<b>9.1. NECESSIDADES PARA IMPLEMENTAÇÃO</b>	<b>72</b>
<b>9.2. ASPECTOS ORGANIZACIONAIS DA PREVISÃO</b>	<b>78</b>
<b>9.3. PROPOSTAS ADICIONAIS DE MELHORIAS PARA O PROCESSO DE ESTIMATIVA</b>	<b>80</b>
<b><u>10. CONCLUSÃO</u></b>	<b><u>82</u></b>
<b>10.1. RESULTADOS OBTIDOS</b>	<b>82</b>
<b>10.2. TRABALHOS FUTUROS</b>	<b>82</b>
<b>10.3. PRINCIPAIS DIFICULDADES ENCONTRADAS NO DECORRER DO TRABALHO</b>	<b>82</b>
<b>10.4. COMENTÁRIOS FINAIS</b>	<b>83</b>
<b><u>11. REFERÊNCIA BIBLIOGRÁFICA</u></b>	<b><u>85</u></b>

## ***Índice de tabelas***

<b>Tabela 1 - Portfólio de Produtos Unilever Brasil Kibon</b>	<b>7</b>
<b>Tabela 2 - Valores de z para intervalo de Confiança</b>	<b>29</b>
<b>Tabela 3 - Tipos de Modelo de Previsão</b>	<b>35</b>
<b>Tabela 4 - Classificação de Pegels</b>	<b>42</b>
<b>Tabela 5 - Itens selecionados para Teste</b>	<b>58</b>
<b>Tabela 6 - Exemplo de Tabela Análise Desempenho Modelos de Previsão</b>	<b>60</b>
<b>Tabela 7 - Resultados Etapa de Testes - Critério: menor DAPM individual</b>	<b>61</b>
<b>Tabela 8 - Resultados Etapa de Testes - Critério: menor DAPM modelos combinados</b>	<b>62</b>
<b>Tabela 9 - Frequência de Escolha dos Modelos - Estratégia 1</b>	<b>63</b>
<b>Tabela 10 - Modelo de Tabela de Análise Vendas Reais x Previsão (Sistema Atual e Modelo Proposto)</b>	<b>67</b>
<b>Tabela 11 - Resultados Etapa de Validação</b>	<b>69</b>
<b>Tabela 12 - Descrição Tabela Parâmetro</b>	<b>73</b>
<b>Tabela 13 - Descrição Tabela Modelo</b>	<b>74</b>
<b>Tabela 14 - Descrição Tabela Vendas</b>	<b>74</b>
<b>Tabela 15 - Descrição Tabela Período</b>	<b>74</b>
<b>Tabela 16 - Descrição Tabela Linha</b>	<b>74</b>
<b>Tabela 17 - Descrição Tabela Família</b>	<b>74</b>
<b>Tabela 18 - Descrição Tabela SKU</b>	<b>75</b>

## ***Índice de figuras***

<b>Figura 1 – Metodologia de Desenvolvimento do Trabalho</b>	<b>5</b>
<b>Figura 2 - Unidades de Negócio da Unilever Brasil</b>	<b>7</b>
<b>Figura 3 - Processos Internos</b>	<b>8</b>
<b>Figura 4 - Detalhamento das Funções do Planejamento Logístico</b>	<b>9</b>
<b>Figura 5 - Componentes da Previsão de Demanda</b>	<b>12</b>
<b>Figura 6 - Impactos do Processo de Estimativa I</b>	<b>14</b>
<b>Figura 7 - Impactos do Processo de Estimativa II</b>	<b>15</b>
<b>Figura 8 - Processo em Análise - lead-times</b>	<b>18</b>
<b>Figura 9 - Etapas de Aplicação - Modelo de Previsão</b>	<b>31</b>
<b>Figura 10 - Algoritmo para aplicação de Modelo de Previsão</b>	<b>33</b>
<b>Figura 11 - Demanda com Tendência</b>	<b>38</b>
<b>Figura 12 - Demanda Cíclica com Tendência</b>	<b>40</b>
<b>Figura 13 – Exemplo de Correlação positiva</b>	<b>48</b>
<b>Figura 14 - Exemplo de Correlação Negativa</b>	<b>48</b>
<b>Figura 15 - Exemplo de Correlação Nula</b>	<b>48</b>
<b>Figura 16 - Algoritmo Metodologia Box-Jenkins</b>	<b>51</b>
<b>Figura 17 - Gráfico Comparativo - Demanda Real x Previsão</b>	<b>68</b>
<b>Figura 18 - Gráfico Comparativo - SFE (Sales Forecast Error)</b>	<b>68</b>
<b>Figura 19 - Gráfico Comparativo - Desempenho Modelos de Previsão x Sistema Atual</b>	<b>70</b>
<b>Figura 20 - Tabelas para Sistema de Previsão de Demanda</b>	<b>73</b>
<b>Figura 21 - Algoritmo Processo A</b>	<b>76</b>
<b>Figura 22 - Algoritmo Processo B</b>	<b>77</b>

## **1. Introdução**

### **1.1. Resumo do trabalho**

Este presente trabalho tem como proposta o desenvolvimento e implementação de um Sistema de Previsão de Demanda na Unilever Brasil Kibon, cuja demanda apresenta um comportamento claramente sazonal, com vendas concentradas em uma determinada época do ano.

Inicialmente, no capítulo 2, é feita uma apresentação sucinta da metodologia seguida para o desenvolvimento deste trabalho. A Empresa na qual o autor desenvolveu este Trabalho de Formatura é descrita brevemente no capítulo 3. Em seguida, no capítulo 4, é descrito o funcionamento do Sistema Atual de Previsão de Demanda na Unilever Brasil Kibon. São discutidos também alguns aspectos organizacionais que apresentam alguma influência relevante no processo em estudo. Além disso, discute-se a relevância deste projeto, bem como suas implicações. O objetivo do trabalho e sua abrangência são descritos detalhadamente, de maneira a se definir claramente o escopo do trabalho, além de garantir que se busquem apenas os modelos de Previsão e demais recursos que sejam realmente necessários neste estudo.

O capítulo 5 apresenta uma Revisão Bibliográfica detalhada, porém objetiva, visando apresentar os modelos de Previsão de Demanda que potencialmente podem ser utilizados para resolver o problema descrito no capítulo 4.

O capítulo 6 se inicia com a descrição da metodologia adotada para a realização dos testes com os modelos previamente selecionados dentre aqueles apresentados no capítulo 5. Utilizando-se desta metodologia os testes com os modelos são efetuados, sendo escolhidos (capítulo 7) os modelos de Previsão de Demanda para cada um dos itens estudados nesta etapa.

O capítulo 8 trata da validação dos resultados, utilizando-se os modelos indicados no capítulo 7 em situações reais de mercado com todas as variações e flutuações de comportamento da Demanda.

No capítulo 9 são apresentadas as eventuais necessidades para a implementação dos modelos de Previsão de Demanda em escala real de uso. Além disso, é apresentada uma discussão sobre aspectos organizacionais envolvidos no processo de Estimativa de Volume de Vendas, no que diz respeito a dificuldades de mudança e motivos para o insucesso ou sucesso de ações de melhoria de Processo de Previsão.

O capítulo 10 conclui o Trabalho, na medida em que se fazem os últimos comentários a respeito dos resultados obtidos, bem como em relação a participação do autor no processo de revisão e melhoria do Sistema de Previsão de Demanda da Unilever Brasil Kibon.

---

## **2. Metodologia**

### **2.1. Descrição das principais etapas de desenvolvimento do trabalho**

Para o desenvolvimento deste presente trabalho, o autor elaborou uma metodologia de trabalho que consiste em 4 principais etapas, de maneira análoga ao ciclo PDCA, buscando-se planejar ações, implementá-las, avaliar os resultados e padronizar as melhores formas de trabalho encontradas. As 4 etapas definidas são:

#### **Etapa 1 - Planejamento**

A etapa de Planejamento consiste em fazer um levantamento detalhado da situação inicial encontrada na Empresa na qual este trabalho foi desenvolvido, mapeando-se processos internos, interfaces entre departamentos, objetivos da área na qual autor desenvolveu suas atividades de Estágio, indicadores de desempenho e problemas encontrados.

Além disso, busca-se conversar com pessoas das diferentes áreas envolvidas, de maneira a tentar compreender o mecanismo de funcionamento do mercado (com todas as peculiaridades da Demanda do mercado de Sorvetes no Brasil) e levantar possíveis efeitos da variação da Demanda sobre a Cadeia de Suprimentos, além de entender os impactos financeiros do processo de Previsão de Demanda.

Após o diagnóstico inicial, parte-se para a definição do escopo do trabalho, estabelecendo-se as necessidades a serem satisfeitas após a conclusão do mesmo.

A etapa de Planejamento também inclui a definição dos critérios de seleção dos modelos a serem implementados e testados, bem como os critérios para escolha do melhor modelo a ser adotado para utilização em situações reais.

## Etapa 2 – Desenvolvimento, Implementação e Testes

A etapa imediatamente seguinte ao Planejamento é aquela que trata do desenvolvimento, implementação e teste de possíveis alternativas para a solução do problema descrito na etapa de Planejamento.

A partir da definição do escopo do trabalho, são coletadas as informações necessárias para seu desenvolvimento, visando atingir os objetivos previamente definidos. Tendo em mãos as informações coletadas, são analisados os pontos positivos e negativos das alternativas levantadas na ocasião da revisão bibliográfica.

Ponderados os aspectos positivos e negativos associados aos diferentes Modelos de Previsão pesquisados, sendo escolhidos os modelos, de acordo com os critérios de seleção previamente definidos, pode-se partir para a fase de Implementação piloto e de testes.

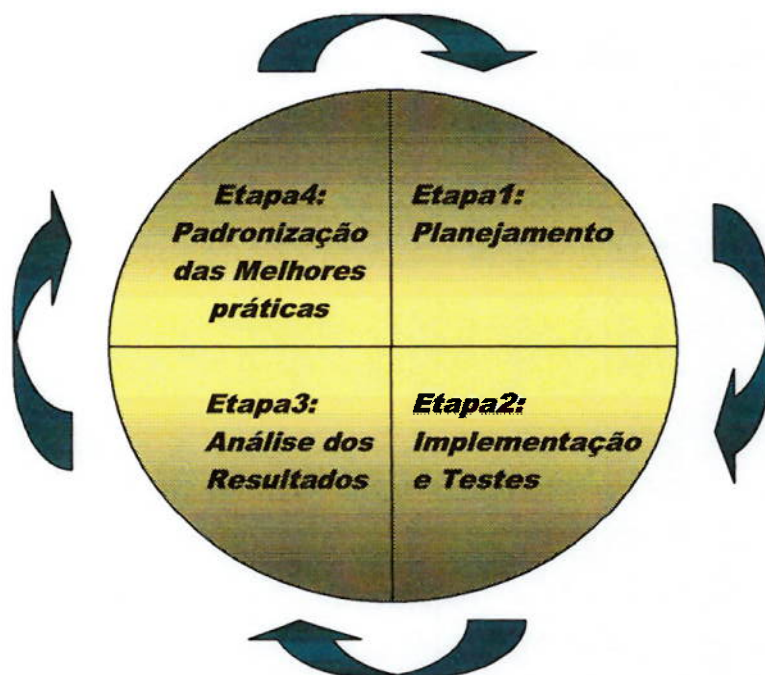
Nesta fase, busca-se efetuar diversos testes piloto com os diferentes Modelos de Previsão, sendo coletados todos os dados referentes a indicadores de desempenho a serem utilizados na Etapa 3 (Análise de Resultados) de desenvolvimento do trabalho.

## Etapa 3 - Análise dos resultados

A etapa de análise dos resultados consiste em compilar os indicadores de desempenho medidos na etapa de implementação e teste dos modelos propostos. A partir destes indicadores e aplicando os critérios de seleção previamente definidos na etapa de Planejamento é possível escolher dentre as alternativas propostas aquelas que se mostrem mais adequadas às necessidades da Empresa no momento atual e dentro do cenário previsto para os próximos anos.

#### Etapa 4 - Padronização das melhores práticas.

Uma vez definidos os melhores modelos a serem adotados pela Empresa deve-se proceder a última etapa deste projeto que consiste em padronizar as melhores práticas, ou seja, implementar e operar o sistema de previsão de demanda em escala real, contemplando todos os itens da Empresa e trabalhando a massa de dados em tamanho real.



**Figura 1 – Metodologia de Desenvolvimento do Trabalho**

Importante ressaltar que o desenvolvimento deste trabalho pode ser encarado como um ciclo, ou seja, uma vez cumpridas as 4 etapas, novas análises podem ser feitas e o ciclo pode ser repetido seguidas vezes, com o intuito de buscar melhorias de uma forma contínua.

### **3. Apresentação da Empresa**

#### **3.1. Tipo de Negócio**

A Unilever Brasil Kibon, empresa na qual o presente trabalho foi desenvolvido, atua no setor de Alimentos, mais especificamente no mercado de Sorvetes.

#### **3.2. Plantas no Brasil**

A Unilever Brasil Kibon possuía até Novembro de 2001 duas plantas instaladas no Brasil: uma em São Paulo – SP e outra em Recife – PE.

#### **3.3. Portfólio de Produtos**

Os produtos comercializados pela Unilever Brasil Kibon são divididos em três grandes Linhas:

Linha “*Impulse*” – é formada por produtos que têm como principal característica o consumo imediato após a compra.

Linha “*Take Home*” – formada por produtos comercializados em supermercados, hipermercados, padarias e outros estabelecimentos comerciais e que são destinados a consumo posterior, ou seja, o consumidor usualmente leva estes produtos para casa antes de consumi-los.

Linha “*Food Service*” – formada por produtos institucionais, isto é, que são comercializados em lanchonetes e restaurantes para consumo no próprio estabelecimento comercial.

As Linhas, por sua vez, podem ser subdivididas em classes e famílias, conforme apresentado na tabela 1:

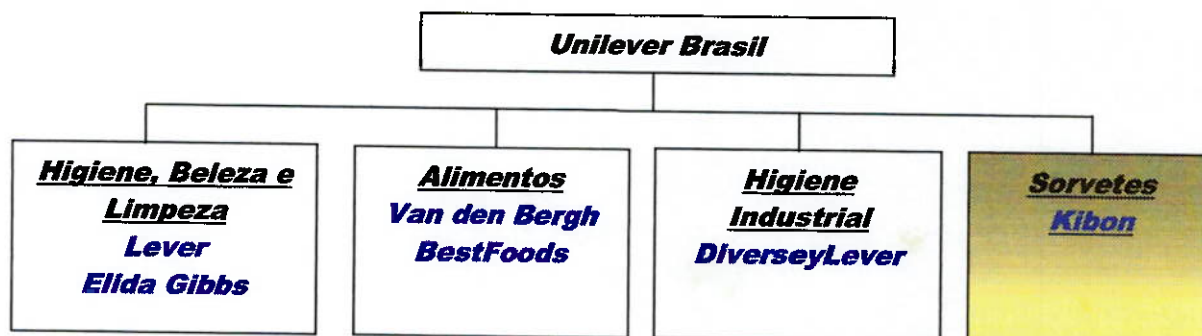
<b>Linha</b>	<b>Classe</b>	<b>Família</b>	
<b>Impulso</b>	<b>Picolés</b>	<b>Fruttare</b>	
		<b>Ao leite</b>	
		<b>Stickless</b>	
		<b>Magnum</b>	
		<b>Kids</b>	
		<b>Kibonbon</b>	
	<b>Cones</b>	<b>Copos</b>	
		<b>Multipacks</b>	
		<b>Take Home</b>	<b>Pote 1 litro</b>
		<b>Potes Light</b>	
		<b>Potes Delice</b>	
	<b>Pote 2 litros</b>	<b>Potes Ao Leite</b>	
		<b>Pote Tazza D'oro</b>	
<b>Food Service</b>	<b>Pote 5 litros</b>		
	<b>Coberturas</b>		
	<b>Soft Ice</b>		

**Tabela 1 - Portfólio de Produtos Unilever Brasil Kibon**

### **3.5. Unidades de Negócio - Unilever Brasil**

A Unilever Brasil pode ser dividida em quatro grandes áreas de negócio:

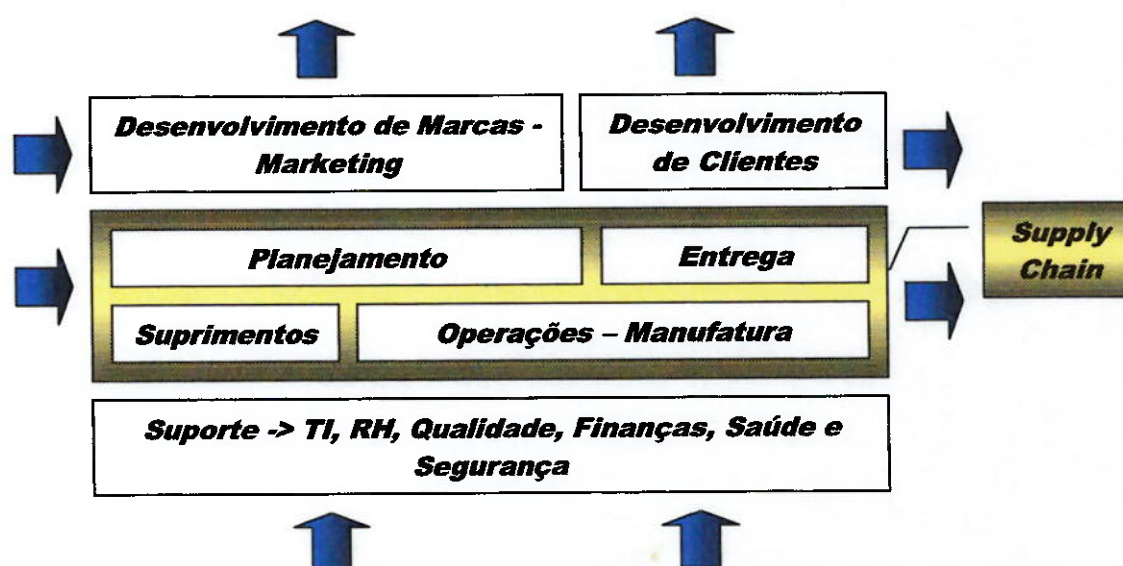
- *HPC – Home and Personal Care* – divisão de higiene pessoal, beleza e limpeza doméstica, composta pelas unidades Lever e Elida Gibbs;
- Unilever BestFoods – divisão de alimentos, que inclui as unidades BestFoods e a Van den Bergh.;
- DiverseyLever – divisão de produtos de higiene industrial;
- Kibon – divisão de sorvetes da Unilever.



**Figura 2 - Unidades de Negócio da Unilever Brasil**

### 3.6. Estrutura Organizacional Interna - Unilever Brasil Kibon

A estrutura organizacional da Unilever Brasil Kibon sugere a existência de dois principais processos que correm em paralelo, visando um mesmo objetivo que é o de atender e satisfazer o cliente. Identifica-se um processo claramente associado às tradicionais área de Vendas e Marketing que buscam desenvolver marcas e clientes. Além disso, um outro processo visível na análise da estrutura organizacional descrita envolve as tradicionais áreas de Compras, Manufatura e Logística. A figura 3 busca resumir estes processos:



**Figura 3 - Processos Internos**

Dando suporte aos dois principais processos tem-se as áreas relacionadas a Qualidade, Finanças, Recursos Humanos, Saúde e Segurança do Trabalho e Tecnologia da Informação.

Importante ressaltar que os dois principais processos internos identificados envolvem uma série de atividades conjuntas, havendo uma série de relacionamentos entre áreas. Inclusive, a atividade de definição da Estimativa Operacional de Volume de Vendas, que apresenta ligação direta com o tema deste presente trabalho, conta com a participação das áreas de Marketing, Vendas, Trade Marketing, Planejamento Logístico, etc.

### **3.7. Detalhamento das Funções da Área de Planejamento**

Dentro da área de Supply Chain a área de Planejamento tem como função principal trabalhar as informações de volume estimado de vendas (Planejamento de Demanda), disponibilidade de matéria prima e materiais de embalagem (Planejamento de Materiais), níveis de estoque de Produtos Acabados (Abastecimento) e capacidade produtiva da fábrica (Planejamento e Programação da Produção), de maneira a proporcionar condições para que a Cadeia de Suprimentos funcione de maneira correta, eficiente e ao menor custo possível, garantindo que os processos de compra, produção, armazenagem e entrega sejam seguidos, atendendo todas as necessidades dos clientes da Unilever Brasil Kibon.



**Figura 4 - Detalhamento das Funções do Planejamento Logístico**

#### **3.7.1. Funções da Área de Planejamento de Demanda**

Na Unilever Brasil Kibon a área de Planejamento de Demanda tem a responsabilidade de auxiliar na captura, interpretação e utilização dos direcionadores de demanda para criar e difundir internamente uma previsão operacional de demanda. A área de Planejamento de Demanda, subordinada ao Planejamento Logístico e por consequência ao *Supply Chain*, serve como interface com áreas do outro processo principal relacionado ao Marketing e Vendas e fica responsável pela definição de uma das componentes da Previsão de Demanda, cuja estrutura é descrita na seção 4.1.1.

### **3.8. Descrição das Atividades de Estágio**

As atividades de estágio desenvolvidas na Unilever Brasil Kibon pelo autor deste trabalho ficaram focadas na área de *Supply Chain*, mais precisamente na área de Planejamento Logístico. O plano de Estágio incluiu atividades nas diversas "sub-áreas" que compõem a área de Planejamento. No entanto, a atividade principal de estágio relaciona-se ao desenvolvimento de um projeto específico. Neste caso, o projeto, da área de Planejamento de Demanda, é de Desenvolvimento e Implementação de um Sistema de Previsão de Demanda para a Empresa. Neste projeto, o autor deste trabalho recebeu total liberdade para pesquisar os diferentes modelos que eventualmente podem ser empregados, levantar informações necessárias para o desenvolvimento deste projeto (dados históricos de volume de vendas, comportamento do mercado, funcionamento dos processos internos, etc.) e tomar ações necessárias para implementação das ferramentas escolhidas. Durante o período de estágio, a maior parte da carga horária de trabalho foi destinada ao desenvolvimento deste projeto.

---

## **4. Descrição do Problema e Definição dos Objetivos do Projeto**

### **4.1. Mecanismo Atual de Previsão de Demanda**

#### **4.1.1. Estrutura da Previsão de Demanda**

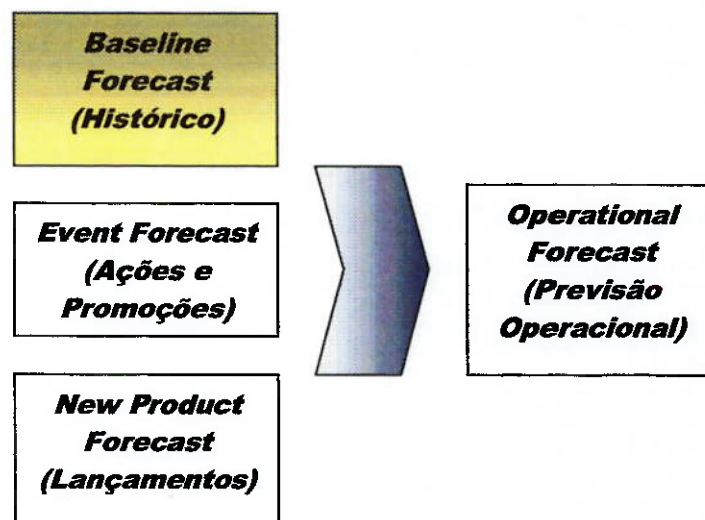
A estrutura de Previsão de Demanda na Unilever Brasil Kibon pode ser dividida em três principais componentes:

*Baseline Forecast* (Histórico) – componente da previsão de demanda correspondente aos dados históricos de vendas da Companhia. Serve como base para a previsão operacional de demanda.

*Event Forecast* (Ações e Promoções) – componente da previsão de demanda que leva em consideração os eventos das áreas de vendas e marketing, tais como: promoções, mídia, políticas de preços, ações de campo, etc.

*New Product Forecast* (Lançamentos) – componente da previsão de demanda que direciona seu foco de estudo para os produtos de lançamento, considerando os efeitos de “canibalização” sobre produtos de linha, procurando também evitar a obsolescência (*write-off*) dos produtos saindo de linha e a falta de produtos em lançamento, levando em conta o enchimento de canal (volume adicional necessário para preencher os pontos de venda da Kibon) das diversas filiais e distribuidores.

A estrutura de Previsão de Demanda da Unilever Brasil Kibon pode ser visualizada na figura 5:



**Figura 5 - Componentes da Previsão de Demanda**

A partir da consolidação das três componentes acima descritas chega-se a previsão operacional do Volume de Demanda.

#### **4.1.2. Participantes do Processo de Estimativa**

No mecanismo atual do Processo de Previsão de Demanda os participantes são a área de Planejamento de Demanda (*Supply Chain*), responsável pelo componente *Baseline Forecast*, a área de Trade Marketing e a área de Marketing, sendo que estas duas últimas se responsabilizam pelos componentes *Event Forecast* e *New Product Forecast*.

#### **4.1.3. Descrição do Processo de Estimativa**

O processo atual de Previsão de Demanda está organizado na forma de uma reunião mensal de estimativa, na qual os participantes trazem as informações referentes a suas componentes de previsão de vendas, além de outras informações pertinentes ao assunto a ser discutido na reunião.

As eventuais pendências são resolvidas e uma vez acertados os volumes estimados de vendas para os meses subsequentes, prossegue-se com a difusão da informação para as demais áreas da Empresa.

#### **4.1.4. Análise do Processo de Estimativa**

Uma primeira análise relativa ao Processo de Estimativa de Vendas na Unilever Brasil Kibon mostra uma ausência de um modelo formal que auxilie a área de Planejamento de Demanda a determinar os volumes relativos ao *Baseline Forecast* para a reunião de estimativa. Esta é uma razão pela qual a área de Planejamento de Demanda busca um modelo formal e estruturado de previsão que suporte suas tomadas de decisão. O mesmo tipo de problema é verificado também em relação às outras áreas e suas respectivas componentes de Demanda. Avalia-se que a ausência de um processo formal de definição dos valores abre espaço para decisões orientadas mais por impressões momentâneas e desejos futuros do que por aspectos racionais que deveriam ser analisados friamente. Nota-se que o Processo Atual de Estimativa de Vendas não reflete uma expectativa de venda futura e sim um desejo (ou meta) por parte da Área Comercial (Vendas e Trade Marketing) que se cristaliza na forma de um volume definido e colocado como meta para os vendedores.

#### **4.2. Descrição dos Objetivos do Trabalho**

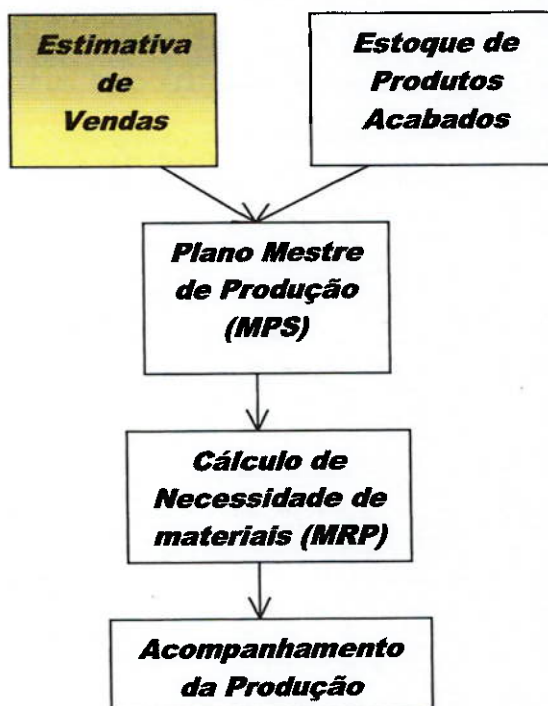
A partir da análise do Processo de Estimativa e dos indicadores de desempenho do processo atualmente utilizados na Unilever Brasil Kibon (a serem melhor discutidos na seção 5.3.2.) avalia-se que o Processo em questão apresenta um problema de baixa qualidade de suas previsões.

Desta forma, o objetivo definido para o trabalho consiste em pesquisar, adaptar e aplicar um modelo matemático de Previsão de Demanda a ser utilizado pela área de Planejamento de Demanda e que proporcione uma qualidade maior ao Sistema de Previsão de Vendas da Unilever Brasil Kibon, de maneira a melhorar o desempenho das áreas de Planejamento de Materiais,

Planejamento e Programação da Produção, além de diminuir os níveis de estoque, acarretando em melhores resultados financeiros para a Unilever Brasil Kibon, garantindo também um melhor fluxo de recursos através da Cadeia de Suprimentos.

#### **4.3. Impactos do Processo de Estimativa / Relevância do Trabalho**

Através da descrição das atividades da área de planejamento logístico na Unilever Brasil Kibon é possível analisar os impactos do Processo de Estimativa de Vendas sobre a Cadeia de Suprimentos. A figura 6 mostra o fluxo de informações na Cadeia de Suprimentos a partir da Estimativa de Vendas:

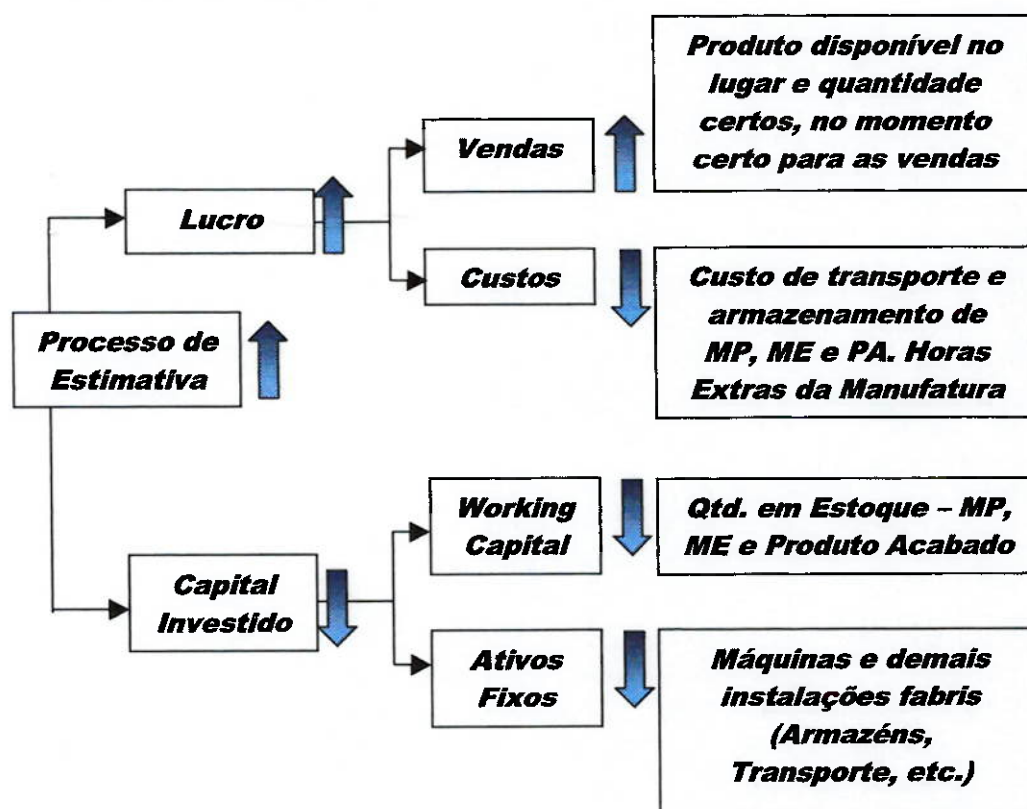


**Figura 6 - Impactos do Processo de Estimativa I**

Uma vez determinados os volumes estimados de venda por SKU para os próximos meses e levando em consideração os estoques de produtos acabados, parte-se para o estudo de capacidade de produção das linhas das fábricas, através do Plano Mestre de Produção. Feitos os ajustes necessários nos volumes (através de pré-estocagem e/ou realocação de produtos em linhas diferentes das inicialmente previstas) prossegue-se com o cálculo de necessidades de material (matéria prima e material de embalagem).

Calculadas as necessidades, são colocadas as ordens de pedidos de materiais para os fornecedores da Kibon.

Desta forma, como se pode perceber, a estimativa de vendas apresenta um impacto significativo no capital investido pela empresa (na forma de matéria prima, material de embalagem e produto acabado em estoque), influenciando diretamente o resultado da Companhia. Além disso, um processo de estimativa de vendas falho pode resultar em desabastecimento de determinado SKU no mercado, o que pode causar sérios danos a imagem da Companhia. Por fim, um processo de estimativa que não funcione corretamente pode levar a tomada de decisões equivocadas na ocasião de estudos de ampliação ou redução de capacidade fabril instalada.



**Figura 7 - Impactos do Processo de Estimativa II**

A relevância e pertinência deste trabalho podem ser demonstrados a partir de uma análise criteriosa dos impactos e implicações do Processo de Estimativa na Cadeia de Suprimentos e no Resultado Geral da Empresa resumidos na

figura 7. Pode-se perceber que até mesmo pequenas melhorias neste Processo podem trazer inúmeros benefícios para a Unilever Brasil Kibon.

#### **4.4. Abrangência do Trabalho**

Seguindo o objetivo proposto para este trabalho, algumas considerações devem ser feitas. O modelo de Previsão de Demanda para a Unilever Brasil Kibon deverá ser de implementação fácil, rápida e ao menor custo possível. O modelo a ser adotado deverá ser simples o bastante para que possa ser compreendido pelas pessoas que o utilizarão, de modo a evitar o problema de se enxergar a Previsão de Demanda como uma “caixa preta” sobre a qual se conhece muito pouco, sendo usados somente os resultados de saída. Acredita-se que o conhecimento sobre o processo de elaboração da Previsão de Demanda é essencial para garantir sua qualidade (através de parametrizações mais precisas, que somente podem ser atingidas quando se tem uma clara visão de como o modelo funciona) e para assegurar o comprometimento de todos que o utilizarão.

Além disso, a implementação deverá ser rápida, uma vez que o Sistema Atual apresenta-se deficiente e que as gerências envolvidas têm manifestado interesse em um novo modelo que comece a funcionar o mais rápido possível para que a Empresa possa se beneficiar das vantagens proporcionadas o quanto antes.

A questão do custo é também de grande importância nesta discussão, tendo em vista que não existe o desejo por parte da Empresa em adquirir *softwares* específicos de Previsão de Demanda no curto e médio prazos, devendo o modelo ser implementado em Planilha Eletrônica (MS-Excel™).

O Modelo a ser desenvolvido e implementado será utilizado para produtos que já estejam em linha há no mínimo 12 meses (uma temporada completa) pois o foco do trabalho é a componente histórica de Previsão (*Baseline Forecast*) para a qual são requeridos valores históricos de vendas, que por razões óbvias não

existem para os produtos recém lançados. Além disso, o modelo de Previsão deverá também tratar as vendas em níveis mais agregados, com previsão para Linhas (*Impulse, Take Home e Food Service*), Classes (Picolés, Cones, além de outros), Famílias (Fruttare, Potes 2 litros, etc) e para o total geral de vendas da Empresa.

Por fim, o horizonte de Previsão de Demanda do Modelo deve ser definido a partir do *lead-time* do processo em análise.

O Processo em análise tem seu início a partir do momento em que se calculam os volumes de Produção por Linha e por SKU (*Stock Keeping Unit – Item de Estoque*) a partir dos volumes de Estimativa de Vendas, sendo observadas as possíveis restrições de Capacidade (MPS – Plano Mestre de Produção ou *Master Plan Scheduling*). Para esta etapa e para cada uma das etapas subseqüentes existe um *lead-time* médio. O processo se encerra quando o Produto Acabado atinge o ponto de venda e se torna disponível para o consumidor final.

A figura 8 resume as principais etapas deste processo:



**Figura 8 - Processo em Análise - lead-times**

A partir da figura 8 chega-se a um *lead-time* total médio de 24 dias. Desta forma, o horizonte de Previsão de Demanda utilizado atualmente pela Unilever Brasil Kibon (um mês para decisões de curto prazo e três meses para decisões mais táticas) encontra-se adequado. Esta questão é de extrema importância pois um Sistema de Previsão de Demanda deve ter seu horizonte de previsão maior ou igual a este *lead-time*, que seria uma espécie de tempo de reação da

Empresa diante de uma eventual flutuação de comportamento da Demanda. A periodicidade da Previsão de Demanda deverá continuar sendo de um mês.

## **5. Revisão Bibliográfica – Modelos de Previsão de Demanda**

### **5.1. Tipos de Previsão**

MAKRIDAKIS (1998) classifica os modelos de previsão de vendas em duas diferentes categorias:

Modelos Quantitativos – baseados em dados numéricos, tais como: histórico de vendas, temperaturas médias, inflação, etc.

Os modelos quantitativos podem ainda ser divididos em:

➤ Modelos baseados em Séries Temporais;

São basicamente modelos de projeção, visto que assumem a premissa de que o comportamento futuro da Demanda irá reproduzir um padrão de comportamento verificado no passado. Não se busca, neste tipo de modelo, uma explicação para as causas da Demanda, visando-se apenas projetar valores para o futuro.

➤ Modelos baseados em Correlação (Modelos Causais);

Modelos nos quais se busca estabelecer regras, ou leis que descrevem a relação existente entre os diferentes fatores analisados e que levam a um determinado valor de Demanda. A hipótese assumida neste caso é a continuidade das relações no decorrer do tempo, ou seja, assume-se que as leis e regras definidas no passado continuarão a ser válidas no futuro.

Modelos Qualitativos – baseados em dados subjetivos, que não podem ser quantificados, tais como: opinião de especialistas, informações de vendedores, etc. Os modelos qualitativos trabalham com a hipótese implícita de que as relações ou padrões de comportamento verificados no passado não se repetirão necessariamente no futuro. A Demanda deixa, portanto, de ser expressa através de uma função matemática clara e passa a ser definida a

partir da consideração de inúmeros fatores que se acredita serem importantes na definição de um valor estimado de Demanda.

A partir das responsabilidades atribuídas à área de Planejamento de Demanda na Unilever Brasil Kibon, o foco do trabalho desenvolvido durante as atividades de estágio pelo autor se voltou para a aplicação de modelos quantitativos de previsão de demanda. Isto porque a componente mais subjetiva da previsão acaba por ser responsabilidade das áreas de Trade Marketing e Marketing, ao passo que a área de Planejamento de Demanda volta seus esforços para o *Baseline Forecast* (conforme discutido na seção 4.1.2.).

Dentre os modelos quantitativos de Previsão de Demanda optou-se num primeiro momento por aqueles baseados em séries temporais. Isso se deve ao fato de que a Unilever Brasil Kibon mantém acessíveis apenas os dados referentes ao históricos de Vendas (a partir do ano de 1997), não havendo registros de preços praticados ao consumidor nestes períodos, temperaturas médias registradas nos principais centros consumidores dos produtos da Empresa, preços praticados pelos concorrentes, além de outros dados que poderiam ser utilizados na montagem de modelos causais que tentariam correlacionar dois ou mais destes fatores. A obtenção destes dados, apesar de possível, não atenderia os requisitos de facilidade, simplicidade, baixo custo e rapidez de implementação da solução apresentados na seção 4.4.

## **5.2. Séries Temporais: componentes Base, Tendência, Sazonalidade, Ciclicidade**

MAKRIDAKIS (1998) e HANKE (1998) apontam quatro componentes distintos na demanda, que devem ser considerados na escolha do modelo mais adequado para a previsão de vendas:

- Tendência – componente de longo prazo que representa crescimento ou declínio em uma série temporal ao longo do tempo;

- Sazonalidade – padrão de comportamento de crescimento e queda que se repete em um determinado período de tempo conhecido (semanas, meses, anos etc.). No caso da Unilever Brasil Kibon a sazonalidade é muito clara e pode ser associada às estações do ano. Os dados históricos de vendas da Empresa demonstram que os volumes de venda são significativamente maiores durante o período compreendido entre os meses de Setembro e Março, tratada internamente como “alta temporada ou verão”.
- Ciclicidade – padrão de comportamento similar ao classificado como sazonal, porém sem período de tempo definido;
- Aleatoriedade – variações no comportamento da demanda que ocorrem de maneira aleatória e que, portanto, não podem ser previstas.

### **5.3. Medidas de Erro de Previsão**

#### **5.3.1. Objetivos de um Indicador de Desempenho – Conceito de Desvio**

O principal objetivo de um indicador de desempenho de um processo é o de fornecer informações relevantes a respeito de seu funcionamento e permitir a tomada de decisões acertadas visando manter o processo sob controle. Usualmente, os indicadores medem de alguma forma o desvio (diferença) entre o valor previsto e o valor real, seja na forma absoluta, seja na forma de porcentagem ou em alguma outra forma diferente.

MAKRIDAKIS (1998) e HANKE (1999) apresentam uma série de indicadores que podem ser utilizados para o Processo de Previsão de Demanda. Estes indicadores servem também para definir a escolha pelo modelo mais adequado a cada situação em estudo (neste caso, é medido o desvio entre os valores previstos por um determinado modelo e os valores reais que formam a base de dados históricos utilizada para escolher, calibrar e testar o modelo de previsão em questão).

A primeira medida de desvio para modelos de previsão de demanda apresentada por MAKRIDAKIS (1998) e HANKE (1998) é a diferença simples entre a previsão e o valor real:

$$e_t = F_t - Y_t \quad (1)$$

onde

$e_t$  é o desvio no período  $t$ ;

$F_t$  é o valor previsto para o período  $t$ ;

$Y_t$  é o valor real verificado no período  $t$ ;

A partir deste valor pode-se chegar a um valor médio de desvio (DM – Desvio Médio), dado por:

$$DM = \frac{1}{n} \sum_{t=1}^n e_t \quad (2)$$

onde  $n$  é o número de períodos considerados para a média.

O valor médio de desvio é importante na medida em que fornece informações sobre a tendência do modelo em subestimar (valores médios negativos) ou superestimar (valores médios positivos) suas previsões diante dos valores reais.

O desvio também pode ser avaliado em valores absolutos, ou seja, a partir do módulo do desvio entre os valores reais e os previstos. Esta medida, denominada Desvio Absoluto Médio (DAM) também é importante porque modelos que apresentam desvios positivos e negativos na mesma proporção podem transmitir a falsa impressão de acurácia elevada, pois o desvio médio se aproximaria de zero. Além disso, esta medida de desvio assume que tanto a previsão superestimada quanto a subestimada são indesejáveis e devem ser consideradas como desvios em relação ao valor real de vendas.

$$DAM = \frac{1}{n} \sum_{t=1}^n |e_t| \quad (3)$$

Os valores de desvio também podem ser elevados ao quadrado, de forma a penalizar modelos de previsão que apresentam poucos erros, porém de grande significância em termos de valor. Este indicador de desvio, classificado por Desvio Quadrático Médio (DQM), tem como finalidade penalizar modelos que aparentemente se mostram estáveis, com valores de desvio baixos, mas que, no entanto, podem apresentar valores de desvio pontuais muito altos, cujos efeitos podem ser desastrosos para a Empresa.

$$DQM = \frac{1}{n} \sum_{t=1}^n e_t^2 \quad (4)$$

Existem situações nas quais a comparação entre dois ou mais valores de desvio fica prejudicada por haver uma diferença considerável na ordem de grandeza destes valores. No caso da Unilever Brasil Kibon esta situação fica muito bem caracterizada pelo comportamento de sua demanda, cujas características claras de sazonalidade resultam em vendas na alta temporada (verão) cerca de cinco vezes maiores que as vendas registradas na baixa temporada (inverno). Desta forma, uma comparação simples entre valores absolutos de desvio entre previsão de vendas e valores reais, referentes a janeiro e a julho seria bastante distorcida.

Para tais casos, HANKE (1998) apresenta uma variante dos indicadores de desvio, os quais passam a ser tratados percentualmente. MAKRIDAKIS (1998) sustenta que esta é uma forma possível de se comparar valores de desvio mesmo com ordens de grandeza diferentes nos valores absolutos.

O equivalente do desvio seria o desvio percentual (DP):

$$DP_t = \left( \frac{Y_t - F_t}{Y_t} \right) \times 100\% \quad (5)$$

Os mesmos indicadores de valores médios também podem ser adaptados para as seguintes formas:

Desvio Percentual Médio (DPM):

$$DPM = \frac{1}{n} \sum_{t=1}^n PE_t \quad (6)$$

Desvio Absoluto Percentual Médio (DAPM):

$$DAPM = \frac{1}{n} \sum_{t=1}^n |PE_t| \quad (7)$$

Obviamente, o desvio quadrático não pode ser trabalhado na forma percentual e desta forma não serve como parâmetro de comparação entre situações nas quais os desvios apresentam ordens de grandeza distintas.

### 5.3.2. Indicadores de Desempenho em uso na Unilever Brasil Kibon

Um aspecto de extrema importância para indicadores de desempenho (medidores de desvio) é o horizonte de tempo considerado na medição. Usualmente, um modelo de previsão é capaz de fornecer estimativas para  $n$  próximos períodos. A medida dos desvios deve ter seu horizonte de tempo igual ou maior que o *lead-time* de entrega dos materiais componentes do produto acabado, processamento e distribuição para o mercado, ou seja, deve-se medir o erro da previsão dentro do tempo de reação que a Empresa teria diante de alguma flutuação significativa no volume de vendas.

No caso da Unilever Brasil Kibon, os desvios medidos entre o volume de vendas estimado pelos modelos matemáticos e o volume real verificado terão como horizonte de tempo um mês. No caso das exceções, isto é, produtos que apresentam *lead-time* diferente, o erro será medido de acordo com este horizonte de tempo. A validade deste período é demonstrada na seção 4.4.

A Unilever Brasil Kibon utiliza alguns indicadores de desempenho para avaliar a eficiência do Sistema de Previsão em uso. Este indicadores se relacionam

também com a política de metas da Empresa e por conseqüência com a distribuição de lucros ao final do ano.

São definidos três indicadores:

SFE – *Sales Forecast Error* ou Desvio Absoluto Percentual de Previsão para cada item (SKU)

$$SFE = \frac{|Venda Real - Venda Estimada|}{Venda Estimada} \times 100\% \quad (8)$$

Este indicador é calculado em módulo para evitar que valores superestimados compensem os subestimados e se tenha a falsa impressão de que a Previsão de Vendas não apresenta desvios.

SFB – *Sales Forecast Bias* ou Desvio Percentual de Previsão.

$$SFB = \frac{(Venda Real - Venda Estimada)}{Venda Estimada} \times 100\% \quad (9)$$

Este indicador tem como finalidade mostrar se a previsão apresenta algum viés, ou seja, tendência de superestimar os valores de previsão (SFB < 0 ) ou de subestimar os valores de previsão (SFB > 0). O Ideal é que o SFB se aproxime de zero.

PAP – *Portfolio Accuracy Performance* ou Acerto dentro da faixa de 80% a 120%.

$$PAP = \frac{\sum \text{Volume de Vendas com acerto entre 80\% e 120\%}}{\text{Volume Total Vendido}} \quad (10)$$

Este indicador assume que a previsão pode se encontrar entre 80 e 120% do valor real sem que haja prejuízo para a Unilever Brasil Kibon. Desta forma, todos os volumes de SKU que se encontram dentro desta faixa são somados e comparados com o volume total de vendas no mês. Busca-se neste caso avaliar a performance da previsão de demanda para o portfólio de produtos como um todo e não da previsão individual de cada SKU.

Analisando os indicadores apresentados conclui-se que sua construção é praticamente igual a dos indicadores sugeridos por MAKRIDAKIS (1998) e HANKE (1998). Desta forma, a princípio estes indicadores permanecerão em uso. Além disso, alguns deles serão utilizados para avaliação dos Modelos de Previsão de Demanda a serem apresentados.

#### 5.4. Estatística U de Theil

MAKRIDAKIS (1998) apresenta também uma outra variante de indicador de medida de desvio denominada Estatística U de Theil. Este indicador tem como objetivo reunir os dois principais aspectos de funcionalidade dos indicadores apresentados previamente: a comparação entre valores de desvio utilizando pesos iguais para todas as medidas e o erro quadrático que enfatiza os erros de grande proporção.

A estatística U de Theil pode ser representada pela seguinte equação:

$$U = \sqrt{\frac{\sum_{t=1}^{n-1} \left( \frac{PD_{t+1} - V_{t+1}}{V_{t+1}} \right)^2}{\sum_{t=1}^{n-1} \left( \frac{F_{t+1} - V_{t+1}}{V_{t+1}} \right)^2}} \quad (11)$$

Uma modificação feita em relação a forma inicialmente proposta por MAKRIDAKIS (1998) é que nesta equação acima, compara-se somente o  $DPM^2$  (quadrado do Desvio Percentual Médio) do modelo proposto (numerador) com o modelo em uso (denominador).

Vale:

$U < 1$ : Modelo proposto apresenta desempenho melhor que o modelo atual;

$U = 1$ : Modelo proposto e modelo atual de Previsão de Demanda apresentam o mesmo desempenho;

$U > 1$ : Modelo proposto se mostra pior que o modelo atual de Previsão de Demanda. Não existe razão para mudar a maneira pela qual se chega a um volume estimado (previsto) de Demanda.

Apesar de útil, inicialmente este indicador não será utilizado a princípio, sendo que para comparar o modelo de Previsão de Demanda proposto com o atualmente em uso serão adotados outros critérios a serem discutidos na seção 6.1. na etapa de testes e escolha dos modelos de Previsão.

### **5.5. Intervalos de Confiança das Previsões**

Um primeiro pressuposto do qual se parte em um Estudo sobre Previsão de Demanda é que a previsão é sempre carregada de incertezas. Portanto, não basta apenas determinar um valor para uma previsão. É necessário também definir dentro de qual intervalo este se situa e qual o grau certeza desta previsão. Desta forma, pode-se ter uma idéia sobre a melhor situação e também sobre a pior situação (extremos do intervalo de confiança).

MAKRIDAKIS (1998) apresenta uma forma para definir este intervalo de confiança, na qual o DQM – desvio quadrático médio (MSE - *Mean Squared Error*) fornece uma estimativa da variância da previsão. Desta forma, a raiz do MSE forneceria um valor de desvio padrão para o erro da previsão.

Assim, o intervalo de confiança de uma previsão pode ser definido como:

$$\boxed{F_{n+1} \pm z \cdot \sqrt{DQM}} \quad (12)$$

O valor  $z$  está relacionado com o grau de precisão que se deseja para o intervalo de confiança da previsão:

<b>z</b>	<b>%</b>
<b>0,674</b>	<b>50</b>
<b>1,000</b>	<b>68</b>
<b>1,150</b>	<b>75</b>
<b>1,282</b>	<b>80</b>
<b>1,645</b>	<b>90</b>
<b>1,960</b>	<b>95</b>
<b>2,576</b>	<b>99</b>

**Tabela 2 - Valores de z para Intervalo de Confiança**

### **5.6. Séries Temporais – Princípios de Decomposição**

Conforme apresentado em 5.2., as séries temporais podem ser divididas em quatro componentes: tendência, ciclicidade, sazonalidade e componente aleatória. Os métodos de decomposição buscam separar e determinar estes componentes das séries temporais. Via de regra os componentes de tendência e ciclicidade são tratados juntos e referem-se a fenômenos de longo prazo, ao passo que o componente de sazonalidade refere-se a mudanças no curto prazo relacionadas a aspectos tais como: temperatura, mês do ano, época de férias, etc.

A representação matemática da decomposição é a seguinte:

$$\boxed{Y_t = f(S_t, T_t, E_t)} \quad (13)$$

A forma exata desta função depende do tipo de decomposição utilizada. MAKRIDAKIS (1998) apresenta duas formas: aditiva e multiplicativa.

A forma aditiva na qual as componentes de demanda se somam pode ser representada por:

$$\boxed{Y_t = S_t + T_t + E_t} \quad (14)$$

A forma multiplicativa, onde as componentes de demanda se relacionam através do produto entre elas, pode ser descrita por:

$$\boxed{Y_t = S_t \times T_t \times E_t} \quad (15)$$

### **5.8. Etapas para Aplicação de um Modelo de Previsão**

Em grande parte dos modelos de previsão de Demanda existe a necessidade de parametrização, onde são definidos os valores para os componentes de demanda e para as variáveis referentes ao modelo empregado. Além disso, existe também a necessidade de testar e validar o modelo antes de sua aplicação prática.

MAKRIDAKIS (1998) sugere uma estratégia para testar, avaliar e escolher o modelo de previsão de demanda a ser utilizado, a qual consiste em duas principais etapas: inicialização e teste. Abordagem semelhante é apresentada e discutida em SANTORO (2000).

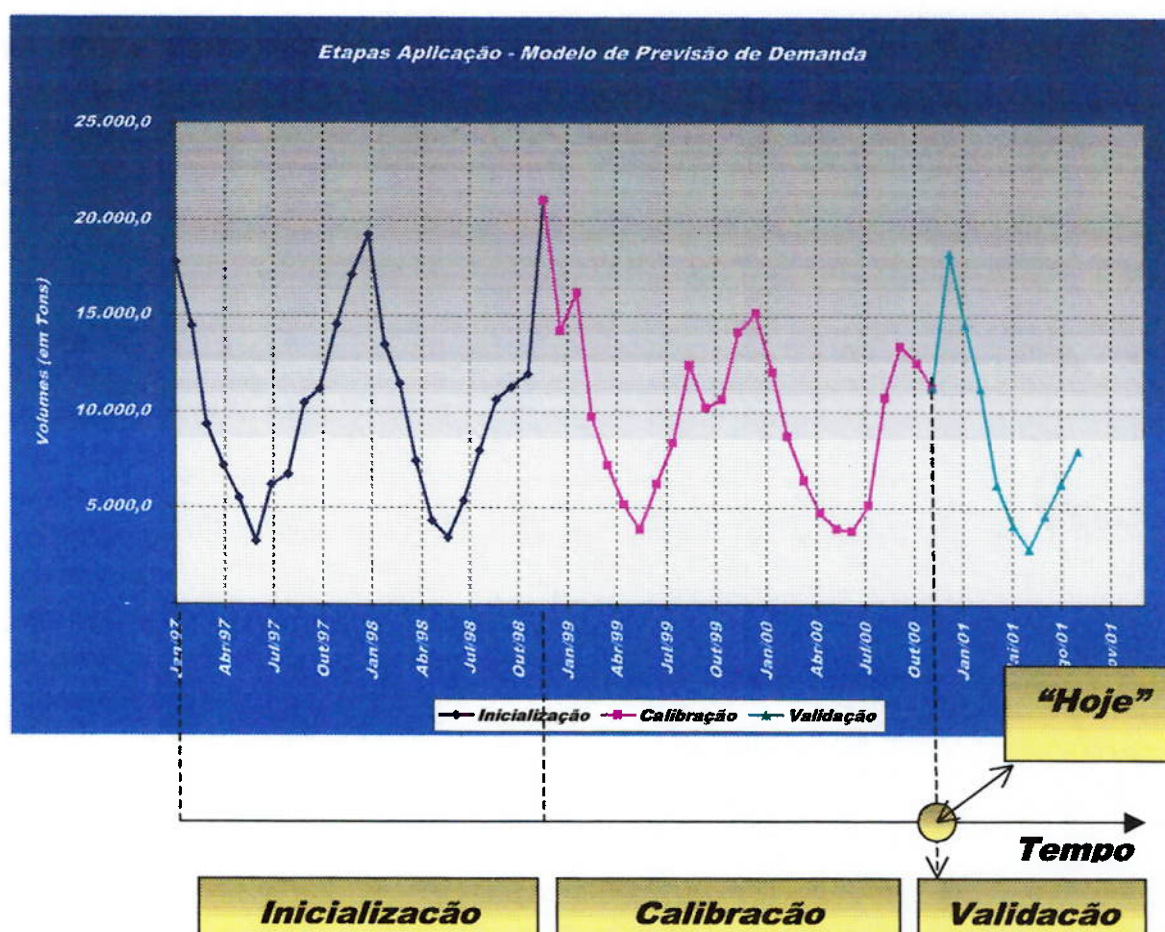
Em todas estas abordagens, a idéia é de utilizar-se de dados passados para cobrir todas as etapas de desenvolvimento e aplicação do modelo de previsão, inclusive utilizando parte destes dados para testar os modelos e simular situações reais de uso. O que se faz é dividir a série histórica em duas partes, onde a mais antiga ("passado distante") é usada para a etapa de inicialização e a menos antiga ("passado próximo") para a etapa de testes.

Neste presente trabalho, no entanto, o que se denomina teste é a etapa de Implementação, testes-piloto e seleção do modelo de Previsão a ser adotado. O autor propõe uma etapa adicional de validação dos resultados, na qual os modelos são aplicados em situações reais de uso.

O autor deste trabalho adota ainda uma divisão da etapa de inicialização em duas atividades:

- Inicialização – atividade na qual são determinados dos valores iniciais dos componentes do modelo de Previsão de Demanda. Em modelos de fórmula recursiva este aspecto é crucial.

- **Otimização / Calibração** – atividade na qual se adota algum procedimento específico para determinar os melhores valores para os parâmetros dos modelos de Previsão de Demanda, onde usualmente busca-se minimizar o Desvio Absoluto Percentual Médio, Desvio Quadrático Médio, etc. No desenvolver deste trabalho, esta atividade se inclui na etapa de Implementação e testes.



**Figura 9 - Etapas de Aplicação - Modelo de Previsão**

Uma vez definidos os valores iniciais das componentes de demanda do modelo de Previsão, bem como os valores dos parâmetros deste modelo, procede-se com a aplicação deste modelo, utilizando-se, então, dos valores do conjunto de dados referentes ao "passado próximo" para validar as escolhas feitas nas etapas anteriores. Esta etapa de validação busca simular uma situação real de uso.

As etapas para aplicação de Modelo de Previsão podem ser resumidas em cinco principais passos:

**Passo 1:**

Divisão da série temporal em três principais períodos: inicialização, calibração e validação.

**Passo 2:**

Inicialização do modelo de previsão. A partir dos dados da primeira parte da série temporal são definidos todos os valores iniciais relacionados com o modelo de previsão a ser avaliado.

**Passo 3:**

Definição dos valores das variáveis do modelo de Previsão de Demanda, buscando-se minimizar algum indicador de desvio, como por exemplo: Desvio Absoluto Percentual Médio ou Desvio Quadrático Médio. Para tanto, pode ser aplicado algum algoritmo de otimização não-linear, ou então, pode-se testar diversos valores para as variáveis ("tentativa e erro") até que se esteja satisfeito com o valor da medida de Desvio escolhida para a avaliação.


**Passo 4:**

Validação do Modelo de Previsão de Demanda através de sua aplicação e comparação entre os valores previstos e os valores do conjunto de dados referentes ao "passado próximo". Para esta comparação, usualmente deve-se utilizar a mesma medida de desvio escolhida para a etapa de calibração.

**Passo 5:**

Análise dos resultados obtidos e consideração de outros fatores, tais como: facilidade de implementação e uso, custo de implementação e operação, necessidade de armazenamento de dados, requisitos técnicos para aplicação prática, além de todos outros fatores julgados pertinentes no processo de

tomada de decisão da Empresa. Analisados os prós e contras de cada alternativa deve-se selecionar aquelas que serão implementadas.



**Figura 10 - Algoritmo para aplicação de Modelo de Previsão**

## **5.9. Abordagens para Previsão de Demanda – Séries Temporais**

### **5.9.1. Média**

Uma das abordagens mais simples para a previsão de demanda é a utilização da média sobre os valores da série temporal com a qual se trabalha. A condição necessária para que a média possa ser utilizada como meio de previsão é que a série histórica apresente um comportamento tipicamente estacionário, ou seja, apresentando valores que se distribuem aleatoriamente em torno de um valor central constante, sem tendência de aumento ou queda deste valor médio.

$$F_{t+1} = \frac{1}{t} \sum_{i=1}^t Y_i \quad (16)$$

No caso de haver a presença de tendência e/ou sazonalidade na série histórica em análise, MAKRIDAKIS (1998) sugere a utilização da média móvel, na qual valores mais antigos são descartados, dando espaço para os valores mais recentes. Para lidar com a sazonalidade uma alternativa é o uso de médias móveis com períodos iguais ao período da sazonalidade em questão, o que em tese anularia os efeitos sazonais.

$$F_{t+1} = \frac{1}{k} \sum_{i=t-k+1}^t Y_i \quad (17)$$

onde  $k$  é a ordem da média móvel, ou seja, o número de valores que são considerados no cálculo da média móvel.

A média móvel, segundo a fórmula apresentada, confere pesos iguais a todos os valores que constam do cálculo. Uma desvantagem que pode ser associada a utilização deste método é a necessidade de armazenar todos os valores que contam do período determinado para a média móvel. No caso de previsão de demanda para um elevado número de itens isto pode se tornar uma séria restrição.

Considerando que a informação carregada pelos dados mais recentes é mais confiável que aquela associada a dados mais antigos pode-se pensar em aplicar pesos diferentes, dando mais importância aos dados mais recentes. Uma forma de fazer isso é utilizando o conceito de suavização exponencial.

MAKRIDAKIS (1998) apresenta uma série de modelos de previsão de demanda que utilizam-se deste conceito.

<b>Métodos de Média</b>	<b>Métodos baseados em Suavização Exponencial</b>
<b>Média Simples</b>	<b>Suavização Exponencial Simples</b> <b>1 parâmetro;</b> <b>Adaptativo;</b>
<b>Média Móvel</b>	<b>Método Linear de Holt</b> <b>(Adequado para tendência)</b>
	<b>Método de Holt-Winters</b> <b>(Adequado para tendência e sazonalidade)</b>

**Tabela 3 - Tipos de Modelo de Previsão**

No caso da Unilever Brasil Kibon busca-se um modelo capaz de trabalhar com as características claras de sazonalidade e tendência apresentadas pelos dados históricos de venda da companhia. Entretanto, para se chegar até um modelo que considere todos estes fatores será feita uma breve discussão a respeito dos modelos mais simples que se utilizam da suavização exponencial e que trabalham com situações menos complexas.

### **5.9.2. Métodos de Suavização Exponencial**

A Suavização Exponencial pode ser considerada uma extensão do método de Média Móvel. Neste, todos os valores passados recebem pesos iguais, ao passo que na Suavização, parte-se do pressuposto que os dados mais recentes oferecem informação mais precisa a respeito do que irá ocorrer no futuro. Desta forma, os valores recentes recebem pesos maiores e estes pesos decrescem de maneira exponencial, conforme os dados se tornam mais antigos. Estes dados são utilizados no cálculo dos parâmetros do Modelo de Previsão de Vendas.

A seguinte equação pode ser empregada para expressar o conceito de Suavização Exponencial:

$$\boxed{F_{t+1} = \alpha \cdot Y_t + (1 - \alpha) F_t} \quad (18)$$

onde:

$F_{t+1}$  é o valor calculado do parâmetro F para o período seguinte (t+1);

$Y_t$  é o valor real verificado no período atual (t);

$F_t$  é o valor anteriormente calculado para o parâmetro F para o período atual (t);

$$0 \leq \alpha \leq 1.$$

Segundo HANKE (1998), o método de Suavização Exponencial revisa continuamente os valores dos parâmetros do modelo de previsão levando em consideração a ocorrência real dos valores no instante presente.

Este método de suavização apresenta este nome porque os termos considerados no cálculo têm seus pesos conferidos segundo uma tendência exponencial. Para demonstrar isto, parte-se da equação (18):

$$\boxed{F_{t+1} = \alpha \cdot Y_t + (1 - \alpha) F_t} \quad (18)$$

Aplicando a mesma equação para  $F_t$  tem-se:

$$\boxed{F_t = \alpha \cdot Y_{t-1} + (1 - \alpha) F_{t-1}} \quad (19)$$

Adotando este procedimento repetidas vezes e substituindo os valores de F na equação original tem-se:

$$\boxed{F_t = \alpha \cdot Y_t + \alpha \cdot (1 - \alpha) \cdot Y_{t-1} + \alpha \cdot (1 - \alpha)^2 \cdot Y_{t-2} + \alpha \cdot (1 - \alpha)^3 \cdot Y_{t-3} + \alpha \cdot (1 - \alpha)^{t-1} \cdot Y_1 + \alpha \cdot (1 - \alpha)^t \cdot F_1} \quad (20)$$

Conforme pode ser verificado nesta equação os pesos conferidos aos valores passados decrescem de maneira exponencial, dando origem ao termo suavização exponencial.

O parâmetro da suavização exponencial, representado pelo símbolo  $\alpha$ , denominado constante de suavização exponencial, determina a velocidade de resposta diante de variações no valor real do parâmetro de previsão previsto pela equação.

Valores de  $\alpha$  próximos de 1 conferem maior capacidade de resposta da suavização exponencial diante de variações no comportamento do parâmetro previsto. Entretanto, esta velocidade também traz uma instabilidade na previsão, com valores oscilando bastante nos períodos. Em contrapartida, valores próximos de zero conferem uma estabilidade maior às previsões. No entanto, variações maiores nos parâmetros previstos incorrerão em tempos de resposta mais elevados na suavização exponencial.

A partir da suavização exponencial simples MAKRIDAKIS (1998) apresenta o método linear de Holt, adequado para situações onde existe comportamento de tendência verificado.

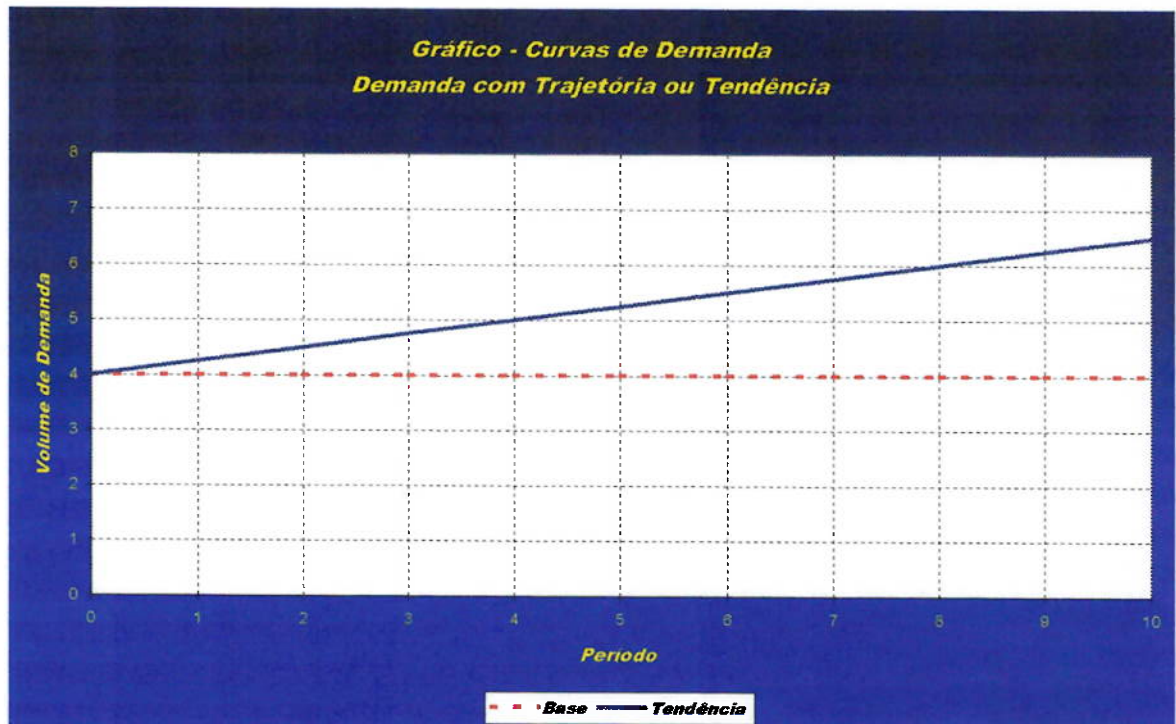
Neste caso, Holt se utiliza de duas equações de suavização exponencial para estimar os valores base e de tendência, segundo as equações:

$$\text{Base : } L_t = \alpha \frac{V_t}{F_{t-p}} + (1 - \alpha) (L_{t-1} + b_{t-1}) \quad (21)$$

$$\text{Tendência : } b_t = \beta (L_t - L_{t-1}) + (1 - \beta) b_{t-1} \quad (22)$$

A previsão é dada por:

$$\text{Previsão : } PD_{t+m} = L_t + b_t \cdot m \quad (23)$$



**Figura 11 - Demanda com Tendência**

No caso específico da Unilever Brasil Kibon, onde existe uma clara característica de tendência e também de sazonalidade no volume de vendas o modelo de previsão apresentado anteriormente não se mostra adequado. Para este caso, MAKRIDAKIS (1998) apresenta um modelo proposto inicialmente por Holt e Winter.

Este método é baseado em três equações de suavização, abordando os aspectos de sazonalidade, tendência, além de uma equação para o valor base de previsão. Vale ressaltar que este conjunto de equações é aplicável para modelos multiplicativos de sazonalidade.

$$\text{Base : } L_t = \alpha \frac{V_t}{F_{t-p}} + (1 - \alpha) (L_{t-1} + b_{t-1}) \quad (21)$$

$$\text{Tendência : } b_t = \beta (L_t - L_{t-1}) + (1 - \beta) b_{t-1} \quad (22)$$

$$\text{Sazonalidade : } F_t = \gamma \frac{V_t}{L_t} + (1 - \gamma) F_{t-p} \quad (24)$$

onde:

$\alpha$  = Constante de Suavização Exponencial do valor Base;

$L_t$  = Valor do parâmetro de Base dessazonalizado calculado no período t;

$V_t$  = Vendas reais no período t;

$F_{t-p}$  = Valor da constante sazonal no período t-p (utilizada aqui para dessazonalizar os valores de venda reais).

$L_{t-1}$  = Valor do parâmetro de Base no período anterior;

$b_{t-1}$  = Valor do parâmetro de Tendência no período anterior;

$\beta$  = Constante de Suavização Exponencial para Tendência;

$b_t$  = Valor do parâmetro de Tendência calculado para o período t;


$L_t$  = Valor do parâmetro de Base no período t;

$\gamma$  = Constante de Suavização Exponencial para Sazonalidade;

$F_{t-p}$  = Valor da constante sazonal no período t-p.

O valor de previsão de vendas para o período t + m é dado pela combinação das equações (21), (22) e (24) que resulta na seguinte expressão:

$$\text{Previsão : } PD_{t+m} = (L_t + b_t \cdot m) F_{t-p+m} \quad (25)$$



**Figura 12 - Demanda Cíclica com Tendência**

#### 5.9.2.1. Inicialização do Modelo de Suavização Exponencial

No caso de modelos recursivos, uma questão extremamente delicada é a definição dos valores iniciais dos parâmetros. O método de Suavização Exponencial também apresenta esta dificuldade. MAKRIDAKIS (1998) sugere o seguinte procedimento para a determinação dos valores iniciais de Base, Tendência e Sazonalidade:

Para o valor do parâmetro de Base, MAKRIDAKIS (1998) sugere que seja tirada a média dos valores do primeiro ciclo completo de sazonalidade segundo a equação:

$$L_p = \frac{1}{p} \sum_{i=1}^p V_i \quad (26)$$

O valor inicial do parâmetro de Tendência é dado pela equação:

$$b_p = \frac{1}{p} \sum_{i=1}^p \frac{V_{p+i} - V_i}{p} \quad (27)$$

Segundo MAKRIDAKIS (1998), cada um dos termos da somatória é uma estimativa da tendência após um ciclo completo de sazonalidade e a estimativa inicial de  $b_s$  é resultante da média dos  $p$  termos.

MAKRIDAKIS (1998) propõe o seguinte procedimento para o cálculo dos valores iniciais de constante de sazonalidade:

$$F_1 = \frac{V_1}{L_p}; \quad F_2 = \frac{V_2}{L_p}; \quad \dots \quad F_p = \frac{V_p}{L_p} \quad (28)$$

#### 5.9.2.2. Otimização do Modelo de Suavização Exponencial

No que diz respeito aos parâmetros  $\alpha$ ,  $\beta$  e  $\gamma$ , MAKRIDAKIS (1998) sugere que a escolha seja feita de maneira a minimizar o Desvio Quadrático Médio – DQM (ou *MSE – Mean Squared Error*) ou o Desvio Absoluto Percentual Médio – DAPM (ou *MAPE – Mean Absolute Percentage Error*), utilizando-se de um algoritmo de otimização não linear. Neste presente trabalho, é utilizado o recurso “*Solver*” presente na planilha de cálculo na qual as soluções serão implementadas (*Microsoft Excel™* versão 97).

#### 5.9.2.3. Classificação de Pegels

MARKIDAKIS (1998) apresenta o método proposto inicialmente por Pegels para classificar os Modelos baseados em Suavização Exponencial levando em consideração a natureza multiplicativa ou aditiva dos métodos em relação às componentes de Tendência e Sazonalidade. Segundo Pegels, os modelos de Suavização Exponencial podem ser classificados no seguinte quadro:

<b>Componente de Tendência</b>	<b>Componente Sazonal</b>		
	<b>1 (Nenhum)</b>	<b>2 (Aditivo)</b>	<b>3 (Multiplicativo)</b>
<b>A (nenhum)</b>	<b>A1</b>	<b>A2</b>	<b>A3</b>
<b>B (Aditivo)</b>	<b>B1</b>	<b>B2</b>	<b>B3</b>
<b>C (Mutiplicativo)</b>	<b>C1</b>	<b>C2</b>	<b>C3</b>

**Tabela 4 - Classificação de Pegels**

Pegels sugere que os diferentes métodos baseados em Suavização Exponencial podem ser resumidos em três equações:

$$L_t = \alpha P_t + (1 - \alpha) Q_t \quad (29)$$

$$b_t = \beta R_t + (1 - \beta) b_{t-1} \quad (30)$$

$$S_t = \gamma T_t + (1 - \gamma) S_{t-s} \quad (31)$$

Para cada uma das células do quadro proposto por Pegels são definidas as equações relativas a  $P_t$ ,  $Q_t$ ,  $R_t$ ,  $T_t$  e  $S_t$ .

O método de Suavização Exponencial apresentado em 5.9.2. baseado nas equações de Holt-Winter pode ser classificado na célula "B3".

### 5.9.3. Método baseado em Séries de Fourier

Um outro método de previsão de vendas para demanda sazonal é sugerido por HAX & CANDEA (1984), consistindo no emprego de funções harmônicas (séries de senos e cosenos) a partir da demonstração feita por Fourier de que qualquer função periódica (sazonal) finita e contínua poderia ser representada por um série matemática harmônica da forma:

$$PD_t = a_1 + b_2 \text{sen}(b_3 + b_4 t) + b_5 \text{cos}(b_6 + b_7 t) + \dots + b_{n-2} \text{cos}(b_{n-1} + b_n t) \quad (32)$$

Segundo a teoria de Fourier a série apresentada seria infinita. Entretanto, para uso prático, o que se faz é empregar uma série finita de termos para representar a função estudada, assumindo então uma aproximação. Segundo

BUFFA (1983), séries finitas de 4 a 14 termos são suficientes para produzir excelentes resultados em previsões para demanda sazonal.

Para utilização em casos onde, além da demanda ser sazonal, ela também apresenta componente de tendência, HAX & CANDEA (1984) sugerem uma pequena alteração na fórmula inicialmente proposta, acrescentando um termo relacionado ao período  $t$ , que responderia pela componente de tendência no modelo proposto:

$$PD_t = a_1 + b_1 t + b_2 \text{sen}(b_3 + b_4 t) + b_5 \text{cos}(b_6 + b_7 t) + \dots + b_{n-2} \text{cos}(b_{n-1} + b_n t) \quad (33)$$

Em relação a determinação dos coeficientes da função harmônica representada na equação (33) empregou-se procedimento análogo ao adotado em relação ao método de Suavização Exponencial, com a utilização de algoritmo de otimização não-linear da própria planilha eletrônica usada no estudo.

Em CHICOLI (2001) é proposta uma regra prática para determinação dos coeficientes da série harmônica de Fourier segundo a qual:

$$b_2 = \frac{(\text{máximo} - \text{mínimo})}{2} \quad (34)$$

$$a_1 = b_2 + \text{mínimo} \quad (35)$$

$$b_4 = \frac{2\pi}{\text{Período}} \quad (36)$$

Os demais coeficientes podem ser ajustados através de análise visual do gráfico da função de série de Fourier e com o auxílio do algoritmo de otimização não-linear da planilha eletrônica (MS-Excel™).

Segundo BUFFA (1979), a questão da multicolinearidade deve ser analisada com muito cuidado ao se aplicar o método de Séries de Fourier. A

---

multicolinearidade está associada às situações onde as variáveis independentes estão correlacionadas entre si. Nestes casos, o método dos Mínimos Quadrados não funciona de maneira eficiente na determinação dos valores dos coeficientes da função.

BUFFA (1979) sustenta que o método baseado em Série de Fourier é extremamente suscetível a este problema, tendo em vista que a teoria que o suporta implica em uma série infinita de termos, ou seja, em infinitas variáveis independentes relacionadas entre si e portanto suscetíveis a multicolinearidade.

Entretanto, BUFFA (1979) também afirma que isto não é um empecilho para sua utilização, uma vez que séries de Fourier com poucos termos além de minimizarem o problema da multicolinearidade apresentam resultados extremamente satisfatórios.

A equação de Fourier anteriormente apresentada fornece o valor de Previsão de Demanda através de método de adição. Claramente podem ser identificados os componentes de base, tendência ( $a+bt$ ) e sazonalidade (termos seno e cosseno). Da forma como a equação está definida, assume-se que todas estas componentes permanecerão constantes no tempo.

No entanto, da mesma forma que se aplicou o conceito de Suavização Exponencial para os componentes de Demanda nas equações de Holt-Winter, pode-se pensar em modificar o modelo de Séries de Fourier, de maneira a atualizar os componentes de Previsão de Demanda conforme o comportamento real das Vendas no decorrer do tempo.

Uma alternativa busca detectar a variação entre os valores reais e os previstos em períodos anteriores para tentar corrigir os valores futuros de previsão através da forma:

$$PD_{t, \text{corrigido}} = \frac{V_{t-1}}{PD_{t-1}} \alpha PD_t + (1 - \alpha) PD_t \quad (37)$$

onde  $0 \leq \alpha \leq 1$

## 5.10. Tracking

### 5.10.1. Modelos de resposta adaptativa

Os modelos de previsão de demanda baseados na suavização exponencial apresentam certa capacidade de reação diante de mudanças de comportamento da demanda. A velocidade de reação depende diretamente dos valores dos parâmetros destes modelos. Valores muito próximos de 1 para as constantes de suavização tornam o modelo extremamente instável, reagindo bruscamente diante de qualquer variação de demanda. Valores de constante de suavização exponencial muito próximos de zero, por sua vez, tornam o modelo estável porém lento diante de mudanças no comportamento da demanda.

Para lidar com este problema pode-se utilizar uma alternativa apresentada por MAKRIDAKIS (1998) na qual a constante de suavização exponencial sofre mudanças baseadas nos valores de desvio verificados no período. Este tipo de modelo é denominado Modelo de Previsão com Suavização Exponencial Simples de Resposta Adaptativa. Basicamente, este modelo utiliza-se das mesmas equações da Suavização Exponencial Simples apresentadas anteriormente. A diferença consiste no fato de que a constante de suavização exponencial deixa de ser constante e passa a variar conforme o desvio verificado no período segundo as equações:

$$\alpha_t = \frac{A_t}{M_t} \quad (38)$$

**onde**

$$A_t = \beta \cdot E_t + (1 - \beta) \cdot A_{t-1}$$

$$E_t = Y_t - F_t$$

$$M_t = \beta \cdot |E_t| + (1 - \beta) \cdot M_t$$

$$0 \leq \beta \leq 1$$

Para a previsão a equação é a seguinte:

$$\boxed{F_{t+1} = \alpha_t \cdot Y_t + (1 - \alpha_t) \cdot F_t} \quad (18)$$

A velocidade de reação do mecanismo adaptativo é dado pelo valor de  $\beta$ , de maneira similar ao que ocorre nas equações de suavização. Valem as mesmas observações a respeito da variação de  $\beta$  entre os valores zero e um.

### 5.10.2. Tracking Signal

Uma forma mais simples de lidar com as variações nos valores de parâmetro previstos pelas equações de suavização exponencial é através de um mecanismo chamado de sinal de rastreamento (*tracking*). Primeiramente é estabelecido algum tipo de medida de erro (desvio). Para esta medida de erro são definidos valores limite (inferior e superior, ou superior se o erro for tomado em módulo). Uma vez ultrapassado este limite toma-se algum tipo de medida corretiva. Um exemplo é o de definir que toda vez que o limite do erro for ultrapassado as constantes de suavização exponencial têm seus valores provisoriamente definidos em 1 ou próximo de 1 a fim de conferir maior agilidade para a resposta. Uma vez dentro da situação de estabilidade, isto é, com medidas de desvio dentro dos padrões pré-estabelecidos, os valores das constantes de suavização retornam ao originalmente definido.

### 5.11. Modelos de previsão causais

Os modelos de previsão causais adotam a premissa de que a variável a ser prevista (neste caso o volume de vendas) apresenta uma relação de causa e

efeito com uma ou mais variáveis independentes. Por exemplo, assume-se que o volume de vendas de uma Empresa está relacionado com o preço praticado, taxa de inflação, taxa de juros, etc.

O princípio básico dos modelos de previsão causais consiste em estabelecer este relacionamento entre as variáveis e a partir disto prever valores futuros. De acordo com os modelos causais, qualquer mudança nos dados de entrada do modelo afetam a saída (previsão) de maneira previsível. Uma premissa importante adotada por estes modelos é a de continuidade na relação entre as variáveis, ou seja, uma vez estabelecidas as relações de causa e efeito estas permanecem constantes no período de previsão.

### 5.11.1. Regressão linear simples

No modelo de previsão causal baseado em regressão linear simples, busca-se relacionar a variável a ser prevista  $Y$  com a variável independente de explicação  $X$  através da forma:

$$\boxed{Y = a + bX} \quad (39)$$

Os coeficientes  $a$  e  $b$  podem ser definidos através do Método de Mínimos Quadrados. Em resumo, este método parte de um conjunto de dados que relaciona  $Y_i$  e  $X_i$ , ou seja, diversos valores de  $Y$  para os instantes  $i$  e respectivos valores da variável de explicação  $X$ . A partir desta relação e com a equação definida busca-se calcular os valores de  $a$  e  $b$  que proporcionem o

menor valor de  $\sum_{t=1}^i (\hat{Y}_t - Y_t)^2$

**onde**

$\hat{Y}_t$  – valor estimado pela equação  $Y = a + bX$


$Y_t$  – valor real de  $Y$  para o período  $t$

Um indicador muito utilizado para a regressão linear simples é o coeficiente de correlação. Este indicador varia de  $-1$  a  $1$  e seus valores indicam o seguinte:


-1: correlação perfeita entre as variáveis e quando uma cresce a outra diminui.

0: não existe correlação entre as variáveis.


+1: correlação perfeita entre as variáveis e quando uma cresce a outra também tem seu valor aumentado.



**Figura 13 - Exemplo de Correlação positiva**



**Figura 14 - Exemplo de Correlação Negativa**



**Figura 15 - Exemplo de Correlação Nula**

Tomado em módulo, pode-se dizer que quanto mais próximo de 1 se encontra este coeficiente de correlação mais a equação consegue explicar o relacionamento entre as duas variáveis.

O coeficiente de correlação pode ser calculado por:

$$\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i \quad (40)$$

$$\bar{Y} = \frac{1}{n} \sum_{i=1}^n Y_i \quad (41)$$

$$Cov_{xy} = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y}) \quad (42)$$

$$S_x^2 = Cov_{xx} = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2 \quad (43)$$

$$S_Y^2 = \text{Cov}_{YY} = \frac{1}{n-1} \sum_{i=1}^n (Y_i - \bar{Y})^2 \quad (44)$$

$$r_{XY} = \frac{\text{Cov}_{XY}}{\sqrt{S_X^2} \cdot \sqrt{S_Y^2}} \quad (45)$$

### 5.11.2. Regressão linear múltipla

No modelo de previsão causal baseado em regressão linear múltipla, busca-se relacionar a variável a ser prevista Y com as variáveis independentes de explicação  $X_i$  através da forma:

$$Y = b_0 + b_1 X_1 + b_2 X_2 + \dots + b_k X_k \quad (46)$$

O procedimento para determinação dos coeficientes  $b_n$  é análogo ao descrito para a Regressão Linear Simples, baseando-se no Método dos Mínimos Quadrados.

No caso da regressão múltipla, o coeficiente de correlação também pode ser aplicado, tomando-se os fatores correlacionados dois a dois.

## 5.12. Modelos Avançados de Previsão de Demanda

### 5.12.1. Box-Jenkins

O método de Box-Jenkins é uma técnica mais avançada de Previsão que a princípio não assume nenhum padrão de comportamento para o conjunto de dados históricos da série temporal para a qual serão feitas as previsões. Este método aplica um processo iterativo de identificação de um possível modelo de Previsão a ser utilizado a partir de um conjunto de Modelos de Previsão de Demanda disponíveis. HANKE (1998) apresenta um conjunto de etapas que resumem a metodologia de Box-Jenkins:

Etapa1: Preparação -> Preparação dos dados de entrada (volumes de Venda);

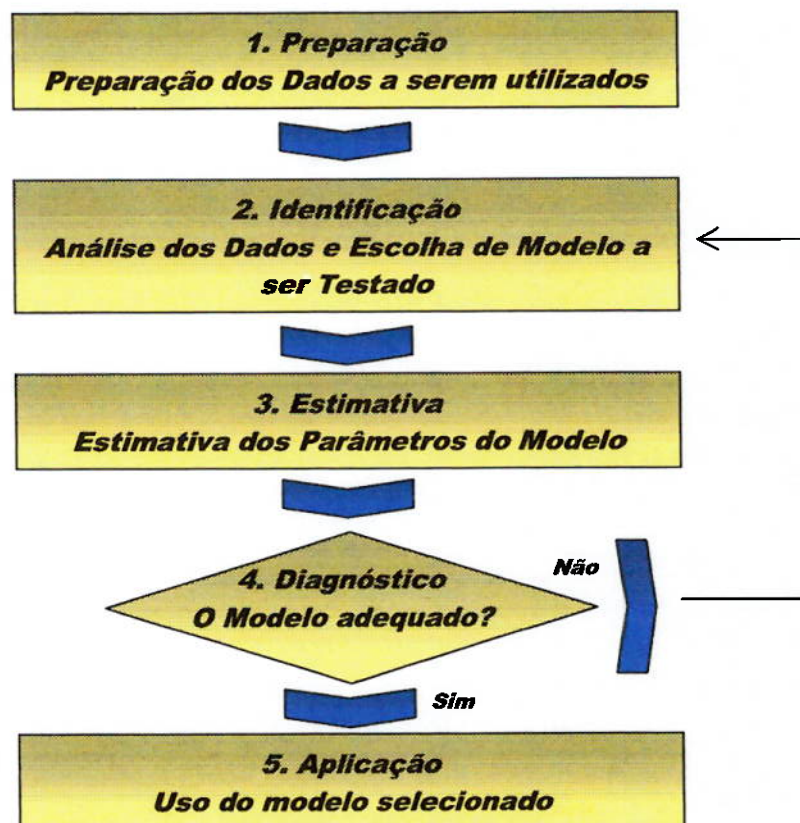
Etapa2: Identificação -> Análise dos dados e identificação do modelo a ser testado;

Etapa3: Estimativa -> Estimativa dos parâmetros do modelo

Etapa4: Diagnóstico -> Diagnóstico e seleção do modelo (através de testes estatísticos que visam medir o quão adequado o modelo é de acordo com os critérios previamente definidos);

Considera-se que o modelo é adequado quando os desvios (diferença entre valor real e valor previsto pelo modelo para um determinado período) são pequenos, aleatoriamente distribuídos e independentes. Enquanto estas condições não são atendidas o processo iterativo seleciona diferentes modelos de Previsão de Demanda.

Etapa5: Aplicação -> Uso do modelo selecionado para previsão.



**Figura 16 - Algoritmo Metodologia Box-Jenkins**

### **5.13. Modelos qualitativos de Previsão de Demanda**

Os modelos quantitativos de Previsão, sejam eles causais ou baseados em séries temporais, utilizam-se de informações passadas para através de algum tipo de extrapolação prever valores futuros. A premissa implicitamente assumida é a de que o padrão de comportamento passado irá se repetir no futuro.

Quando isso não se verifica, o valor de previsão obtido a partir destes modelos necessita sofrer algum tipo de ajuste de maneira a se tornar mais confiável. Este ajuste pode ser dado a partir da opinião da equipe de vendas, a partir das informações obtidas no campo, a partir de estratégias a serem adotadas pela Empresa, ou de qualquer outro dado de entrada de natureza subjetiva, que não possa ser facilmente quantificado, porém que exerce algum tipo de influência relevante sobre a variável de previsão.

Os modelos qualitativos de previsão partem deste princípio de funcionamento para chegarem aos valores de previsão.

HANKE (1998) sugere algumas alternativas de Métodos Qualitativos de Previsão de Demanda:

➤ Método Delphi

Segundo HANKE (1998), no método Delphi existe um grupo de coordenação das atividades que inicialmente distribui as questões aos diversos especialistas a serem consultados. Estes permanecem separados nesta etapa, respondendo às questões de maneira individual. O grupo de coordenação sumariza as respostas dos participantes e as envia a todos os especialistas para que estes possam analisar as respostas de todo o grupo, mantendo suas respectivas opiniões ou modificando-as a partir das respostas de outros especialistas.

Este processo continua por mais duas ou três rodadas até que o grupo de coordenação esteja satisfeito com os pontos de vista e considerações desenvolvidas no decorrer do processo. Pode-se também reunir o grupo inteiro no final para que seja conduzida uma discussão em grupo. Neste método, espera-se que as sucessivas rodadas resultem numa convergência de opiniões para um ponto em comum que consiga contemplar todas as observações pertinentes feitas pelos participantes no decorrer do processo.

➤ Método baseado em Cenários

Este método se baseia na construção de diferentes cenários para o futuro da Empresa, buscando reproduzir as principais alternativas vislumbradas pelas pessoas consultadas. Pode-se tentar montar cenários que reproduzam os efeitos de diferentes taxas de inflação, preços praticados pela Empresa e seus concorrentes, lançamento de produtos pela Empresa e pela concorrência, além de outros fatores.

Além destes, existem uma série de outros métodos de Previsão Qualitativos. Todos eles têm como princípio básico de funcionamento a utilização de algum tipo de método formal de análise e tomada de decisão a partir da opinião de um grupo de pessoas que estejam envolvidas com a operação e que sejam capazes de contribuir de maneira positiva para se chegar a um valor consensado de Previsão.

#### **5.14. Considerações a respeito dos modelos apresentados**

A Revisão Bibliográfica (capítulo 5) busca introduzir uma discussão a respeito dos principais Modelos de Previsão que podem ser empregados na solução do problema descrito em (capítulo 4), levando em consideração as peculiaridades da Demanda da Unilever Brasil Kibon, que apresenta comportamento claramente sazonal e extremamente sujeito a variações. Desta forma, todos os modelos pesquisados a priori poderiam ser utilizados para resolver o problema descrito. Entretanto, os modelos selecionados para a etapa de Implementação e testes devem atender aos requisitos definidos na seção 4.4.

#### **5.15. Modelos escolhidos para a próxima etapa**

O foco do trabalho, definido na seção 4.4. direcionou os esforços para os Modelos Quantitativos de Previsão baseados em Séries Temporais. Desta forma, os modelos de Suavização Exponencial e Séries de Fourier serão empregados na etapa seguinte deste projeto onde serão testados e avaliados buscando-se o(s) modelo(s) mais adequado(s) para cada recurso (SKU).

Desta forma, a escolha dos métodos baseados em Suavização Exponencial e em Séries de Fourier pode ser justificada pelos seguintes aspectos:

- Os dados necessários para a aplicação destes modelos estão disponíveis na Unilever Brasil Kibon. Isto já não ocorre no caso dos modelos baseados em regressão (Modelos Causais), os quais demandam informações que para serem disponibilizadas demandariam tempo e recursos;

- Os métodos em questão são de fácil implementação em mecanismos simples, como por exemplo uma planilha eletrônica (MS-Excel<sup>TM</sup>), sendo também de fácil compreensão por parte dos usuários do Sistema. O método de Box-Jenkins por sua vez é menos conhecido, mais complexo e de maior dificuldade de entendimento por parte dos usuários. Além disso, MAKRIDAKIS (1998) sugere que o custo de implementação desta solução seria mais elevado em comparação com os métodos baseados em Suavização Exponencial. O mesmo ocorre, em menor grau, com os modelos Causais;

### **5.16. Combinação de Modelos de Previsão de Demanda**

Segundo MAKRIDAKIS (1999) a precisão dos Modelos de Previsão pode ser melhorada através da combinação de diferentes modelos, ou seja, através do uso conjunto de diferentes técnicas de Previsão de Demanda. A variação dos desvios medidos na etapa de utilização do Modelo seria menor neste caso do que em comparação com a aplicação isolada dos modelos de Previsão.

Entretanto, MAKRIDAKIS (1998) sustenta que esta observação é de natureza empírica, havendo, portanto, opiniões contraditórias de outros autores que defendem a utilização de apenas um único modelo que na etapa de otimização minimize alguma medida de desvio previamente estabelecida (por exemplo: desvio médio quadrático).

A principal premissa adotada na utilização de um Modelo de Previsão Quantitativo, seja ele de natureza causal ou baseado em Séries Temporais é a continuidade. Isto é, assume-se que todas as relações e padrões de comportamento passado permanecerão constantes no futuro. Entretanto, este tipo de comportamento, principalmente no setor de bens de consumo não duráveis, caso da Unilever Brasil Kibon dificilmente é encontrado. Pode-se assumir uma certa parcela de continuidade, porém, deve-se buscar modelos que sejam capazes de acompanhar as mudanças que venham acontecer no comportamento da Demanda.

MAKRIDAKIS (1998) sustenta que a partir do momento que se utilizam modelos de Previsão de Demanda combinados, os erros de superestimação e de subestimação podem se cancelar de maneira a resultar em menores valores de Desvio Médio Quadrático, melhorando este aspecto de desempenho do Processo de Previsão de Demanda.

Neste presente trabalho, a partir dos dois principais modelos apresentados (Suavização Exponencial – Holt-Winter e Séries de Fourier) serão feitas diferentes combinações para que sejam também avaliadas na seção 6.4.:

- Combinação A: Suavização Exponencial + Série de Fourier
- Combinação B: Suavização Exponencial + Série de Fourier “Suavizada”
- Combinação C: Série de Fourier + Série de Fourier “Suavizada”
- Combinação D: Suavização Exponencial + Série de Fourier + Série de Fourier “Suavizada”

O peso conferido aos componentes da combinação é dado de maneira inversamente proporcional ao valor médio de desvio percentual do componente isolado, ou seja, maior peso é conferido ao componente que isoladamente apresenta menor valor de desvio.

O cálculo dos pesos pode ser representado pelas seguintes equações:

$$DT = \sum_{i=1}^n \frac{1}{DAPM_i} \quad (47)$$

$$Peso_i = \frac{1}{DAPM_i} \times \frac{1}{DT} \quad (48)$$

$$DAPM_i \geq 0$$

onde:

$n$  é o número de componentes da combinação;

$DAPM_i$  é o Desvio Absoluto Percentual Médio do componente  $i$  da combinação.

Se  $DAPM_i = 0$ , então o modelo tem aderência perfeita ao real e deverá ser utilizado individualmente.

## **6. Testes dos Modelos Apresentados**

### **6.1. Metodologia de Teste**

Dentro da metodologia apresentada na seção 2.1., após a Revisão Bibliográfica, a etapa seguinte (Etapa 2) consiste em implementar os modelos previamente selecionados em planilha eletrônica para que se proceda com os testes piloto, nos quais os modelos receberão conjuntos de dados idênticos para serem testados.

A etapa de Testes requer alguns passos para se concretizar. Uma primeira atividade desta etapa consiste em coletar os dados históricos de Vendas, a serem utilizados nas fases de Inicialização e Otimização. Os dados coletados devem passar por uma primeira análise buscando-se identificar valores a serem descartados devido a algum tipo de comportamento fora do normal. Nesta etapa, por exemplo, deve-se excluir os valores históricos referentes aos períodos onde tenha sido adotada alguma estratégia comercial e/ou de marketing de grande impacto que resulte em uma distorção dos volumes sem que se tenha recursos para definir qual teria sido o valor normal sem estas interferências.

Uma vez executados os testes piloto, os resultados coletados deverão ser compilados e analisados (Etapa 3) para a tomada de decisão de qual o modelo a ser implementado em definitivo na previsão de cada recurso da Empresa (SKU, Família, Linha, Total Geral) (Etapa 4).

Para a tomada de decisão é preciso especificar previamente qual o critério de seleção do Modelo de Previsão de Demanda. No caso deste presente trabalho, o critério de decisão será o menor valor médio de Desvio Absoluto Percentual (DAPM).

## **6.2. Itens / SKU's "pilotos" (a serem testados)**

Uma vez definidos os critérios de seleção dos Modelos de Previsão de Demanda, deve-se especificar sobre quais itens serão efetuados os primeiros testes. O plano é que em um determinado momento, todos os itens de linha da Empresa, tenham seus volumes previstos por um determinado modelo de Previsão, o mesmo valendo para volumes de venda de famílias e linhas. Entretanto, para o desenvolvimento deste trabalho, os primeiros testes serão efetuados sobre 25 itens, incluindo previsões para SKU's, para Famílias, Classes, Linhas e para o Total Geral de Vendas da Unilever Brasil Kibon. Acredita-se que a partir desta massa inicial de testes já é possível chegar a algumas conclusões a respeito da aplicabilidade de Modelos Quantitativos de Previsão de Demanda, tendo em vista os resultados dos testes em comparação com o desempenho do Mecanismo Atual de Previsão de Demanda desta Empresa. Além disso, o tempo disponível para o desenvolvimento deste trabalho não permite que o processo seja conduzido de maneira cuidadosa para os mais de 150 itens a terem Modelos de Previsão de Demanda.

Os itens selecionados para a etapa de Testes, análise de Resultados e Validação dos Modelos propostos receberam nomes fictícios a pedido da Empresa, de maneira a manter a confidencialidade dos dados relativos aos Volumes de Venda da Unilever Brasil Kibon. Os itens são os seguintes:

<b>Código</b>	<b>Descrição</b>
<b>P001</b>	<b>Classe -&gt; Camburi</b>
<b>P002</b>	<b>Família -&gt; Juqueí</b>
<b>P003</b>	<b>SKU -&gt; Boiçucanga</b>
<b>P004</b>	<b>SKU -&gt; Ilhabela</b>
<b>P005</b>	<b>SKU -&gt; Calhetas</b>
<b>P006</b>	<b>SKU -&gt; Engenho</b>
<b>P007</b>	<b>SKU -&gt; Juréia</b>
<b>P008</b>	<b>SKU -&gt; Barra do Sai</b>
<b>P009</b>	<b>SKU -&gt; Maresias</b>
<b>P010</b>	<b>Linha -&gt; S. Sebastião</b>
<b>P011</b>	<b>SKU -&gt; Vermelha</b>
<b>P012</b>	<b>Classe -&gt; Almada</b>
<b>P013</b>	<b>SKU -&gt; Flamengo</b>
<b>P014</b>	<b>SKU -&gt; Prumirim</b>
<b>P015</b>	<b>SKU -&gt; Toninhas</b>
<b>P016</b>	<b>SKU -&gt; Lázaro</b>
<b>P017</b>	<b>SKU -&gt; Lagoa</b>
<b>P018</b>	<b>SKU -&gt; Tenório</b>
<b>P019</b>	<b>SKU -&gt; Félix</b>
<b>P020</b>	<b>Linha -&gt; Ubatuba</b>
<b>P021</b>	<b>Classe -&gt; Astúrias</b>
<b>P022</b>	<b>SKU -&gt; Pitangueiras</b>
<b>P023</b>	<b>SKU -&gt; Enseada</b>
<b>P024</b>	<b>Linha -&gt; Guarujá</b>
<b>P025</b>	<b>Linha -&gt; Santos</b>

**Tabela 5 - Itens selecionados para Teste**

### **6.3. Coleta de Dados de Vendas**

Os volumes históricos de Vendas disponíveis para este presente trabalho referem-se ao período compreendido entre Janeiro de 1997 e Setembro de 2001. Para a etapa de Inicialização foram empregados os dados históricos de vendas referentes aos anos de 1997 e 1998. Para a etapa de calibração do modelo, foram utilizados os dados de vendas relativos aos anos de 1999 e 2000. Finalmente, para a etapa de Validação foram considerados os dados

históricos de vendas referentes ao período compreendido entre Janeiro de 2001 e Setembro de 2001.

Vale ressaltar que nem todos os itens estavam em linha em Janeiro de 1997. Para estes casos, onde o volume de dados disponíveis é menor, as modificações necessárias nos procedimentos de inicialização e otimização serão feitas de maneira a viabilizar o teste dos modelos de Previsão de Demanda também para estes itens. As modificações incluem a utilização de menos dados para as etapas de inicialização e otimização, porém sempre com o cuidado para não comprometer a confiabilidade dos resultados apresentados pelos Modelos de Previsão de Demanda.

#### **6.4. Modelos a serem testados**

De acordo com o definido nas seções 5.15 e 5.16, os modelos a serem testados são os seguintes:

- Modelo1: Suavização Exponencial
- Modelo2: Série de Fourier
- Modelo3: Série de Fourier "Suavizada"
- Combinação A: Suavização Exponencial + Série de Fourier
- Combinação B: Suavização Exponencial + Série de Fourier "Suavizada"
- Combinação C: Série de Fourier + Série de Fourier "Suavizada"
- Combinação D: Suavização Exponencial + Série de Fourier + Série de Fourier "Suavizada"

## 7. Análises Comparativas

### 7.1. Análise dos dados obtidos para cada modelo aplicado – recomendação de modelos a serem utilizados

Para cada um dos itens selecionados para a etapa de testes foram aplicados os modelos apresentados na seção 6.4., sendo medidos os valores relativos a DAPM e DPM e seus respectivos Desvios Padrão. A princípio foram definidas duas estratégias de escolha dos modelos. A primeira consistia em escolher o modelo que apresentasse o menor valor de DAPM. A segunda, levando em consideração indícios de que modelos de previsão combinados poderiam tender a apresentar resultados melhores em situações dinâmicas de uso, nas quais as condições verificadas na etapa de testes modificam-se muito rapidamente, consistia em escolher o menor valor de DAPM dentre os 4 modelos combinados de Previsão de Demanda.

Este procedimento foi adotado para cada um dos 25 itens selecionados para esta etapa de testes. Um exemplo de tabela de análise utilizada nesta etapa é apresentada a seguir:

#### **Desempenho dos Modelos de Previsão**

Item: **P025 - Família -> Santos**

<b>Calibração</b>				
<b>Período 99/00</b>				
<b>Modelo</b>	<b>MAPE</b>	<b>DesvPad</b>	<b>MPE</b>	<b>DesvPad</b>
<b>(1)</b>	<b>15,3%</b>	<b>10,9%</b>	<b>-7,2%</b>	<b>17,6%</b>
<b>(2)</b>	<b>22,7%</b>	<b>17,6%</b>	<b>6,3%</b>	<b>28,4%</b>
<b>(3)</b>	<b>18,6%</b>	<b>11,9%</b>	<b>2,3%</b>	<b>22,3%</b>
<b>(A)</b>	<b>20,3%</b>	<b>13,6%</b>	<b>3,8%</b>	<b>24,4%</b>
<b>(B)</b>	<b>16,9%</b>	<b>8,6%</b>	<b>-3,1%</b>	<b>19,1%</b>
<b>(C)</b>	<b>15,6%</b>	<b>8,3%</b>	<b>-3,8%</b>	<b>17,5%</b>
<b>(D)</b>	<b>17,0%</b>	<b>8,7%</b>	<b>-1,6%</b>	<b>19,4%</b>

**Tabela 6 - Exemplo de Tabela Análise Desempenho Modelos de Previsão**

Os resultados para os 25 itens previamente selecionados, compilados de acordo com as 2 principais estratégias de escolha de Modelos de Previsão de Demanda foram analisados para se escolher qual das duas estratégias seria seguida:

**Etapa: Inicialização e Testes**

**DAPM - Desvio Absoluto Percentual Médio (MAPE - Mean Absolute Percentage Error)**

**Critério: Menor DAPM Individual**

Código	Descrição	Modelo	1999 - 2000		1999 - 2000		Diferença
			Modelo Previsão		Sistema Atual		
			Média	Desvio Padrão	Média	Desvio Padrão	
P001	Classe -> Camburi	(C)	17,7%	11,8%	24,6%	15,4%	-28,1%
P002	Família -> Juqueí	(C)	23,5%	14,1%	31,4%	18,2%	-25,1%
P003	SKU -> Boiçucanga	(3)	20,5%	17,7%	27,8%	16,9%	-26,3%
P004	SKU -> Ilhabela	(3)	18,2%	15,2%	21,3%	15,9%	-14,4%
P005	SKU -> Calhetas	(1)	2,7%	7,5%	49,5%	25,2%	-94,6%
P006	SKU -> Engenho	(D)	14,5%	11,1%	26,2%	18,9%	-44,8%
P007	SKU -> Juréia	(2)	15,2%	10,9%	26,8%	18,8%	-43,1%
P008	SKU -> Barra do Sai	(C)	15,2%	2,6%	26,7%	18,8%	-43,2%
P009	SKU -> Maresias	(C)	14,5%	14,3%	35,9%	15,0%	-59,5%
P010	Linha -> S. Sebastião	(C)	18,4%	11,5%	22,7%	15,1%	-18,9%
P011	SKU -> Vermelha	(C)	20,3%	17,1%	29,3%	23,7%	-30,7%
P012	Classe -> Almada	(3)	14,6%	9,1%	16,7%	13,4%	-12,8%
P013	SKU -> Flamengo	(C)	14,9%	11,2%	22,8%	16,5%	-34,7%
P014	SKU -> Prumirim	(3)	15,1%	10,7%	16,6%	13,2%	-9,3%
P015	SKU -> Toninhas	(D)	17,9%	11,4%	18,0%	13,6%	-0,5%
P016	SKU -> Lázaro	(3)	18,2%	13,5%	28,3%	23,4%	-35,5%
P017	SKU -> Lagoa	(3)	11,9%	8,7%	21,7%	17,1%	-45,3%
P018	SKU -> Tenório	(1)	28,1%	17,7%	30,9%	30,1%	-8,8%
P019	SKU -> Felix	(1)	22,6%	16,8%	26,6%	17,2%	-14,8%
P020	Linha -> Ubatuba	(1)	14,6%	13,2%	16,6%	12,9%	-12,3%
P021	Classe -> Astúrias	(B)	5,0%	9,1%	19,7%	21,5%	-74,5%
P022	SKU -> Pitangueiras	(1)	8,1%	16,9%	37,6%	34,1%	-78,4%
P023	SKU -> Enseada	(1)	5,7%	13,3%	47,5%	53,2%	-88,0%
P024	Linha -> Guarujá	(C)	10,9%	7,7%	15,3%	11,3%	-28,5%
P025	Linha -> Santos	(1)	15,3%	10,9%	17,0%	11,6%	-9,7%

Média -> **-35,3%**

Diferença é o Desempenho do Modelo de Previsão em relação ao Sistema Atual

**Tabela 7 - Resultados Etapa de Testes - Critério: menor DAPM individual**

**Etapa: Inicialização e Testes****DAPM - Desvio Absoluto Percentual Médio (MAPE - Mean Absolute Percentage Error)****Critério: Menor DAPM Combinado**

Código	Descrição	Modelo	1999 - 2000 Modelo Previsão		1999 - 2000 Sistema Atual		Diferença
			Média	Desvio Padrão	Média	Desvio Padrão	
P001	Classe -> Camburi	(C)	17,7%	11,8%	24,6%	15,4%	-28,1%
P002	Família -> Juqueí	(C)	23,5%	14,1%	31,4%	18,2%	-25,1%
P003	SKU -> Boiçucanga	(C)	22,9%	16,3%	27,8%	16,9%	-17,7%
P004	SKU -> Ilhabela	(A)	18,4%	15,7%	21,3%	15,9%	-13,6%
P005	SKU -> Calhetas	(C)	5,6%	6,8%	49,5%	25,2%	-88,8%
P006	SKU -> Engenho	(D)	14,5%	11,1%	26,2%	18,9%	-44,8%
P007	SKU -> Juréia	(A)	15,2%	10,9%	26,8%	18,8%	-43,1%
P008	SKU -> Barra do Sai	(C)	15,2%	2,6%	26,7%	18,8%	-43,2%
P009	SKU -> Maresias	(C)	14,5%	14,3%	35,9%	15,0%	-59,5%
P010	Linha -> S. Sebastião	(C)	18,4%	11,5%	22,7%	15,1%	-18,9%
P011	SKU -> Vermelha	(C)	20,3%	17,1%	29,3%	23,7%	-30,7%
P012	Classe -> Almada	(A)	16,2%	13,4%	16,7%	13,4%	-3,0%
P013	SKU -> Flamengo	(C)	14,9%	11,2%	22,8%	16,5%	-34,7%
P014	SKU -> Prumirim	(A)	15,9%	11,0%	16,6%	13,2%	-4,1%
P015	SKU -> Toninhas	(D)	17,9%	11,4%	18,0%	13,6%	-0,5%
P016	SKU -> Lázaro	(A)	18,2%	13,6%	28,3%	23,4%	-35,6%
P017	SKU -> Lagoa	(A)	12,1%	8,0%	21,7%	17,1%	-44,3%
P018	SKU -> Tenório	(C)	28,7%	14,9%	30,9%	30,1%	-7,2%
P019	SKU -> Felix	(C)	22,7%	15,1%	26,6%	17,2%	-14,8%
P020	Linha -> Ubatuba	(C)	15,4%	8,7%	16,6%	12,9%	-7,2%
P021	Classe -> Astúrias	(B)	5,0%	9,1%	19,7%	21,5%	-74,5%
P022	SKU -> Pitangueiras	(B)	11,1%	15,9%	37,6%	34,1%	-70,5%
P023	SKU -> Enseada	(B)	7,5%	11,7%	47,5%	53,2%	-84,2%
P024	Linha -> Guarujá	(C)	10,9%	7,7%	15,3%	11,3%	-28,5%
P025	Linha -> Santos	(C)	15,6%	8,3%	17,0%	11,6%	-8,4%

Média -> **-33,2%**

Diferença é o Desempenho do Modelo de Previsão em relação ao Sistema Atual

**Tabela 8 - Resultados Etapa de Testes - Critério: menor DAPM modelos combinados**

Conforme pode ser analisado na comparação entre as duas estratégias, os resultados obtidos apresentam valores muito parecidos. Em média, a estratégia de se escolher o menor DAPM dentre todos os modelos resulta em redução da ordem de 35,0% nos desvios de Previsão de Demanda, ao passo que a estratégia de escolha do menor DAPM dentre os modelos combinados resulta em queda de 33,2% nos desvios de Previsão. A maior redução de desvios da estratégia de menor DAPM dentre todos os modelos, bem como a redução mais significativa nos itens mais importantes para a Empresa fez com que o autor escolhesse esta estratégia para definir os modelos de Previsão de Demanda a serem adotados para cada um dos itens a serem trabalhados no processo de Estimativa.

Além disso, observando os resultados comparativos relativos a estratégia 1 pode-se perceber que 44,0% dos modelos selecionados são combinados e 56,0% são individuais. Portanto, não existem indícios que levem a conclusão de que sempre os modelos combinados se mostram melhores que os modelos de Previsão de Demanda Simples.

Estratégia1: menor MAPE dentre todos

<b>Modelo</b>	<b>Freq</b>	<b>%</b>
<b>1</b>	<b>7</b>	<b>28,0</b>
<b>2</b>	<b>1</b>	<b>4,0</b>
<b>3</b>	<b>6</b>	<b>24,0</b>
<b>A</b>	<b>0</b>	<b>0,0</b>
<b>B</b>	<b>1</b>	<b>4,0</b>
<b>C</b>	<b>8</b>	<b>32,0</b>
<b>D</b>	<b>2</b>	<b>8</b>
<b>total</b>	<b>25</b>	<b>100,0</b>

**Tabela 9 – Frequência de Escolha dos Modelos - Estratégia 1**

## **7.2. Considerações sobre cada modelo**

Um aspecto muito importante na escolha do modelo de Previsão de Demanda que foi considerado neste trabalho foi o da aplicabilidade do modelo em situações reais. Desta forma, procurou-se avaliar qual seria a praticidade de

aplicação de um modelo em escala real, na qual existem mais de 150 itens a serem trabalhados no processo de Estimativa.

Portanto, na etapa de testes buscou-se avaliar o tempo a ser gasto nas diversas etapas de desenvolvimento de um modelo de Previsão de Demanda para determinado item, principalmente nas etapas de calibração e inicialização.

Percebeu-se que, via de regra, os modelos de Fourier e Fourier Suavizado foram os que mais consumiram tempo na etapa de inicialização e calibração. Isto pode ser explicado parcialmente pelo fato de que estes modelos utilizam-se de 13 e 14 variáveis, respectivamente. Além disso, a mudança de valor de uma variável dentre estas dificilmente pode ter seus efeitos previstos. Desta forma, o que se faz é alterar o valor da variável e testar os efeitos desta mudança. Um outro aspecto importante em relação ao modelo baseado em séries de Fourier é que ele exige uma revisão mais detalhada dos seus parâmetros ao final da temporada, visto que este modelo não apresenta característica de adaptação a variações no comportamento da Demanda, ao contrário dos modelos baseados no conceito de Suavização.

Já o modelo baseado em Suavização Exponencial utiliza-se de apenas 7 variáveis. Além disso, uma vez que o modelo empregado baseia-se nas equações de Holt-Winter, separando as diversas componentes da Demanda (Base, Tendência, Sazonalidade), fica mais fácil prever qual o efeito de uma eventual alteração no valor de alguma das variáveis do modelo.

Por último, os modelos combinados de previsão de Demanda apenas necessitam dos pesos a serem conferidos aos diversos componentes da combinação. São os mais fáceis de serem parametrizados, porém estes modelos apenas se utilizam de resultados obtidos na aplicação dos modelos de Suavização e Fourier (normal e suavizado). Desta forma, quaisquer mudanças mais profundas implicam em alterar variáveis destes modelos básicos.

No decorrer desta etapa de testes percebeu-se que mesmo a manutenção dos modelos baseados em Série de Fourier, apesar de mais demorada, não apresenta maiores problemas mesmo para a escala real de uso (com mais de 150 SKU a serem trabalhados).

## **8. Aplicação prática dos Modelos**

### **8.1. Etapa de Validação**

Na fase de testes os modelos de previsão para cada um dos itens foram selecionados segundo um critério de desempenho estipulado. Entretanto, os valores médios de desvio percentual (DAPM) obtidos nesta etapa não são necessariamente os verificados na utilização do modelo. Tal fato ocorre pois os modelos são calibrados e “otimizados” segundo os valores históricos de venda (neste caso referentes aos anos de 1999/2000) e por muitas vezes as condições verificadas neste período não são as mesmas observadas no período de utilização destes modelos.

Portanto, uma outra etapa tão importante quanto a escolha do modelo de Previsão de Demanda a ser empregado em cada um dos itens a serem trabalhados no processo de Estimativa é a etapa de validação dos resultados.

Nesta etapa, os modelos selecionados para cada um dos 25 itens da fase de testes são aplicados e têm seus resultados comparados com os valores reais referentes ao período de Jan/2001 a Set/2001. Desta forma, busca-se simular um possível comportamento destes modelos de Previsão diante de um situação real de uso. Importante ressaltar que estes dados da fase de validação não são considerados nas etapas anteriores de calibração e inicialização. Isso, de uma certa forma, garante que os resultados da simulação de uso sejam confiáveis, uma vez que para o Modelo de Previsão de Demanda estes dados são novos e têm o mesmo efeito de uma situação real de uso. É a partir destes resultados que se pode ter uma estimativa de como o modelo se comportará na realidade.

Além disso, a etapa de validação, como o próprio nome diz, serve também para que as escolhas feitas em etapas anteriores sejam validadas, ou seja, para que os modelos de Previsão previamente selecionados tenham suas escolhas confirmadas.

Os resultados desta etapa de utilização foram coletados para cada um dos 25 itens previamente trabalhados. O modelo de tabela de análise é apresentado a seguir:

<b>Quadro Comparativo -&gt; Vendas Reais x Previsão (Sistema Atual e Modelo Proposto)</b>										
<b>Item</b>	<b>Descrição</b>									
<b>P001</b>	<b>Classe Camburi</b>									
	<b>Jan/01</b>	<b>Fev/01</b>	<b>Mar/01</b>	<b>Abr/01</b>	<b>Mai/01</b>	<b>Jun/01</b>	<b>Jul/01</b>	<b>Ago/01</b>	<b>Set/01</b>	<b>Média</b>
<b>Real</b>	4.019,2	3.134,9	2.179,5	1.058,0	841,2	476,8	750,3	1.032,3	1.601,1	
<b>Prev Modelo</b>	2.421,6	2.437,1	1.917,5	1.374,4	834,6	618,8	870,8	1.145,5	1.649,8	
<b>Real - Previsão</b>	1.597,6	697,8	262,0	-316,4	6,6	-142,1	-120,5	-113,2	-48,7	
<b>SFE Modelo</b>	66,0%	28,6%	13,7%	23,0%	0,8%	23,0%	13,8%	9,9%	3,0%	20,2% <- MAPE
<b>SFB</b>	66,0%	28,6%	13,7%	-23,0%	0,8%	-23,0%	-13,8%	-9,9%	-3,0%	4,0% <- MPE
<b>Prev Atual</b>	5.491,3	3.170,4	2.323,6	1.435,0	1.439,2	1.210,0	1.094,5	834,1	2.230,4	
<b>Real - Previsão</b>	-1.472,1	-35,6	-144,0	-377,0	-597,9	-733,2	-344,2	198,2	-629,3	
<b>SFE Atual</b>	26,8%	1,1%	6,2%	26,3%	41,5%	60,6%	31,4%	23,8%	28,2%	27,3% <- MAPE

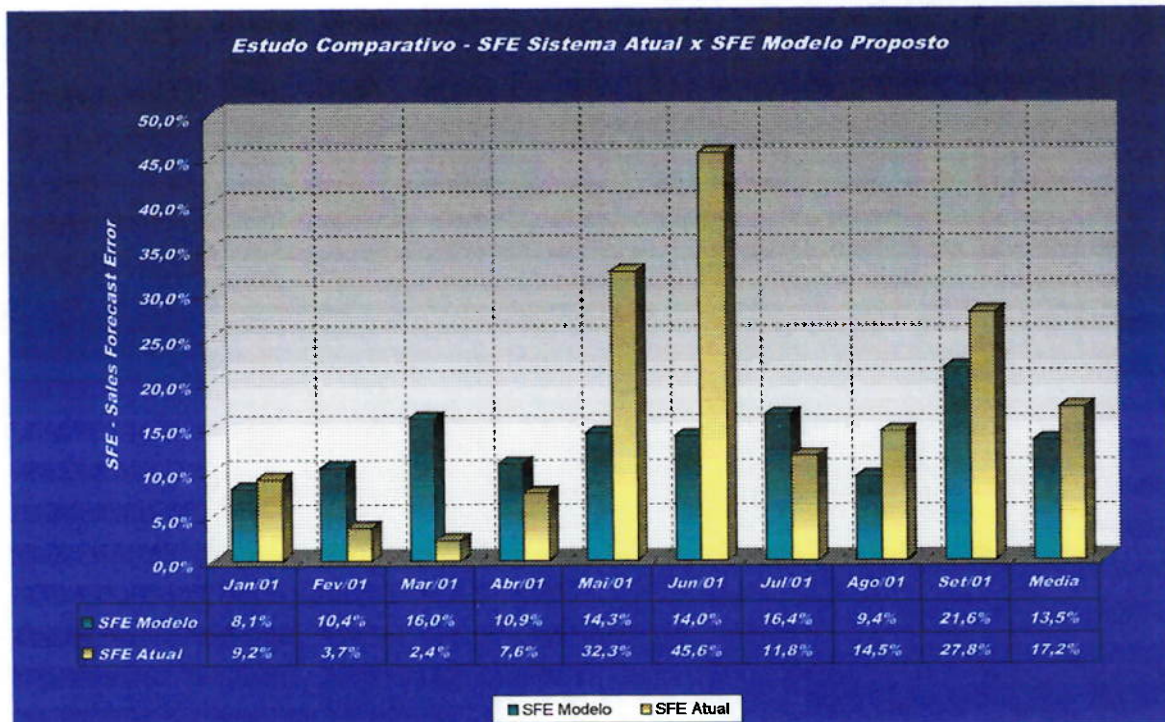
**Obs.: Volumes indicados em TONS**  
1 TON = 1.000 litros

**Tabela 10 - Modelo de Tabela de Análise Vendas Reais x Previsão (Sistema Atual e Modelo Proposto)**

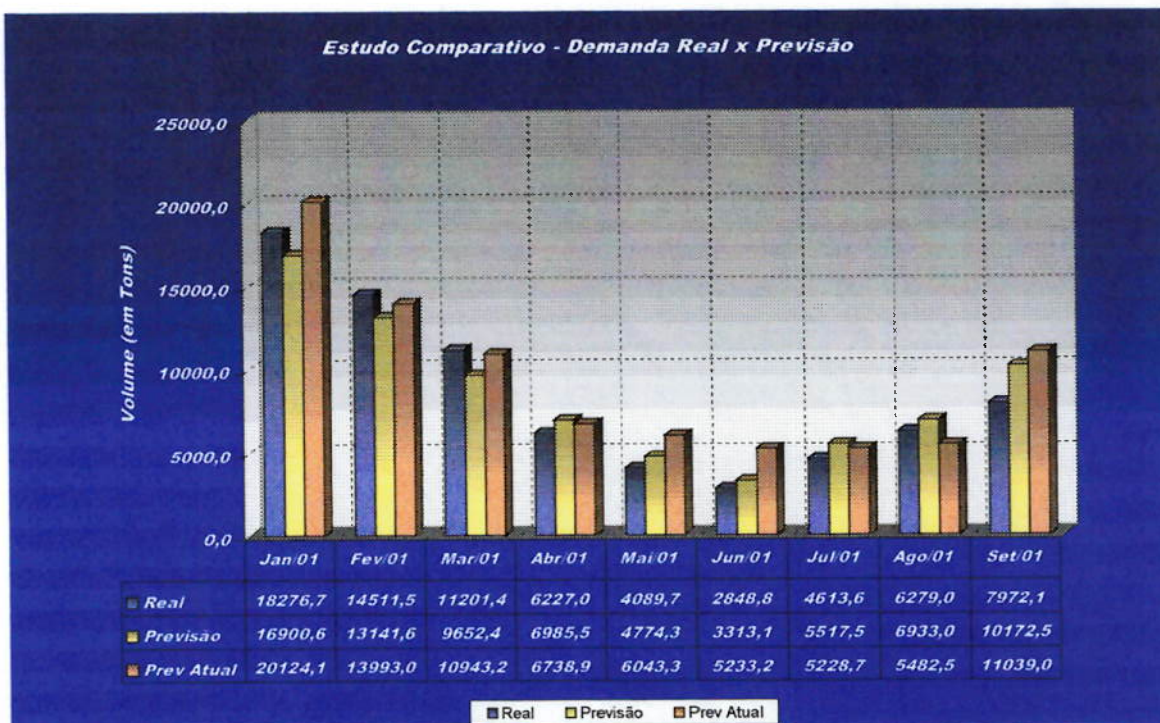
Um detalhe a ser mencionado é que a unidade de medida em uso na Unilever Brasil Kibon é o "ton", onde 1 ton equivale a 1.000 litros. O ton não apresenta relação direta com a unidade "tonelada" (1 t = 1.000 kg).

Neste estudo, a análise é também complementada por gráficos comparativos que visam facilitar a visualização das informações levantadas.

Para cada um dos 25 itens utilizados neste trabalho, foram analisados gráficos comparativos entre Vendas Reais e Vendas previstas pelo sistema Atual e pelo Modelo de Previsão proposto. Foram também construídos gráficos comparativos entre os indicadores de Desvio (DAPM ou SFE) do Sistema Atual de Estimativa e do Modelo de Previsão proposto.



**Figura 17 - Gráfico Comparativo - Demanda Real x Previsão**



**Figura 18 - Gráfico Comparativo - SFE (Sales Forecast Error)**

Os resultados para cada um dos itens foram compilados segundo a tabela apresentada em seguida:

**Etapa: Validação**

**DAPM - Desvio Absoluto Percentual Médio (MAPE - Mean Absolute Percentage Error)**

**Critério: Menor DAPM Individual**


Código	Descrição	Modelo	2001 Modelo Previsão		2001 Sistema Atual		Diferença
			Média	Desvio Padrão	Média	Desvio Padrão	
P001	Classe -> Camburi	(C)	20,2%	19,5%	27,3%	17,6%	-26,1%
P002	Família -> Juqueí	(C)	25,6%	11,2%	33,5%	23,3%	-23,5%
P003	SKU -> Boiçucanga	(3)	27,5%	19,3%	32,1%	23,0%	-14,4%
P004	SKU -> Ilhabela	(3)	19,2%	13,1%	24,7%	17,0%	-22,4%
P005	SKU -> Calhetas	(1)	22,8%	12,0%	34,4%	20,9%	-33,9%
P006	SKU -> Engenho	(D)	19,3%	11,5%	29,3%	17,6%	-34,3%
P007	SKU -> Juréia	(2)	17,8%	14,7%	27,5%	17,0%	-35,2%
P008	SKU -> Barra do Sai	(C)	13,2%	10,1%	16,1%	14,8%	-17,9%
P009	SKU -> Maresias	(C)	21,8%	19,8%	24,2%	16,6%	-9,6%
P010	Linha -> S. Sebastião	(C)	11,7%	9,4%	25,7%	15,5%	-54,4%
P011	SKU -> Vermelha	(C)	14,3%	12,4%	19,9%	14,7%	-27,8%
P012	Classe -> Almada	(3)	10,8%	12,2%	16,8%	14,7%	-35,6%
P013	SKU -> Flamengo	(C)	17,1%	11,2%	25,0%	16,4%	-31,7%
P014	SKU -> Prumirim	(3)	14,6%	12,8%	18,2%	10,0%	-19,9%
P015	SKU -> Toninhas	(D)	14,8%	10,8%	17,1%	17,2%	-13,9%
P016	SKU -> Lázaro	(3)	17,2%	18,9%	17,2%	15,6%	0,4%
P017	SKU -> Lagoa	(3)	10,6%	10,7%	17,0%	10,8%	-37,8%
P018	SKU -> Tenorio	(1)	22,7%	20,0%	47,0%	70,1%	-51,6%
P019	SKU -> Felix	(1)	26,2%	24,2%	18,2%	17,6%	43,8%
P020	Linha -> Ubatuba	(1)	14,1%	9,9%	16,6%	14,3%	-15,2%
P021	Classe -> Astúrias	(B)	12,5%	10,2%	15,3%	8,8%	-18,5%
P022	SKU -> Pitangueiras	(1)	24,6%	16,6%	43,5%	19,0%	-43,5%
P023	SKU -> Enseada	(1)	15,0%	13,1%	23,4%	16,5%	-36,0%
P024	Linha -> Guarujá	(C)	9,2%	6,9%	15,8%	8,1%	-41,8%
P025	Linha -> Santos	(1)	13,5%	4,2%	17,2%	14,8%	-21,7%
<b>Média -&gt;</b>							<b>-24,9%</b>

Diferença é o Desempenho do Modelo de Previsão em relação ao Sistema Atual

**Tabela 11 - Resultados Etapa de Validação**

Os resultados obtidos indicam que em média, espera-se um redução de 24,9% nos desvios absolutos percentuais do Processo de Estimativa de Demanda. Além disso, dos 25 itens trabalhados, houve redução de desvios em 23 (92,0% dos casos). Em 1 caso, o desempenho do modelo selecionado ficou

praticamente igual ao sistema atual de Previsão de Demanda. Em 1 caso específico, houve piora do desempenho do processo de Estimativa. Para este caso, pode-se buscar um outro modelo de Previsão de Demanda ou até mesmo utilizar-se somente das componentes subjetivas de Estimativa (sob responsabilidade de Marketing e Trade Marketing).



**Figura 19 - Gráfico Comparativo - Desempenho Modelos de Previsão x Sistema Atual**

A análise dos resultados obtidos na aplicação dos Modelos de Previsão de Demanda em uma situação real permite observar também grandes melhorias de desempenho no processo de Previsão de Demanda, como por exemplo no item P018 (SKU-> Tenório) que apresentou redução de 51,6% no DAPM em situações reais de uso. Houve melhoria significativa de desempenho na previsão de itens importantes para a Unilever Brasil Kibon. A previsão do total Geral de Vendas da Empresa e das Vendas de cada uma das Linhas (Impulse, Take Home e Food Service) também melhorou bastante, sendo que o item P010 (Linha -> S. Sebastião) chegou a reduzir seu DAPM em 54,4% com a adoção do Modelo de Previsão de Demanda Combinado C (Série de Fourier + Série de Fourier "Suavizada"). Tal fato é importante, na medida em que estes valores são extremamente importantes no planejamento da fábrica, com foco na capacidade produtiva das linhas.

De maneira geral, pode-se concluir que a escolha dos modelos de Previsão de Demanda efetuada na etapa anterior é válida, não havendo necessidade de

revisão da seleção de modelos. Para o item específico P019 (SKU-> Félix), cujos resultados se apresentaram piores que o sistema atual, a previsão deverá ser feita a partir de informações de Trade Marketing e Marketing pois os demais modelos de Previsão apresentados neste estudo também não apresentaram resultados melhores que os verificados a partir do Sistema Atual de Previsão de Demanda. No caso do item P016 (SKU-> Lázaro) o resultado obtido ficou muito próximo do proporcionado pelo Sistema Atual. Assim sendo, a opção é a de adotar o modelo matemático proposto.

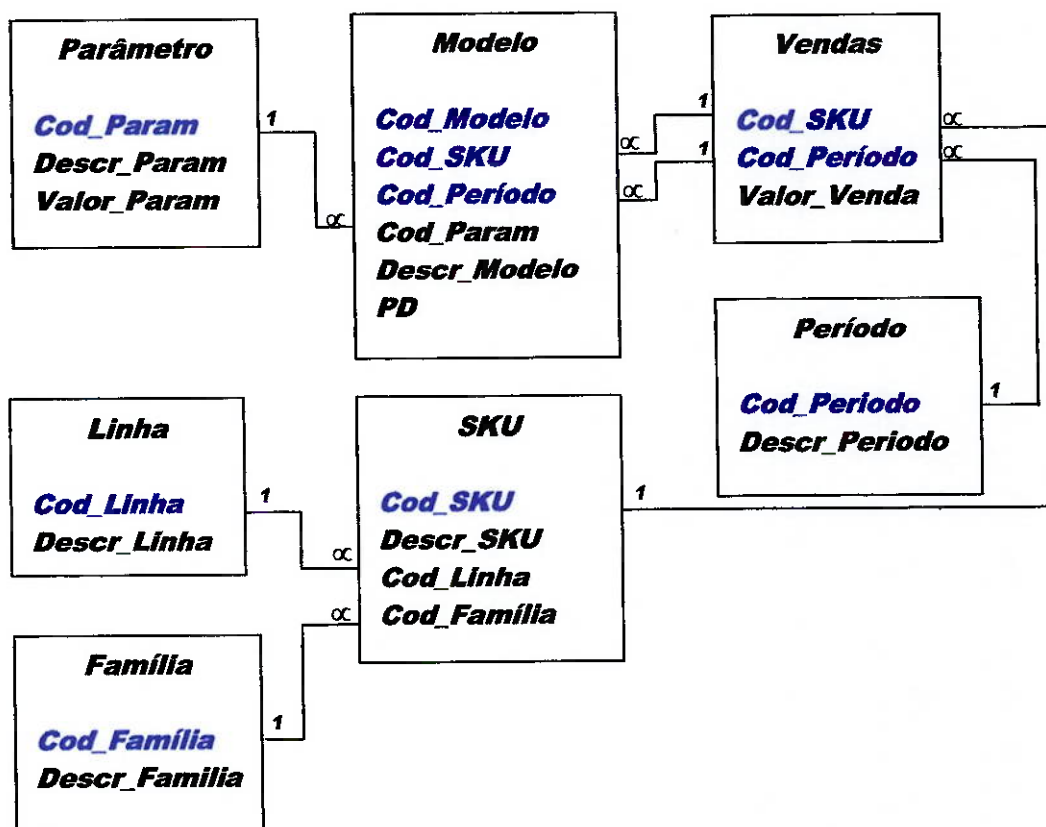
## **9. Considerações Finais**

### **9.1. Necessidades para Implementação**

Todos os modelos de previsão de Demanda utilizados neste presente trabalho, bem como os testes piloto efetuados nas diferentes etapas de desenvolvimento foram implementados em planilha eletrônica (MS-Excel™), devido a simplicidade buscada, baixo custo e rapidez de implementação.

Para viabilizar este trabalho, buscou-se, em paralelo ao desenvolvimento dos Modelos de Previsão de Demanda, uma estruturação dos dados necessários no trabalho de maneira a organizar a lógica do Sistema de Previsão de Demanda.

A figura 20 mostra como as tabelas de dados foram organizadas e relacionadas para se chegar aos resultados apresentados neste trabalho.



**Figura 20 - Tabelas para Sistema de Previsão de Demanda**

A estrutura de dados é bastante simples e pode ser utilizada como referência para futuras implementações em sistemas dedicados, desenvolvidos em linguagem de programação específica. Vale ressaltar, no entanto, que esta é uma etapa futura do desenvolvimento de um Sistema de Previsão de Demanda para a Unilever Brasil Kibon e não faz parte do escopo deste trabalho.

#### Descrição dos Campos das Tabelas do Sistema de Previsão de Demanda

<b>Tabela PARÂMETRO</b>		
<b>Campo</b>	<b>Tipo</b>	<b>Descrição</b>
<b>Cod_Param</b>	<b>Código</b>	<b>Código único de identificação do Parâmetro</b>
<b>Descr_Param</b>	<b>Texto</b>	<b>Texto utilizado para descrever o Parâmetro</b>
<b>Valor_Param</b>	<b>Número</b>	<b>Valor numérico associado ao Parâmetro</b>

**Tabela 12 - Descrição Tabela Parâmetro**

<b>Tabela MODELO</b>		
<b>Campo</b>	<b>Tipo</b>	<b>Descrição</b>
<b>Cod_Modelo</b>	<b>Código</b>	<b>Código único de identificação do Modelo de Previsão de Demanda</b>
<b>Cod_SKU</b>	<b>Número</b>	<b>Código de referência para o SKU a ser Previsto</b>
<b>Cod_Período</b>	<b>Número</b>	<b>Código de referência para o Período de Previsão</b>
<b>Cod_Param</b>	<b>Número</b>	<b>Código de referência para o Parâmetro a ser utilizado na Previsão</b>
<b>Descr_Modelo</b>	<b>Texto</b>	<b>Texto utilizado para descrever o Modelo de Previsão de Demanda</b>
<b>PD</b>	<b>Número</b>	<b>Valor de Previsão de Demanda do Modelo para o SKU e Período especificados</b>

Tabela 13 - Descrição Tabela Modelo

<b>Tabela VENDAS</b>		
<b>Campo</b>	<b>Tipo</b>	<b>Descrição</b>
<b>Cod_SKU</b>	<b>Número</b>	<b>Código de referência para o SKU</b>
<b>Cod_Período</b>	<b>Número</b>	<b>Código de referência para o Período</b>
<b>Valor_Venda</b>	<b>Número</b>	<b>Valor de Venda para o SKU e Período especificados</b>

Tabela 14 - Descrição Tabela Vendas

<b>Tabela PERÍODO</b>		
<b>Campo</b>	<b>Tipo</b>	<b>Descrição</b>
<b>Cod_Período</b>	<b>Código</b>	<b>Código único de identificação do Período</b>
<b>Descr_Período</b>	<b>Texto</b>	<b>Texto utilizado para descrever o Período</b>

Tabela 15 - Descrição Tabela Período

<b>Tabela LINHA</b>		
<b>Campo</b>	<b>Tipo</b>	<b>Descrição</b>
<b>Cod_Linha</b>	<b>Código</b>	<b>Código único de identificação da Linha de Produtos Acabados</b>
<b>Descr_Linha</b>	<b>Texto</b>	<b>Texto utilizado para descrever a Linha</b>

Tabela 16 - Descrição Tabela Linha

<b>Tabela FAMÍLIA</b>		
<b>Campo</b>	<b>Tipo</b>	<b>Descrição</b>
<b>Cod_Familia</b>	<b>Código</b>	<b>Código único de identificação da Família de Produtos Acabados</b>
<b>Descr_Familia</b>	<b>Texto</b>	<b>Texto utilizado para descrever a Família</b>

Tabela 17 - Descrição Tabela Família

<b>Tabela SKU</b>		
<b>Campo</b>	<b>Tipo</b>	<b>Descrição</b>
<b>Cod_SKU</b>	<b>Código</b>	<b>Código único de identificação do SKU</b>
<b>Descr_SKU</b>	<b>Texto</b>	<b>Texto utilizado para descrever o SKU</b>
<b>Cod_Linha</b>	<b>Número</b>	<b>Código de referência para a Linha</b>

---

<b>Cod_Familia</b>	<b>Número</b>	<b>Código de referência para a Família</b>
--------------------	---------------	--

**Tabela 18 - Descrição Tabela SKU**

Os campos de tabela destacados com cor azul são únicos e não podem ser replicados.

Os índices presentes nos relacionamentos entre tabelas indicam unicidade ou multiplicidade. Por exemplo: Linha 1-∞ SKU indica um relacionamento denominado “um-para-muitos” onde uma Linha pode ser associada a vários SKU’s, ao passo que um SKU só pode ser associado a uma Linha.

Além disso, os modelos de Previsão de Demanda apresentados neste trabalho podem ser descritos por algoritmos que podem servir como referência para eventuais desenvolvimentos futuros de sistemas.

Os processos a serem descritos são:

Processo A: Inicialização, Calibração, Implementação, Teste e Escolha dos Modelos de Previsão;

Processo B: Utilização dos Modelos de Previsão de Demanda.

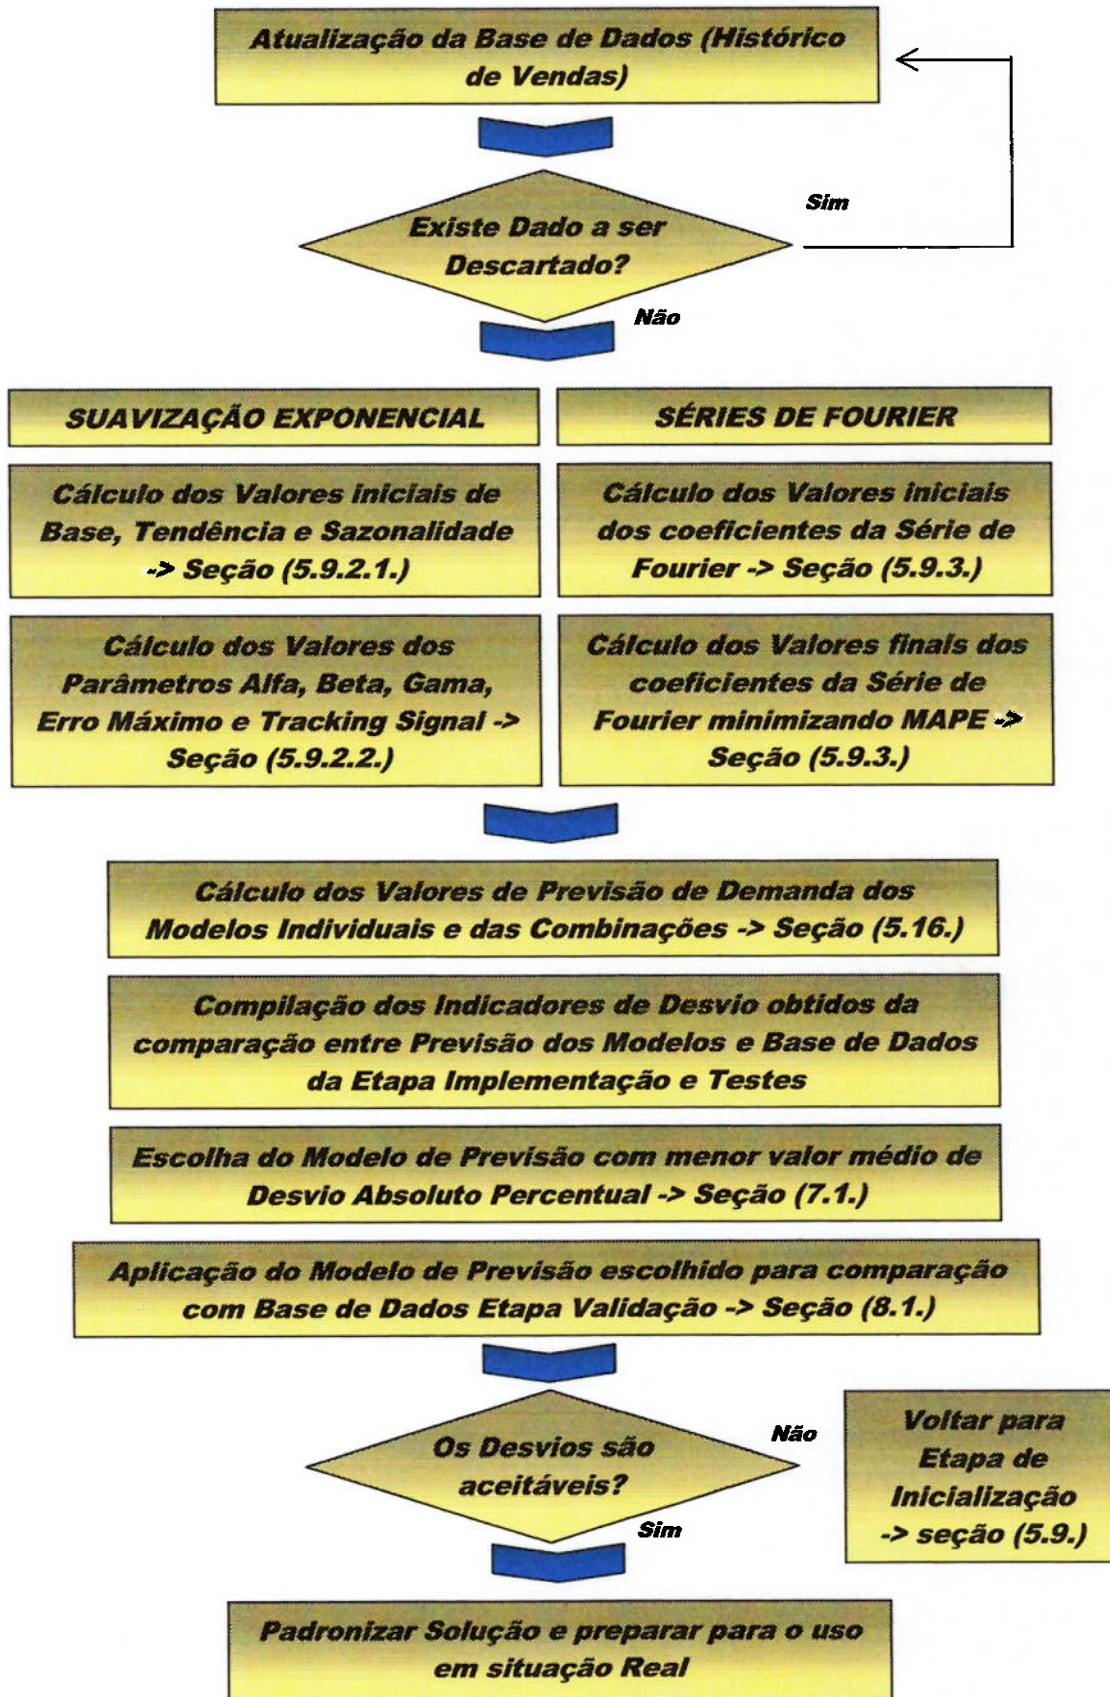


Figura 21 - Algoritmo Processo A

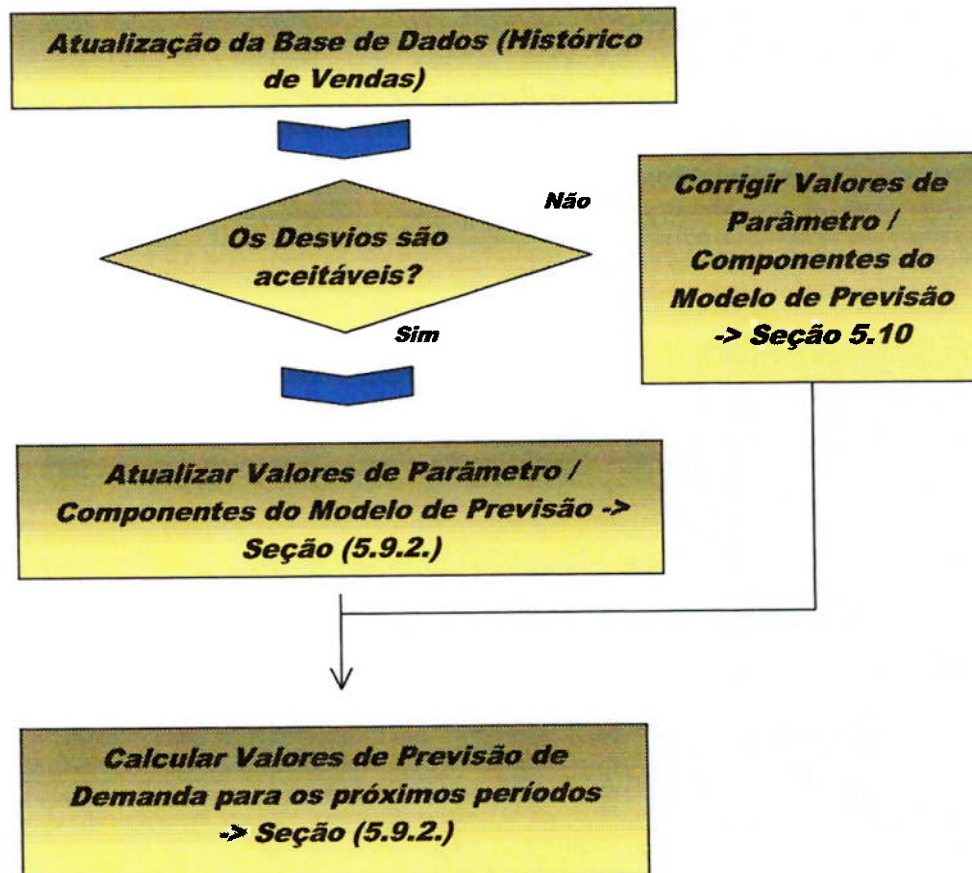


Figura 22 - Algoritmo Processo B

## **9.2. Aspectos organizacionais da Previsão**

Além das técnicas de Previsão de Demanda propriamente ditas e todos os aspectos teóricos envolvidos, tais como: medidas estatísticas de desvios, premissas quanto a aleatoriedade, conceitos de média móvel, suavização exponencial e funções harmônicas, um fator essencial para o sucesso da implementação de qualquer tipo de Modelo de Previsão de Demanda é a harmonia quanto aos aspectos Organizacionais que se relacionam com a Previsão.

MAKRIDAKIS (1998) aponta a falha de comunicação como um dos principais problemas em relação aos aspectos organizacionais do processo de Previsão de Demanda, sendo comuns os casos onde existem percepções distintas por parte dos usuários do Sistema de Previsão e dos implementadores do Sistema em relação aos conhecimentos e habilidades requeridos para concepção e operação do Sistema de Previsão de Demanda.

Segundo MAKRIDAKIS (1998) existem uma série de fatores que podem influenciar negativamente o processo de Previsão de Demanda dentro de uma organização:

Credibilidade e Impacto – casos nos quais o Processo de Previsão de Demanda apresenta baixa credibilidade e baixo impacto na tomada de decisões na Empresa. Este problema pode ter causas pessoais, no caso de problemas de comunicação entre participantes do processo, ou ter origem na própria Estrutura Organizacional da Empresa, no caso onde o Processo de Estimativa é conduzido por níveis hierárquicos de pouca expressão, sem apoio da alta direção da Empresa e, portanto, sem força política dentro da Organização para participar ativamente no Processo de Tomada de Decisões. Além disso, uma outra fonte de falta de credibilidade do Processo é seu baixo Desempenho, traduzido em desvios de previsão altos que prejudicam o funcionamento da Cadeia de Suprimentos como um todo.

---

Falta de recentes melhorias de desempenho no Processo – casos nos quais não se registram melhorias recentes no Processo de Previsão de Demanda. Segundo MAKRIDAKIS (1998), isto pode ser causado porque os recursos alocados para o Processo já se encontram no limite de desempenho, havendo necessidade de investimentos ou de mudanças no processo para que se alcance algum tipo de melhoria de performance. Outra razão para a ocorrência deste problema é a falha em se perceber mudanças organizacionais e/ou problemas de interface entre departamentos da Empresa.

Deficiência na base do Processo – caso mais comum em processos de Previsão de Demanda que começam a se estruturar. Por vezes, existe deficiência por parte dos envolvidos na concepção e desenvolvimento do Processo em relação ao conhecimento das técnicas disponíveis e da teoria por trás destes modelos, que serve para orientar escolhas de modelos mais adequados. Este problema também pode ser verificado quando não existe uma estratégia claramente definida para o Desenvolvimento de um Processo de Previsão de Demanda.

Na Unilever Brasil Kibon uma primeira análise feita em relação aos aspectos organizacionais relacionados ao Processo de Previsão de Demanda aponta a ocorrência em diferentes graus de intensidade de alguns dos problemas apontados anteriormente. Pode-se perceber uma certa falta de credibilidade do Processo de Estimativa devido aos resultados apresentados nos últimos meses, sendo comuns valores de desvio de Previsão da ordem de 30%. É possível perceber também que a estrutura organizacional atual acaba por contribuir para a falta de impacto do Processo na tomada de decisões, uma vez que os números agregados (volumes de venda Impulse, Take Home e Food Service) são definidos prioritariamente pela área de Vendas, cabendo ao processo de Reunião de Estimativa o ajuste dos números micro no nível de SKU.

Percebe-se que na Unilever Brasil Kibon, o processo de Estimativa reflete muito significativamente um desejo da área de Vendas em relação aos volumes

de vendas de períodos futuros, colocados sob a forma de metas de desempenho para a equipe de vendas em vez de direcionar seus esforços para projetar a Demanda proveniente do mercado.

Em relação aos recursos direcionados para a Previsão de Demanda pode-se afirmar que um primeiro passo foi dado, na medida em que se reconheceu a importância deste Processo para o resultado da Empresa e iniciou-se um trabalho de desenvolvimento e melhoria do Processo de Estimativa de Demanda.

### ***9.3. Propostas adicionais de Melhorias para o Processo de Estimativa***

Registros de falta de produtos – não existem registros formais de falta de produto. Levantou-se que uma prática usual no campo é substituir um eventual produto em falta por um outro semelhante. Isto, no entanto, apresenta dois aspectos prejudiciais para o Processo de Estimativa, mascarando a Demanda tanto do produto em falta quanto ao do produto substituto. Não se sabe ao certo se uma queda de volume de vendas de um determinado SKU é devido a uma mudança no padrão de comportamento do mercado ou se é causada pela simples falta deste item. Ao mesmo tempo, não se consegue responder com certeza se um aumento de volume de vendas de um outro SKU é devido a uma alteração no padrão de comportamento do consumidor ou se este SKU foi oferecido pela equipe de vendas para substituir um eventual SKU em falta.

Estruturação Reunião Estimativa – processo que já vem ocorrendo desde Setembro de 2001 visando integrar as diversas áreas envolvidas no Processo de Previsão de Demanda. Vem se buscando uma participação mais efetiva da área de Marketing, essencial para a definição dos volumes de Estimativa, tendo em vista a importância das campanhas de mídia, lançamento de novos produtos e alterações em produtos de linha nos volumes de venda da Empresa. Além disso, o processo vem se reestruturando de maneira a se tornar mais ágil. Tem-se buscado divulgar números prévios antes da Reunião

Mensal de Estimativa para que as áreas envolvidas possam analisar os volumes e emitir seus pareceres na ocasião da Reunião.

---

## **10. Conclusão**

### **10.1. Resultados obtidos**

Os resultados obtidos neste trabalho podem ser considerados muito satisfatórios, uma vez que o objetivo foi cumprido. O desempenho previsto para o novo Sistema de Previsão de Demanda apresenta melhorias da ordem de 25,0% no que se refere a desvios percentuais de previsão. Tal resultado apresenta impactos significativos em relação a estoques de segurança de Matéria Prima, Material de Embalagem e Produto Acabado, no que diz respeito a capital investido pela Unilever Brasil Kibon. Vislumbra-se portanto, uma perspectiva de melhoria nos resultados financeiros da Companhia, que pode ser proporcionada pela maior confiança no processo de Estimativa que se traduz em menos estoque de segurança na Empresa.

Além disso, o trabalho desenvolvido apresenta facilidade e rapidez de implementação, bem como um baixo custo para a concretização deste projeto. Todos estes fatores também se incluíam no objetivo inicialmente proposto.

### **10.2. Trabalhos futuros**

Acredita-se que no futuro pode-se considerar a hipótese de implementar os modelos de Previsão de Demanda em um sistema dedicado que esteja integrado com os sistemas que controlam vendas e estoques, agregando ainda mais valor ao processo de Estimativa de Demanda.

Para auxiliar nestas tarefas preparou-se neste trabalho um esquema de concepção das tabelas de dados necessários para o funcionamento de um Sistema de Previsão de Demanda, assim como algoritmos relacionados ao funcionamento dos modelos de Previsão discutidos no decorrer deste trabalho.

### **10.3. Principais dificuldades encontradas no decorrer do Trabalho**

As principais dificuldades encontradas no decorrer deste trabalho foram muito próximas daquelas discutidas por MAKRIDAKIS (1998) e apresentadas na seção 9.2. Houve alguns problemas de comunicação no decorrer do processo, quando foi preciso explicar a importância da mudança no sistema de Previsão de Demanda com a utilização de modelos formais e estruturados visando complementar as informações importantes de caráter subjetivo originadas das áreas de Vendas, Trade Marketing e Marketing.

Além disso, devido ao desempenho não satisfatório do Processo de Previsão de Demanda apresentado nos últimos anos, o autor sentiu uma certa descrença por parte dos envolvidos no processo em relação a importância e validade de um procedimento formal de Previsão de Demanda.

Verificou-se também que por muitas vezes houve uma certa confusão em relação a questão de Previsão de Demanda *versus* Metas para Equipe de Vendas. Percebeu-se que existe uma força muito grande no interior da Organização que amplifica a importância do aspecto Meta de Vendas em relação a Estimativa de Demanda.

#### **10.4. Comentários finais**

Por fim, uma observação importante a ser feita a respeito deste trabalho é a participação ativa do autor no desenvolvimento e melhoria do Sistema de Previsão de Demanda da Unilever Brasil Kibon. Foi o autor o responsável pela pesquisa, adaptações e testes dos modelos de Previsão de Demanda apresentados neste trabalho. Além disso, o autor implementou as planilhas eletrônicas que possibilitaram realizar todos os estudos comparativos que permitiram selecionar os modelos de Previsão a serem associados aos itens da Empresa. Planilhas eletrônicas também foram desenvolvidas para a implementação em escala real para os itens de linha da Unilever Brasil Kibon.

Para poder tomar todas estas ações, o autor recebeu total apoio da Gerência de Planejamento Logístico, na medida em que a grande parte da carga horária

de estágio desenvolvido durante o ano de 2001 foi utilizada no desenvolvimento deste projeto.

Acredita-se que desta forma, todos os objetivos foram cumpridos, tanto no caso da Unilever Brasil Kibon, com a concepção de um modelo de Previsão de Demanda cujos resultados indicam melhorias potenciais para o resultado da Empresa, como também no ponto de vista do aluno, com a oportunidade de desenvolvimento e implementação de um projeto em situação real que sem dúvida alguma contribuíram em muito para o desenvolvimento acadêmico, profissional e pessoal deste autor. Por fim, sob a perspectiva do Departamento de Engenharia de Produção da Escola Politécnica da Universidade de São Paulo os objetivos também foram cumpridos, na medida em que se acredita que este trabalho é um indício da validade do processo de desenvolvimento acadêmico e pessoal dos alunos desta Escola, propiciando ao autor a oportunidade de utilizar ativamente os mais variados conteúdos apresentados no decorrer do curso de Graduação em Engenharia de Produção nesta Escola.

## **11. Referência Bibliográfica**

BUFFA, E.S., **Modern Production / Operations Management**, 7a. edição, Los Angeles, John Wiley & Sons, 1983.

BUFFA, E.S.; MILLER, J.G., **Production-Inventory Systems: Planning and Control**, Illinois, Richard D. Irwin Inc., 1979.

CHICOLI, M., **Curso de Planejamento, Programação e Controle da Produção**, Consultoria A. Sapiens, 2001.

COPPEAD/UFRJ – Apostila do Curso “**Modelos Quantitativos de Previsão de Demanda**”, 2001.

CORRÊA, H.; GIANESI, I.G.N., CAON, M., **Planejamento, Programação e Controle da Produção: MRPII / ERP: Conceitos, uso e implantação**, 2a. edição, São Paulo, Editora Atlas, 1999.

GILCHRIST, W., **Statistical Forecasting**, John Wiley & Sons, 1976.

HANKE, J.E. & REITSCH, A.G., **Business Forecasting**, Prentice Hall, Upper Saddle River, New Jersey, 1998.

HAX, A & CANDEA, D., **Production and Inventory Management**, Englewood Cliffs, N.J.: Prentice-Hall, 1984.

MAKRIDAKIS, S; WHEELWRIGHT, S.C. & HYNDMAN, R.J., **Forecasting: Methods and Applications**, 3a. edição, John Wiley & Sons, 1998.

MENTZER, J.T. & BIENSTOCK, C.C., **Sales Forecasting Management**, Sage Publications, 1997.

SANTORO, M.C. - Notas de Aula – **Planejamento, Programação e Controle da Produção e Estoques** – 2000.

SILVER, E.A.; PYKE, D.F., PETERSON, R., **Inventory Management and Production Planning and Scheduling**, John Wiley & Sons, New York, 1998.