

RAFAEL ARB DE CASTRO

**ESTUDO DO COMPORTAMENTO DA DEMANDA NO VAREJO
ATRAVÉS DE MODELOS DE PREVISÃO**

Trabalho de Formatura apresentado à
Escola Politécnica da Universidade de
São Paulo para obtenção do Diploma de
Engenheiro de Produção

São Paulo

2009

RAFAEL ARB DE CASTRO

**ESTUDO DO COMPORTAMENTO DA DEMANDA NO VAREJO
ATRAVÉS DE MODELOS DE PREVISÃO**

Trabalho de Formatura apresentado à
Escola Politécnica da Universidade de
São Paulo para obtenção do Diploma de
Engenheiro de Produção

Orientador: Prof. Dr. Miguel Cezar Santoro

São Paulo

2009

FICHA CATALOGRÁFICA

Castro, Rafael Arb de

**Estudo do comportamento da demanda no varejo através de
modelos de previsão / R.A. de Castro. -- São Paulo, 2009.
123 p.**

**Trabalho de Formatura - Escola Politécnica da Universidade
de São Paulo. Departamento de Engenharia de Produção.**

**1. Demanda (Previsão) 2. Varejo 3. Bens de consumo I. Uni -
versidade de São Paulo. Escola Politécnica. Departamento de
Engenharia de Produção II. t.**

Dedico este trabalho aos meus pais, Ricardo e Silvia, e ao meu irmão, Rodrigo, as pessoas mais especiais e importantes de minha vida, e os verdadeiros responsáveis por minha formação.

AGRADECIMENTOS

Gostaria de iniciar expressando minha incomensurável gratidão aos meus pais, Ricardo e Silvia, e ao meu irmão, Rodrigo, por todo amor, carinho e dedicação. Sou extremamente grato por todos os exemplos de vida transmitidos e, principalmente, os valores ensinados. Muito obrigado pelo enorme apoio e incontestável torcida! Amo vocês!

Também agradeço de maneira especial ao Prof. Dr. Miguel Cezar Santoro por toda atenção despendida. Graças à valiosa orientação e aos preciosos conselhos, esse trabalho pôde se tornar uma realidade. Obrigado pela confiança!

Sou grato, ainda, a todos os amigos que de alguma forma conviveram, trabalharam, sofreram e se divertiram comigo ao longo dessa difícil trajetória na POLI. Aos amigos-colegas pelas ajudas mútuas na luta por um mesmo ideal: a formatura. Aos amigos do peito pela convivência frequente, além de toda força e companheirismo. Aos amigos-irmãos pelos conselhos, pelo incentivo e pela presença nos momentos mais importantes dessa jornada, fazendo da amizade um verdadeiro grau de parentesco.

Não podia deixar de lembrar também daquele que foi fundamental para o meu desenvolvimento durante a universidade: o CAEP. Este, que foi para mim um segundo lar, propiciou-me um enorme crescimento e muitos desafios, além, obviamente, do incrível contato com pessoas fantásticas. Obrigado, pessoal, por ter sempre me apoiado e confiado na minha amizade. Um agradecimento especial à Cris e ao Osni que foram para mim muito mais do que meros membros do CAEP, e sim, verdadeiros amigos, que através de toda torcida, incentivo e ajuda fizeram toda diferença. Espero, sinceramente, poder retribuir, um dia, todos esses gestos carinhosos que jamais serão esquecidos.

Meus agradecimentos a todos da empresa onde esse trabalho foi desenvolvido, pela receptividade, solicitude, pelos conhecimentos transmitidos e por me propiciar um indescritível crescimento em minha primeira experiência profissional.

Enfim, sou grato a Deus por ter tido tantas oportunidades e poder desfrutar de tantas companhias especiais como essas que vão, com certeza, ficar gravadas em minha memória e, espero eu, acompanhar-me pelo resto de minha vida.

O autor

“A falta de planejamento é o planejamento
para o fracasso”

(Ricardo de Castro)

RESUMO

Esse trabalho visa desenvolver um modelo de previsão de demanda no varejo para os bens de consumo de uma grande multinacional. O objetivo desse projeto é fornecer para a cadeia estudada mais, e melhores, informações a respeito do comportamento da sua demanda, dando condições para que boas decisões sobre o abastecimento das lojas sejam tomadas. Isso tudo foi considerado a fim de se evitar a chamada ruptura de gôndola que vem sido, principalmente, causada devido ao dilema existente na cadeia entre responsividade e eficiência. O não atendimento de uma demanda pode gerar danos significativos tanto para o fornecedor quanto para o varejista. Dessa maneira, foi desenvolvido um modelo de projeção que se baseia apenas em dados históricos da demanda para a realização de uma previsão inicial. Na sequência, por meio de uma análise causal, foram obtidas informações que, ao serem acrescentadas aos primeiros resultados, melhoraram a sua precisão, formando-se assim, um modelo integrado de previsão de demanda. Por fim, tendo em vista os bons resultados atingidos são propostas ferramentas e alterações de processo para a implementação desse modelo, bem como, alguns trabalhos futuros que devem ser realizados para o seu aperfeiçoamento.

Palavras-chave: Previsão de demanda no varejo. Bens de consumo. Decisões de abastecimento. Responsividade. Eficiência. Modelo integrado de previsão de demanda.

ABSTRACT

This work aims to develop a forecasting model of retail demand for consumer goods of a large multinational. The project goal is to provide for the studied chain more and better information about the behavior of their demand, giving conditions to take good decisions about the stores' supply. All this was considered in order to avoid the so-called out of stock, that has being mainly caused due to the existence of the dilemma between responsiveness and efficiency. Failure to reply to a demand can generate significant damage to both the supplier as to the retailer. Thus, a projection model was developed based only on demand historical data for the realization of an initial forecast. Subsequently, through a causal analysis, some information was obtained and added to the initial results, improving its accuracy and forming an integrated model of demand forecast. Finally, considering the good results achieved, tools and process changes are proposed to implement this model, as well as some further work to be undertaken for its improvement.

Keywords: Retail demand forecasting. Consumer goods. Supply decisions. Responsiveness. Efficiency. Integrated model of demand forecast.

LISTA DE ILUSTRAÇÕES

FIGURA 2.1 – LINHA DO TEMPO DA UNILEVER.....	18
FIGURA 2.2 – PRINCIPAIS MARCAS DE HPC.....	19
FIGURA 2.3 – PRINCIPAIS MARCAS DE FOODS	20
FIGURA 2.4 – LOGO DA KIBON.....	20
FIGURA 2.5 – FÁBRICAS E ESCRITÓRIOS DA UNILEVER BRASIL	21
FIGURA 3.1 - ETAPAS DO PROCESSO DE PLANEJAMENTO DA DEMANDA	26
FIGURA 3.2 - FLUXO DE INFORMAÇÕES DE UM PEDIDO.....	28
FIGURA 3.3 – FLUXO FÍSICO DE UM PEDIDO	30
FIGURA 4.1 – COMPORTAMENTO DO SHOPPER BRASILEIRO PERANTE A FALTA DE PRODUTO NA LOJA	34
FIGURA 4.2 – CAUSAS PARA A OCORRÊNCIA DA RUPTURA.....	35
FIGURA 4.3 – IMAGEM DE UMA GÔNDOLA ABASTECIDA DE ACORDO COM A ESTRATÉGIA DE VISIBILIDADE E DE UMA GÔNDOLA COM RUPTURA	37
FIGURA 5.1 – CURVA DE CUSTO DE ESTOQUE EM RELAÇÃO À RESPONSABILIDADE	42
FIGURA 5.2 – ALINHAMENTO ESTRATÉGICO MEDIANTE OS NÍVEIS DE RESPONSABILIDADE E INCERTEZA DA DEMANDA.....	43
FIGURA 5.3 – PROCESSO DE ABASTECIMENTO DE ESTOQUES.....	43
FIGURA 5.4 – FLUXO DE INFORMAÇÃO DA PREVISÃO DE DEMANDA E PLANEJAMENTO DOS NEGÓCIOS.....	50
FIGURA 5.5 – DEFINIÇÃO DOS PERÍODOS DE PREVISÃO.....	54
FIGURA 6.1 – <i>GAP</i> NO ACOMPANHAMENTO DO OP	72
FIGURA 6.2 – FORMAS DE AGRUPAMENTO DOS PRODUTOS	74
FIGURA 6.3 – CURVA DE DEMANDA DIÁRIA DA FAMÍLIA I DA MARCA A	78
FIGURA 6.4 – CURVA DE DEMANDA SEMANAL DA FAMÍLIA I DA MARCA A.....	79
FIGURA 6.5 – CORRELOGRAMA DA DEMANDA DIÁRIA DA FAMÍLIA I DA MARCA A	81
FIGURA 6.6 – CORRELOGRAMA DA DEMANDA SEMANAL DA FAMÍLIA I DA MARCA A.....	82
FIGURA 6.7 – LINHA DE TENDÊNCIA DA FAMÍLIA I DA MARCA A	84
FIGURA 6.8 – DETERMINAÇÃO DOS PERÍODOS DE PREVISÃO DA FAMÍLIA I DA MARCA A.....	89
FIGURA 6.9 – CURVA DE PREVISÃO X CURVA REAL (HORIZONTE DE PREVISÃO DE 1 DIA)	93

FIGURA 6.10 – CURVA DE PREVISÃO X CURVA REAL (HORIZONTE DE PREVISÃO DE 7 DIAS)	94
FIGURA 6.11 – GRÁFICO DE RESÍDUOS DA FAMÍLIA I DA MARCA A	100
FIGURA 6.12 – GRÁFICO DE PROBABILIDADE NORMAL PARA A FAMÍLIA I DA MARCA A	100
FIGURA 6.13 – HISTOGRAMA DA FAMÍLIA I DA MARCA A	101
FIGURA 7.1 – TELA MENU DA FERRAMENTA DE ESCOLHA DO MODELO DE PREVISÃO.....	103
FIGURA 7.2 – TELA DO MODELO DE SUAVIZAÇÃO EXPONENCIAL COM SAZONALIDADE	104
FIGURA 7.3 – TELA DO RESUMO DE RESULTADOS.....	105
FIGURA 7.4 – TELA MENU DA FERRAMENTA DE PREVISÃO INTEGRADA DA DEMANDA.....	105
FIGURA 7.5 – TELA DO MODELO INTEGRADO DE PREVISÃO DA DEMANDA	106
FIGURA 7.6 – PROPOSTA DO NOVO PROCESSO NO PLANEJAMENTO DA DEMANDA	108
FIGURA A.1 – CURVA DE DEMANDA DIÁRIA DA FAMÍLIA II DA MARCA B	115
FIGURA A.2 – CURVA DE DEMANDA SEMANAL DA FAMÍLIA II DA MARCA B	115
FIGURA A.3 – CORRELOGRAMA DA DEMANDA DIÁRIA DA FAMÍLIA II DA MARCA B	116
FIGURA A.4 – CORRELOGRAMA DA DEMANDA SEMANAL DA FAMÍLIA II DA MARCA B	116
FIGURA A.5 – LINHA DE TENDÊNCIA DA FAMÍLIA II DA MARCA B	117
FIGURA A.6 – CURVA DE PREVISÃO X CURVA REAL (HORIZONTE DE PREVISÃO DE 1 DIA)	118
FIGURA A.7 – CURVA DE PREVISÃO X CURVA REAL (HORIZONTE DE PREVISÃO DE 7 DIAS)	118
FIGURA A.8 – CURVA DE DEMANDA DIÁRIA DA FAMÍLIA III DA MARCA C.....	119
FIGURA A.9 – CURVA DE DEMANDA SEMANAL DA FAMÍLIA III DA MARCA C	119
FIGURA A.10 – CORRELOGRAMA DA DEMANDA DIÁRIA DA FAMÍLIA III DA MARCA C.....	120
FIGURA A.11 – CORRELOGRAMA DA DEMANDA SEMANAL DA FAMÍLIA III DA MARCA C.....	120
FIGURA A.12 – LINHA DE TENDÊNCIA DA FAMÍLIA III DA MARCA C.....	121
FIGURA A.13 – CURVA DE PREVISÃO X CURVA REAL (HORIZONTE DE PREVISÃO DE 1 DIA)	122
FIGURA A.14 – CURVA DE PREVISÃO X CURVA REAL (HORIZONTE DE PREVISÃO DE 7 DIAS)..	122

LISTA DE TABELAS

TABELA 2.1 – CARACTERIZAÇÃO DOS FORMATOS DE LOJA DA REDE WAL-MART	23
TABELA 4.1 – MUDANÇAS ESPERADAS NAS VISÕES DE TRABALHO	40
TABELA 5.1 – PRINCIPAIS MODELOS DE GESTÃO DE ESTOQUES	47
TABELA 6.1 – CARACTERIZAÇÃO DAS AMOSTRAS ESCOLHIDAS PARA O ESTUDO	75
TABELA 6.2 – CRITÉRIO DE CONSOLIDAÇÃO DOS DADOS DIÁRIOS EM SEMANAS DO MÊS	79
TABELA 6.3 – PARTICIPAÇÃO DA DEMANDA POR DIA DA SEMANA E SEMANA DO MÊS	80
TABELA 6.4 – ERROS OBTIDOS COM OS DIFERENTES MODELOS DE PREVISÃO	89
TABELA 6.5 – FRAGMENTO DA TABELA UTILIZADA NO MODELO DE PREVISÃO	93
TABELA 6.6 – PRINCIPAIS RESULTADOS DO MODELO ESCOLHIDO	94
TABELA 6.7 – VARIÁVEIS INDEPENDENTES DISPONÍVEIS	97
TABELA 6.8 – CARACTERÍSTICAS DAS VARIÁVEIS INDEPENDENTES FORNECIDAS PELA REGRESSÃO LINEAR MÚLTIPLA	98
TABELA 6.9 – ANOVA DA FAMÍLIA I DA MARCA A	99
TABELA 6.10 – RESULTADO DO MODELO INTEGRADO	102
TABELA A.1 – PARTICIPAÇÃO DA DEMANDA POR DIA DA SEMANA E SEMANA DO MÊS	116
TABELA A.2 – ERROS OBTIDOS COM OS DIFERENTES MODELOS DE PREVISÃO	117
TABELA A.3 – PRINCIPAIS RESULTADOS DO MODELO ESCOLHIDO	118
TABELA A.4 – PARTICIPAÇÃO DA DEMANDA POR DIA DA SEMANA E SEMANA DO MÊS	120
TABELA A.5 – ERROS OBTIDOS COM OS DIFERENTES MODELOS DE PREVISÃO	121
TABELA A.6 – PRINCIPAIS RESULTADOS DO MODELO ESCOLHIDO	122
TABELA A.6 – FRAGMENTO DA TABELA UTILIZADA PARA REGRESSÃO LINEAR MÚLTIPLA	123

LISTA DE ABREVIATURAS E SIGLAS

AP	<i>Annual Plan</i>
AQP	<i>Annual Quarter Plan</i>
CD	Centro de Distribuição
CPFR	<i>Collaborative Planning, Forecasting and Replenishment</i>
ECR	<i>Efficient Consumer Response</i>
HC	<i>Home Care</i>
HP	Horizonte de Previsão
HPC	<i>Home and Personal Care</i>
HPF	<i>Home care, Personal care and Foods</i>
ICE	<i>Ice Cream</i>
LT	<i>Lead Time</i>
MAE	<i>Mean Absolute Error</i>
MAPE	<i>Mean Absolute Percentage Error</i>
ME	<i>Mean Error</i>
MPE	<i>Mean Percentage Error</i>
MSE	<i>Mean Squared Error</i>
OP	<i>Operational Plan</i>
PC	<i>Personal Care</i>
RMR	<i>Retailer Managed Release</i>
SKU	<i>Stock Keeping Unit</i>
SOA	<i>Share Of Assortment</i>
VIF	<i>Variance Inflation Factor</i>
VMR	<i>Vendor Managed Release</i>
WMAPE	<i>Weighted Mean Absolute Percentage Error</i>

SUMÁRIO

1. INTRODUÇÃO	15
2. A EMPRESA.....	17
2.1 HISTÓRICO	17
2.2 MARCAS E PRODUTOS.....	19
2.3 ESTRUTURA DA EMPRESA	21
2.4 O ESTÁGIO.....	22
2.5 O VAREJISTA	22
3. O PROCESSO DE VENDAS	25
3.1 PLANEJAMENTO DE DEMANDA.....	25
3.2 VENDA E ABASTECIMENTO DAS LOJAS	27
4. DEFINIÇÃO DO PROBLEMA E OBJETIVO	33
4.1 RUPTURA.....	33
4.2 O PROBLEMA	35
4.3 O OBJETIVO DO TRABALHO.....	39
5. REVISÃO BIBLIOGRÁFICA	41
5.1 GESTÃO DE ESTOQUES NO VAREJO	41
5.1.1 Trade-Off Custo de Estoque X Responsividade	42
5.1.2 Modelos de Estoques.....	43
5.2 PLANEJAMENTO, PREVISÃO E REABASTECIMENTO COLABORATIVOS	48
5.3 PREVISÃO DE DEMANDA.....	49
5.2.1 Por quê Prever ?	50
5.2.2 Tipos de Previsão.....	52
5.2.3 Etapas para Aplicação da Previsão.....	53
5.2.4 Acurácia da Previsão.....	55
5.2.5 Métodos Qualitativos	58
5.2.6 Métodos Quantitativos	61
6. MODELAGEM DA PREVISÃO DE DEMANDA	71
6.1 CONTEXTUALIZAÇÃO NO PROCESSO DE PLANEJAMENTO	71
6.2 ABRANGÊNCIA DO ESTUDO	74
6.3 LEVANTAMENTO DOS DADOS	76
6.4 ANÁLISE PRELIMINAR DOS DADOS	77
6.5 SELEÇÃO DO MODELO DE PREVISÃO	85
6.5.1 Testes dos Modelos.....	88
6.5.2 O Modelo Escolhido.....	91
6.5.3 Melhoria do Modelo Escolhido	95

7. PROPOSTA DE IMPLEMENTAÇÃO	103
7.1 A FERRAMENTA DE PREVISÃO	103
7.2 PROPOSTA DE ADAPTAÇÃO DO PROCESSO DE PLANEJAMENTO	107
8. CONCLUSÃO	109
8.1 SÍNTESE E CONSIDERAÇÕES FINAIS	109
8.2 DESDOBRAMENTOS.....	111
REFERÊNCIAS BIBLIOGRÁFICAS.....	113
ANEXOS	115
I. RESULTADOS E ANÁLISES SUCINTAS DAS FAMÍLIAS II E III	115
II. TABELA DE DADOS PARA A REGRESSÃO LINEAR MÚLTIPLA	123

1. INTRODUÇÃO

Este trabalho tem como objetivo a realização de um estudo em torno da demanda do varejo brasileiro pelos bens de consumo de uma grande multinacional, através do desenvolvimento de modelos de previsão. Proporcionando um maior conhecimento da demanda e uma forma de prevê-la, esse estudo visa reduzir o comum problema de indisponibilidade ou insuficiência de produtos nos pontos de venda. A não presença de um determinado item em alguma loja pode ser traduzida como uma oportunidade de venda perdida e ainda, em alguns casos, como a migração do consumidor para a concorrência. Considerando o grande portfólio da empresa e o enorme volume que é girado no mercado varejista, pode-se perceber que o fato é realmente importante.

Assim sendo, o intuito desse trabalho é desenvolver um modelo de previsão que proporcione à empresa maiores informações sobre o comportamento de sua demanda e, consequentemente, melhores condições para que a decisão quanto à forma de abastecimento do varejo seja bem feita.

Introduzido o contexto do projeto é válido fazer-se um breve resumo do que será encontrado nesse documento.

No Capítulo 2 é apresentada a empresa onde o trabalho foi desenvolvido, sendo caracterizada a sua História, as suas principais marcas e produtos, além de sua estrutura física e de negócios.

O Capítulo 3 busca demonstrar como se dão as principais etapas que envolvem o processo de vendas dentro da empresa. Há um grande destaque para os procedimentos de planejamento da demanda e de atendimento dos pedidos, destacando-se nesse último, tanto o fluxo de informações quanto o fluxo físico que caracterizam um pedido desde a efetuação até sua chegada à gôndola do supermercado.

O Capítulo 4 busca desenvolver e apresentar detalhadamente o problema diagnosticado nesse cenário e sua relevância de estudo. Além disso, é nele que são definidos concretamente os reais objetivos desse trabalho.

No Capítulo 5 é realizada uma revisão bibliográfica vinculada aos pontos mais relevantes trabalhados ao longo desse estudo. O objetivo da mesma é apresentar os principais conceitos teóricos existentes na literatura que serviram para fundamentar a análise do problema e orientar a escolha da melhor solução para tratá-lo.

O Capítulo 6 explicita detalhadamente toda a metodologia recomendada para o levantamento e análise dos dados disponíveis, bem como para a escolha do modelo mais apropriado para o caso estudado. Ainda nele desenha-se a melhor solução e avaliam-se os resultados obtidos com a aplicação da mesma.

No Capítulo 7 é realizada a proposta de implementação da solução delineada, procurando-se apresentar a ferramenta elaborada para a efetiva utilização do modelo de previsão e, as possíveis adaptações que o atual processo de planejamento da demanda deverá sofrer para um bom funcionamento do sistema criado.

Por fim, o último capítulo é destinado aos comentários finais e conclusões do estudo realizado, onde serão desenvolvidas análises críticas sobre o mesmo, como também, algumas sugestões de desdobramentos futuros desse trabalho.

2. A EMPRESA

Para um melhor conhecimento do local onde foi desenvolvido esse trabalho, a empresa em estudo será apresentada a seguir com base em informações bastante relevantes, tais como: histórico, marcas e produtos comercializados, além das estruturas físicas e de trabalho.

2.1 HISTÓRICO

A Unilever – uma das maiores empresas do mundo na área de alimentos, higiene e beleza – teve sua história iniciada na Inglaterra em finais do século XIX, quando William Hesketh Lever (um dos fundadores da empresa, então chamada Lever Brothers) teve uma idéia original e muito bem aceita: dar nome e embalagens individuais aos sabões que fabricava, o Sunlight.

Em uma época em que o sabão era um produto genérico e vendido por peso, Sunlight se tornou um sucesso com seu nome atraente, sua bela embalagem e, obviamente, uma qualidade difícil de ser encontrada. Com isso, o crescimento veio rápido e logo a empresa expandiu sua atuação para outros países.

Em 1929, a Lever Brothers ampliou seus mercados unindo-se a um grupo holandês da área de alimentos. Nascia aí a Unilever, que no mesmo ano surgiria também no Brasil, mais especificamente na cidade de São Paulo, como Sociedade Anônima Irmãos Lever.

No ano seguinte à chegada ao país, começa a funcionar a primeira fábrica da companhia, que deixa de importar o sabão Sunlight e os Flocos Lux ingleses e passa a ter sua própria produção no Brasil.

Em 1960, a Irmãos Lever faz sua primeira grande e significativa aquisição: a Cia. Gessy Industrial, uma experiente e muito popular empresa nacional no ramo de higiene pessoal. A importância de tal negócio foi tamanha que a Irmãos Lever até trocou o seu nome: surge nessa data a Gessy Lever.

Uma década depois, a empresa ingressou no mercado brasileiro de alimentos com o lançamento de Doriana, a primeira margarina cremosa do país. Em 1986, estabeleceu sólida base no mercado alimentício ao adquirir a Anderson Clayton S/A e, em 1993, ampliou ainda mais sua atuação nesse segmento com a compra da Cica.

Em 1997, adquire a Kibon, a maior aquisição da Unilever fora dos Estados Unidos, evidenciando o claro comprometimento da empresa com o país.

Três anos mais tarde, a Unilever realiza uma fusão internacional com a Bestfoods, uma das maiores empresas de alimentos do mundo, até então conhecida no Brasil como Refinações de Milho Brasil (RMB). O negócio representou um salto na participação da empresa no mercado de alimentos com um portfólio renovado por marcas de grande penetração e tradição no país, como: Hellmann's, Arisco, Knorr e Maizena.

Por fim, em 2001, acompanhando o conjunto de mudanças internas que se iniciaram com essa última aquisição, a Gessy Lever abandona essa assinatura e passa a adotar sua identidade internacional: Unilever.

Para propiciar uma visualização mais resumida da história da Unilever, foi elaborada uma linha do tempo com os principais acontecimentos para a empresa, conforme pode ser visto na Figura 2.1.

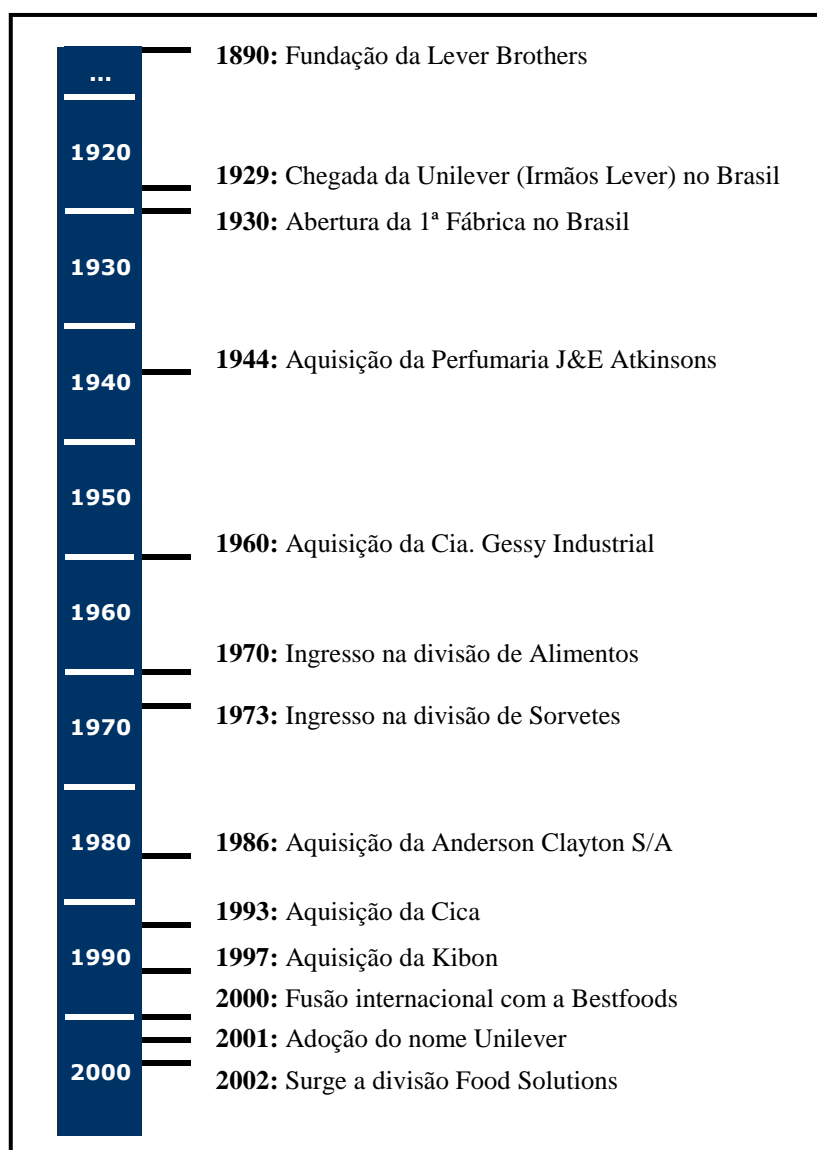


Figura 2.1 – Linha do tempo da Unilever

2.2 MARCAS E PRODUTOS

Atualmente, a Unilever do Brasil apresenta uma enorme variedade de marcas nas mais diversas áreas de atuação. As excelentes aquisições realizadas ao longo de sua história e o contínuo crescimento durante esses 80 anos de existência, propiciaram à Unilever uma incrível solidez e a conquista da posição de ser uma das maiores empresas de consumo do país.

Obviamente que conforme a empresa cresce, maior é a exigência de organização da mesma. Assim sendo, para melhor controlar e gerenciar suas mais de 25 marcas no mercado, a Unilever criou internamente quatro divisões principais buscando separá-las por tipo de negócio. Estruturada dessa forma, ela acredita que pode lidar mais facilmente com os *gaps* e oportunidades do mercado para atingir a liderança e o crescimento de cada um desses segmentos e, conseqüentemente, da companhia como um todo.

Dessa forma, é válido caracterizar resumidamente todas essas divisões, buscando apresentar as principais marcas pertencentes a cada uma delas.

➤ HPC (*Home and Personal Care*)

Trata-se da divisão referente aos cuidados com a casa (*Home Care* – HC) e aos cuidados pessoais (*Personal Care* – PC), isto é, corresponde ao segmento que cuida dos produtos destinados à higiene e beleza dos seus consumidores. Há diversas categorias que compõe essa divisão, dentre as quais podemos destacar: detergentes em pó, amaciantes, limpadores, desodorantes, produtos para cabelos, sabonetes, higiene bucal e produtos para pele.

A divisão de HPC da Unilever ocupa a liderança de mercado em diversas dessas categorias, cujas principais marcas podem ser encontradas na Figura 2.2.



Figura 2.2 – Principais marcas de HPC

➤ FOODS

Trata-se da divisão correspondente aos produtos alimentícios, um segmento que atua em um mercado muitíssimo exigente e com concorrência bastante acirrada. A Unilever acredita que a receita de sucesso para continuar a crescer e ser reconhecida como a melhor empresa de alimentos do país é oferecer ao consumidor produtos confiáveis, inovadores e a preços acessíveis. Nessa divisão também há diferentes categorias, dentre as quais se destacam: bebidas, amidos, molhos, produtos a base de tomates e culinários. Na Figura 2.3 encontram-se as principais marcas desse segmento.



Figura 2.3 – Principais marcas de FOODS

➤ ICE (*Ice Cream*)

Trata-se da divisão de sorvetes da Unilever, isto é, corresponde à Kibon, uma líder de mercado mesmo antes de ser adquirida pela empresa. O segmento se destaca pelo constante investimento em inovação, buscando sempre trazer lançamentos e desenvolver conceitos e sabores para cada tipo de cliente. A Kibon, desde 2003, adota um novo posicionamento e transforma o logo do coração (vide Figura 2.4) em uma marca ainda mais poderosa com reconhecimento mundial.



Figura 2.4 – Logo da Kibon

➤ FOODSOLUTIONS

Trata-se da divisão que veio para consolidar a posição da empresa no mercado de alimentação fora de casa – *Food Service* – composto por restaurantes, cadeias de *fast-food*, hotéis, *rotisseries*, entre outros. As marcas envolvidas nessa divisão são, em sua maioria, as mesmas de FOODS, porém oferecendo apenas embalagens alimentícias de grande escala (*big sizes*).

É válido ressaltar que o presente trabalho terá como foco os principais produtos pertencentes às divisões de HPC e FOODS, já que estes são os segmentos que o autor tem maior contato na empresa e estão diretamente envolvidos com o problema diagnosticado.

2.3 ESTRUTURA DA EMPRESA

A Unilever possui atualmente no Brasil um total de 12 fábricas espalhadas por quatro estados diferentes: São Paulo, Pernambuco, Minas Gerais e Goiás (vide Figura 2.5). Cada uma dessas fábricas é responsável pela produção “exclusiva” dos produtos de apenas um dos negócios da empresa (alimentos, higiene e beleza ou sorvetes).

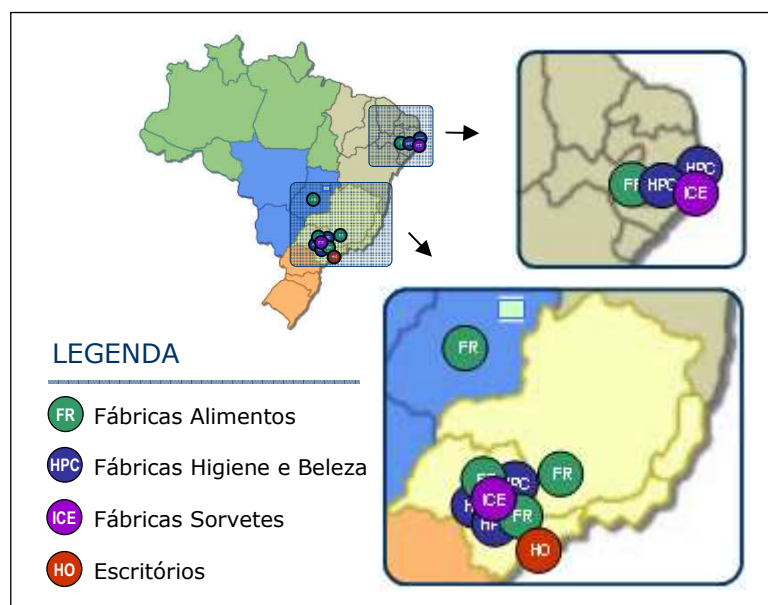


Figura 2.5 – Fábricas e escritórios da Unilever Brasil

Os escritórios concentram-se na cidade de São Paulo em dois luxuosos prédios, vizinhos entre si, nomeados pela própria Unilever de JK1 e JK2, já que ambos estão localizados em um dos pontos mais valorizados da cidade: a Av. Juscelino Kubitschek. O JK1 - inteiramente ocupado pela Unilever - surgiu em 2006, reunindo pela primeira vez na história da empresa no país, todos os três negócios em uma única sede. Em 2008, houve a necessidade de expansão e três andares do prédio JK2 foram obtidos.

Tamanha estrutura exige um elevado número de funcionários envolvidos. Hoje no mundo, a Unilever possui aproximadamente 300.000 funcionários trabalhando nos mais de 150 países em que a companhia está presente, sendo que 14.000 deles estão aqui no Brasil.

2.4 O ESTÁGIO

É válido destacar que, durante todo o ano de 2009, o autor deste trabalho realizou estágio na área de Vendas da Unilever, atuando, mais especificamente, na *Regional Key Account*. Durante esse período, foi responsável pela conta da rede de supermercados Wal-Mart, trabalhando diretamente com toda a base de dados do mesmo, no intuito de analisar o andamento e comportamento das vendas e diagnosticar possíveis *gaps* para que medidas fossem tomadas.

É importante dizer que os dados manuseados pelo autor estão relacionados a duas das divisões da companhia: cuidados pessoais e cuidados com a casa (HPC) e alimentos (FOODS). Quando isso acontece dentro da empresa, denomina-se que o indivíduo está trabalhando com dados HPF (*Home care, Personal care and Foods*).

Dessa forma, ressalta-se aqui que este trabalho terá como foco a área de maior conhecimento e contato do autor. Assim sendo, o estudo a ser realizado tomará como base o processo de vendas da Unilever para o Wal-Mart, considerando principalmente os produtos das divisões de HPC e FOODS.

Apesar de o autor estar envolvido com todos os SKU's (*Stock Keeping Unit*) produzidos pela Unilever nessas duas divisões e com toda a rede do Wal-Mart, a existência de centenas de SKU's distintos e de um grande número de bandeiras dentro da rede do cliente (vide Seção 2.5) impossibilitam uma análise envolvendo todos os dados. Dessa forma, este trabalho foi desenvolvido considerando apenas algumas amostras de produtos e as lojas de uma mesma bandeira, de maneira a criar um cenário que possa ser facilmente replicável para todos os outros casos.

2.5 O VAREJISTA

Chegada ao Brasil em meados de 1995, a rede de supermercados Wal-Mart sempre adotou uma política agressiva de manter preços mais baixos que a sua concorrência e, por isso, não parou de crescer. Hoje, presente em 18 estados brasileiros, a rede conta com cerca de 350 lojas de nove bandeiras diferentes e encaixadas em quatro formatos de lojas, conforme mostrado na Tabela 2.1. Tamanha divisão tem como objetivo a adaptação e a satisfação das necessidades dos mais distintos perfis de consumidores.

Tabela 2.1 – Caracterização dos formatos de loja da rede Wal-Mart

FORMATO	CARACTERÍSTICAS	BANDEIRA DA LOJA
Hipermercado	Contém 45.000 a 65.000 itens disponíveis	
		
		
Supermercado	Contém cerca de 15.000 itens disponíveis	
		
		
Atacado	Contém cerca de 6.000 itens disponíveis	
		
Loja de Vizinhança	Contém cerca de 4.000 itens disponíveis	

É importante destacar que o trabalho da Unilever com a conta do Wal-Mart engloba análises estratégicas e negociações com todas as bandeiras apresentadas acima. Para suprir as necessidades particulares apresentadas por esses formatos de loja, equipes de vendedores são criadas para atender exclusivamente cada uma das bandeiras do grupo. Além disso, essas equipes, geralmente, se subdividem de forma a permitir atendimentos focados em apenas uma das divisões da empresa.

Aqui é válido apontar que a bandeira Wal-Mart Supercenter ou, simplesmente, Wal-Mart, foi a escolhida para ser o foco das análises desse trabalho, já que ela é a bandeira com maior facilidade de acesso às informações.

3. O PROCESSO DE VENDAS

Para melhor compreender o funcionamento da empresa e o objetivo desse trabalho, posteriormente apresentado, esse capítulo será dedicado à explicação das principais etapas inseridas no processo de vendas da Unilever.

3.1 PLANEJAMENTO DE DEMANDA

Pode-se dizer que o processo de previsão de demanda se inicia em todo final de ano com a definição do chamado *Annual Plan* (AP): um plano que prevê as vendas, mês a mês, de todo o ano que está para se iniciar.¹ Vale destacar que esse é um processo que começa com o envolvimento da alta diretoria de diversas áreas (Finanças, Gerenciamento de Categoria, Marketing, *Supply Chain* e Vendas) que, a partir de premissas sobre o comportamento esperado do mercado, o desempenho obtido nas vendas, o nível de investimento disponível e as estratégias pretendidas, desenvolvem um plano para a companhia.

O AP desenvolvido é uma ferramenta para apontar quais são os volumes de vendas esperados para as categorias de cada Regional de Vendas e, a partir disso, torna-se um meio de definição da meta anual a ser atingida pela empresa. Toda organização é cobrada com base nesse plano, ou seja, ele é a principal referência dos níveis adequados de produção e venda.

Dessa forma, é com base em todas essas definições que cada Regional determina o seu próprio AP: plano que especifica separadamente para os clientes o que se esperar das suas respectivas vendas ao longo do ano em cada categoria das divisões da empresa, sem qualquer abertura por marcas ou SKU.

Vale enfatizar que as informações contidas no AP são obtidas sem o uso de qualquer método formal, sendo a previsão realizada apenas com base no histórico das vendas efetuadas no ano que está se encerrando e, nas estratégias de crescimento traçadas pela empresa.

Para melhorar o nível dessas previsões estabelecidas, cada conta de atendimento realiza, trimestralmente, uma reunião para detalhar e rever os números inicialmente definidos. Nesse procedimento, a previsão de cada categoria é feita no nível das suas marcas, buscando fixar a previsão do trimestre que se inicia e ajustar as previsões de todos os meses restantes no ano.

¹ **Nota do Autor:** É importante destacar que os procedimentos do AP aqui descritos englobam toda a previsão para os mercados de varejo e atacado e, por isso, incluem integralmente as divisões de HPC, FOODS e ICE. A divisão FOODSOLUTION é tida na empresa como um negócio à parte e, portanto, possui procedimentos um pouco distintos que não serão abordados neste trabalho.

Trata-se, portanto, da elaboração de um plano que revise os números definidos pelo AP em maior nível de detalhamento e que especifica a previsão do próximo trimestre. Esse plano é chamado de *Annual Quarter Plan* (AQP) e é definido integralmente pela área comercial.

Concluída essa elaboração, o AQP é enviado à equipe de Planejamento, Marketing e *Trade Marketing* para passar por uma avaliação mensal que visa verificar se há ou não consistência no mesmo. Essa avaliação cruza as metas estabelecidas pelo AP original com o que já foi realizado e com a previsão ali apresentada. Dessa forma, ao final de todo mês é feita uma Reunião de Estimativa envolvendo as áreas citadas, que avalia a necessidade (ou não) de alterações nas previsões do AQP, gerando assim, as estimativas de um novo plano: o *Operational Plan* (OP). Logo, o OP pode incrementar o AQP, ou seja, quando os valores do AP não são atingidos em determinado mês e percebe-se que o AQP está baixo para atingir-se a meta anual, nas estimativas para os meses subsequentes podem entrar volumes maiores que buscam suprimir esses não atingimentos.

Concluída a etapa, o OP deve ser encaminhado de volta para a área comercial. Entretanto, antes disso, ele é enviado ao setor logístico onde os valores definidos para o mês são “repartidos” entre os SKU’s pertencentes às marcas em questão. O artifício aqui utilizado é a definição do *Share Of Assortment* (SOA) dos SKU’s, que nada mais é do que definir a porcentagem de participação de cada SKU dentro do volume total definido para sua respectiva marca. Esse valor é definido com base no histórico de vendas das últimas semanas, sem também nenhum uso de métodos formais de previsão de demanda.

A Figura 3.1 foi elaborada para uma melhor visualização do processo de planejamento de demanda realizado dentro da Unilever.

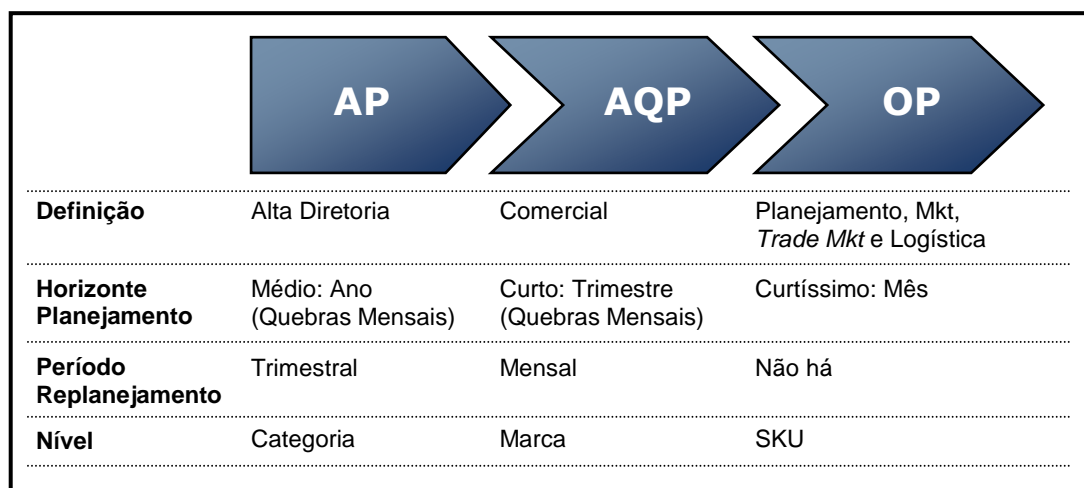


Figura 3.1 - Etapas do processo de planejamento da demanda

3.2 VENDA E ABASTECIMENTO DAS LOJAS

O processo de vendas que se dá entre a Unilever e o Wal-Mart é classificado como um processo de *Sell Out*, isto é, os pedidos são feitos pelo varejista conforme os lotes de produtos disponíveis em suas lojas vão se esgotando com as vendas ao consumidor final.

Para se entender corretamente todo esse processo é importante caracterizar todas as etapas envolvidas desde a efetuação do pedido por parte do varejista, até a sua chegada às gôndolas das lojas. Basicamente descrever-se-á aqui como se dão os fluxos físicos e de informação dentro desse processo.

Fluxo de Informação

Esse fluxo se inicia com a ocorrência efetiva da venda de um determinado item ao consumidor final. O sistema de informação da loja Wal-Mart registra essa venda no exato momento em que o produto passa pelo caixa (*check out*) da loja e já o desconta do montante total em estoque, registrado em sua base de dados. Ou seja, a cada venda é realizado um cruzamento entre as quantidades do item que foram compradas pela loja e as quantidades vendidas pela mesma, de forma a identificar qual é o tamanho atual do estoque daquele item para aquela loja em específico.

Cada loja é responsável por calcular, para todo item ali comercializado, um parâmetro numérico com o intuito de indicar a quantidade mínima que significa um estado de atenção quanto ao nível dos estoques. Esse parâmetro é cadastrado na base de dados do sistema que, ao perceber atingi-lo, dispara um alerta sinalizando ser o momento de fazer um pedido para o item em questão. Logo, alcançar o parâmetro é equivalente ao ponto de pedido das lojas.

Emitido o sinal, o setor de compras da loja gera um pedido ao Centro de Distribuição (CD) da própria rede Wal-Mart. Devido à enorme variedade de itens que circulam pelas lojas, o CD classifica e trabalha com dois “tipos” de produtos: os estocáveis, que apresentam um conjunto de características que o fazem merecer a manutenção de um certo nível de estoque; e, os não estocáveis, que não se demonstram interessantes de manter estoques. Assim, chegada a solicitação do pedido ao CD, há duas possibilidades de continuidade: a primeira, para o caso do item possuir estoque, em que é feito o simples envio do lote encomendado para a loja; e, a segunda, para o caso do item não possuir estoque, em que é realizado um pedido pelo CD do Wal-Mart para o CD da Unilever. Essa verificação do item ser ou não estocável e estar ou não presente no CD é equivalente ao ponto de pedido do CD.

Pode-se dizer que o *lead time* desse processo é composto apenas pelas atividades que dependem diretamente da ação humana para a sua ocorrência visto que as etapas de responsabilidade do sistema acontecem automaticamente em um tempo que pode ser considerado nulo. Assim sendo, somente as etapas de pedidos das lojas ao CD do Wal-Mart e deste último ao CD da Unilever apresentam intervalos de tempos para a sua ocorrência. Ambos são iguais e podem variar de zero a um dia útil de forma que, consequentemente, o fluxo como um todo varia de zero a dois dias úteis para ser concretizado.

A Figura 3.2 permite uma observação gráfica de todo o fluxo de informação acima apresentado.

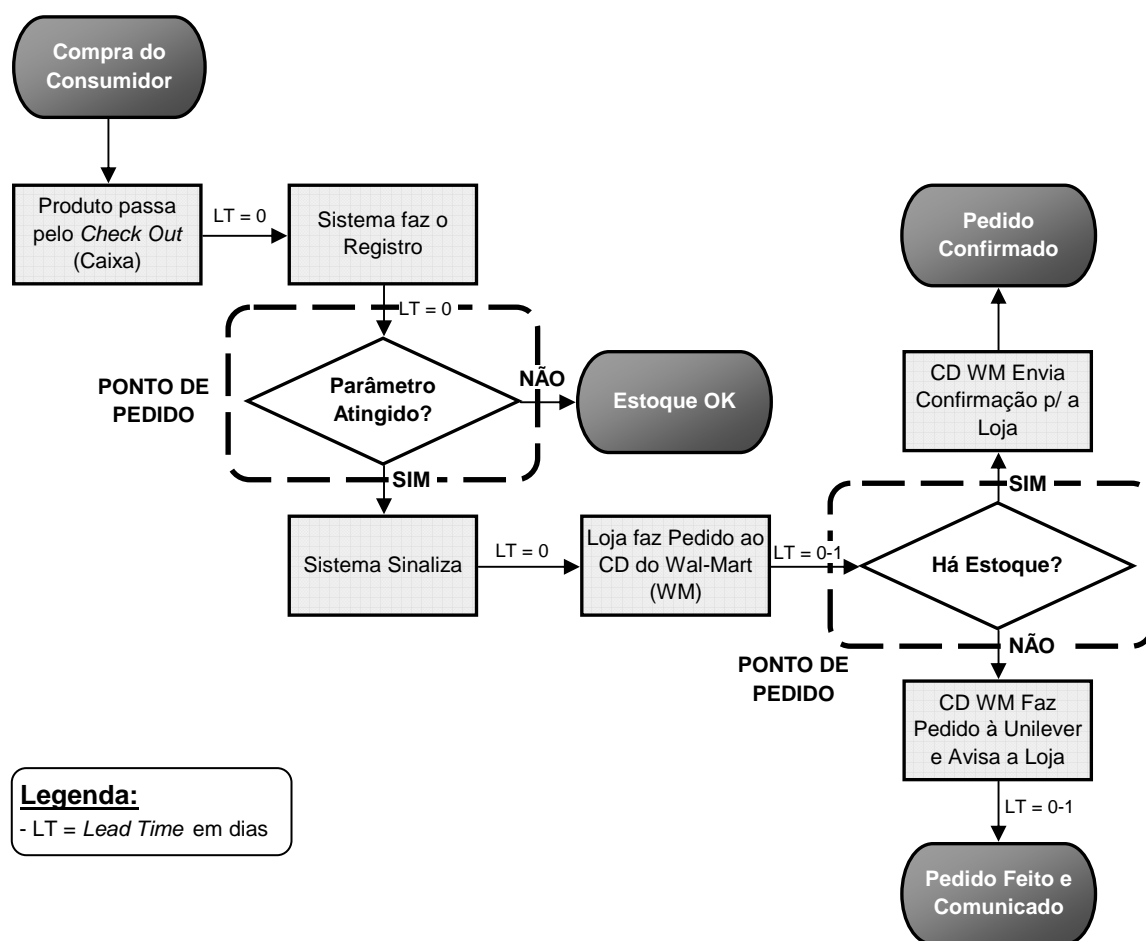


Figura 3.2 - Fluxo de informações de um pedido

Conforme se pode observar no fluxograma, o processo de decisão referente a que pedidos devem ser realizados é de total responsabilidade do Wal-Mart. Entretanto, a equipe de vendas da Unilever existe justamente para não ficar passiva a esse fato, isto é, ela interage constantemente com a rede para tentar evitar e/ou corrigir rapidamente os constantes erros presentes nesse sistema.

Fluxo Físico

O fluxo em questão se inicia exatamente com o término do fluxo de informação apresentado, ou seja, a efetivação do pedido por parte do cliente à Unilever atua como *starter* do processo físico de atendimento do mesmo.

Assim, chegado o pedido ao CD da Unilever, os lotes de produtos encomendados são separados e colocados no caminhão para poder ser feita a entrega ao CD do Wal-Mart. Normalmente os pedidos solicitados pelo varejista ocorrem em datas fixas da semana – Terças, Quintas e Sábados – e, da mesma forma, as entregas geralmente ocorrem dois dias úteis depois de recebida a encomenda – Quintas, Sábados e Terças, respectivamente. É válido ressaltar que em casos emergenciais o pedido pode ser feito independente do dia da semana e ser entregue ao CD do varejista no dia seguinte ou ainda no mesmo dia.

Quando o CD do Wal-Mart recebe os lotes que pediu, há, seguindo o mesmo raciocínio do fluxo de informação, duas possibilidades de continuação: a primeira delas acontece quando o pedido foi efetuado para abastecer o próprio CD, o que implica na estocagem dos lotes recém-chegados; e, a segunda ocorre quando o lote foi pedido para abastecer as lojas necessitadas, implicando em seu encaminhamento para as mesmas. Nesse último caso é interessante dizer que o *lead time* para a entrega nas lojas geralmente varia de um a três dias. Em alguns casos, a mercadoria recém entregue pelo fornecedor fica pouquíssimas horas no CD, sendo apenas baldeada do caminhão Unilever para o caminhão Wal-Mart (*crossdocking*).

Chegado o caminhão com os produtos na sua respectiva loja, é necessária uma autorização de descarga por parte dos responsáveis pelo abastecimento. Enquanto não autorizado, o caminhão fica aguardando nas docas da loja. Geralmente, a descarga é realizada imediatamente após a chegada do caminhão ou depois de poucas horas. Entretanto, devido às inúmeras variedades de itens que as lojas trabalham e caminhões que recebem, algumas vezes acontece de haver grandes filas de descarregamentos e, nesses casos, pode-se demorar até um dia e meio para a liberação da carga.

Concedida a autorização os funcionários do Wal-Mart descarregam toda a mercadoria para o pequeno estoque mantido pela loja. Como as lojas buscam manter o menor estoque possível dentro de si, praticamente toda encomenda realizada é programada para caber inteiramente na gôndola destinada ao item em questão, ou seja, quando os produtos chegam à loja, os promotores da Unilever que ali trabalham são avisados e imediatamente providenciam a retirada dos produtos do estoque, destinando-os às prateleiras. Como os promotores precisam

reabastecer as gôndolas de todos os produtos da empresa que chegaram, a atividade normalmente é finalizada em até um dia de trabalho.

Para um melhor entendimento dos procedimentos descritos, a Figura 3.3 oferece uma observação gráfica de todo o fluxo físico apresentado.

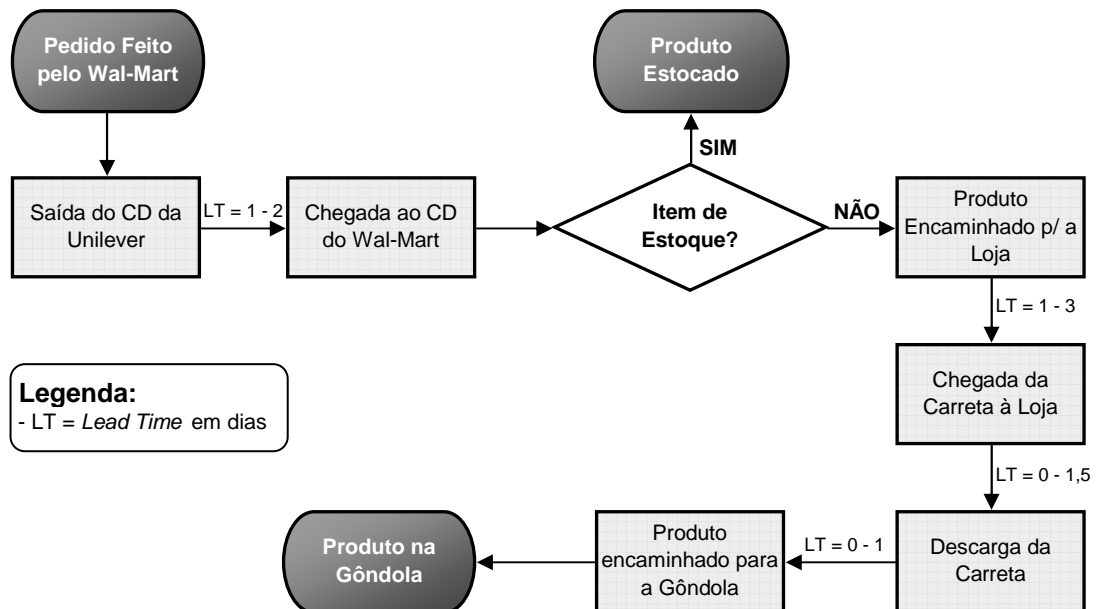


Figura 3.3 – Fluxo físico de um pedido

Apresentado todo o fluxo, percebe-se que o tamanho do estoque máximo da maior parte dos produtos que a loja mantém é bastante restrito, ou melhor, é o equivalente ao número de itens que conseguem preencher todo o espaço da prateleira destinada a ele. Apesar de já ter sido superficialmente citado a maneira de reabastecimento desse estoque, é válido um breve aprofundamento no assunto dado que essa questão é de grande relevância e está bastante vinculada à realização do presente trabalho.

Estoque nas Lojas Wal-Mart

Tendo em vista todo o conteúdo acima abordado, percebe-se que as lojas do Wal-Mart apresentam um modelo de reabastecimento dos estoques que é reativo à demanda, isto é, os pedidos são somente realizados conforme os produtos vão sendo vendidos e o estoque atinge o valor do parâmetro definido. O tamanho do lote encomendado é sempre o mesmo e é obtido pela diferença da quantidade máxima de produtos que cabem na gôndola destinada ao item e o valor do seu parâmetro. Assim sendo, pode-se dizer que essa forma de operação dos estoques segue um modelo de lote fixo.

O parâmetro usado nesse modelo é atualmente calculado de acordo com a média diária de vendas que o item apresentou nas últimas semanas e considera como restrição apenas o *lead time* entre o pedido e a chegada do produto até a gôndola, visando evitar que ela fique vazia. A fórmula simplificada para esse cálculo é:

$$\text{Parâmetro} = Q_{\text{frente}} + X_{\text{médio}} \cdot LT$$

Onde, Q_{frente} = quantidade de unidades que ocupam a “frente” da gôndola destinada ao item
 $X_{\text{médio}}$ = média de vendas nas últimas semanas
 LT = *lead time* desde o pedido até a chegada dos produtos à gôndola

A quantidade Q_{frente} é tida como o estoque de segurança do produto e é igual ao número de unidades que cabem na primeira fileira de produtos da gôndola. Teoricamente essa consideração tem por objetivo manter a visibilidade desejada para o item e evitar o aparecimento de “buracos” na prateleira. O *lead time* assumido para esse cálculo é de 5 dias, pois esse é considerado pelo Wal-Mart o valor médio do processo.

Para um melhor entendimento desse cálculo segue-se um exemplo hipotético. Supondo que determinado item possua 16 unidades de “frente” de gôndola e tenha obtido nas últimas semanas uma média diária de vendas de 4 unidades, chega-se à seguinte situação:

$$\text{Parâmetro} = 16 + 4 \cdot 5 = 36 \text{ unidades}$$

Como a capacidade máxima da prateleira, geralmente, é determinada pela quantidade que cabe em sua “frente” adicionada de mais três colunas idênticas de produto alocadas atrás dela, conclui-se que o estoque máximo desse item é de 64 unidades. Assim, a quantidade a ser pedida pode ser obtida por:

$$\text{Pedido} = \text{Estoque Máximo} - \text{Parâmetro}$$

$$\text{Pedido} = 64 - 36 = 28 \text{ unidades}$$

Tendo esse número, é necessário transformar a quantidade dada em unidades em um número inteiro de caixas, arredondando da forma mais conveniente possível. Dessa maneira, no exemplo, se o produto vier em caixas com 12 unidades, seriam encomendadas pela loja 2 caixas do mesmo.

É interessante ressaltar que apesar desse modelo aparentemente considerar o fator visibilidade em seus cálculos, percebe-se que ele não garante a sua plena implementação. Ao definir a quantidade de itens que satisfaz a estratégia de visibilidade como sendo o valor do estoque de segurança, especifica-se que esse “excedente” atuará, não para assegurar a presença de toda a “frente” da gôndola, mas sim, e, principalmente, para absorver eventuais variações na demanda pelo produto. Assim sendo, para qualquer excesso ocorrente surgirão buracos na gôndola do item e a sua visibilidade estará prejudicada.

Além disso, pode-se dizer que esse modelo não considera fatores como a existência de ações promocionais e a possível sazonalidade da demanda como restrições nos seus cálculos. Esses são fatos que podem influenciar bastante a demanda do item e, conseqüentemente, a necessidade de pedidos.

Vale relembrar que essa foi apenas uma abordagem sucinta a respeito do modelo de gestão de estoques existente atualmente no Wal-Mart. Um maior aprofundamento sobre esse e os diversos modelos existentes na literatura será apresentado no Capítulo 5.

4. DEFINIÇÃO DO PROBLEMA E OBJETIVO

Este capítulo busca apresentar o problema central da empresa em estudo, bem como o objetivo deste trabalho. Entretanto, antes de descrevê-los é necessária a apresentação da visão geral de um tema extremamente relevante para o entendimento desse projeto: a ruptura de gôndolas.

4.1 RUPTURA

Nos últimos anos, o mercado de bens de consumo tem se tornando cada vez mais dinâmico e muito mais acirrado com a grande concorrência que foi instaurada pelas empresas do setor. Dentro desse contexto, inúmeros são os fatores que passaram a ser levados em consideração na tentativa de conquistar a preferência do *shopper*² na hora da compra. Estratégias de preços, de visibilidade do produto no ponto de venda, de publicidade, e, de enaltecimento da marca são alguns exemplos de ações que passaram a ser constantemente utilizadas para chamar a atenção.

Para viabilizar a implementação de qualquer uma dessas ações, um fator passou a ser extremamente importante nesse cenário: a disponibilidade dos produtos. Ter o produto na loja é fundamental para alavancar sua venda. Apesar da obviedade de tal premissa, ainda hoje é frequente deparar-se com a falta de diversos produtos nos supermercados. Por este motivo, vem à tona um novo termo amplamente utilizado no setor varejista para expressar essa deficiência, a chamada ruptura de gôndolas.

Entende-se por ruptura a ausência completa de determinado produto nas gôndolas do supermercado, ou ainda, a insuficiência quantitativa do mesmo na loja a ponto de não poder satisfazer a estratégia de visibilidade estabelecida pela empresa ou possibilitar a montagem de pontos extras³ previamente acordados.

² **Nota do Autor:** para a Unilever, *shopper* é a pessoa que executa a compra de um produto ou marca. Não é necessariamente o consumidor, pois ela pode ser responsável pela compra de um produto a ser consumido por outras pessoas. O *shopper* está em um estado de espírito diferente do consumidor e, por isso, é impactado por todas as variáveis do ponto de venda.

³ **Nota do Autor:** ponto extra é todo local em que o produto está sendo exposto de forma adicional à sua exposição regular, ou melhor, a sua gôndola de costume. São exemplos tradicionais de ponto extra:

- *Ponta de Gôndola:* é a extremidade que liga duas fileiras de gôndolas de corredores distintos, ou seja, é a “esquina” de dois corredores, voltada para um dos corredores principais de circulação.

- *Ilha:* é o ponto montado no centro de um corredor principal de circulação sem estar em prateleira alguma, ou seja, é realmente uma ilha montada com o produto.

Em pesquisa realizada por Latin Panel (2009) foram diagnosticadas as principais reações que o *shopper* brasileiro expressa ao deparar com a falta de algum produto na loja em que está realizando a sua compra. A pesquisa separa a análise por divisão de negócios e, assim sendo, apenas as informações referentes às duas divisões da Unilever consideradas neste estudo (HPC e FOODS) foram utilizadas. Feita uma ponderação dos dados com a representatividade de cada divisão na companhia, obtiveram-se os resultados apresentados na Figura 4.1.




Figura 4.1 – Comportamento do shopper brasileiro perante a falta de produto na loja

FONTE: Adaptado de Latin Panel (2009).

Analisando o resultado da pesquisa, percebe-se que o problema da ruptura não afeta apenas o fornecedor do produto, mas também, impacta as atividades do varejista. Para o lojista, a falta de um produto procurado pelo *shopper* e não encontrado significa, em 36% dos casos, uma oportunidade de venda perdida que nunca mais será retomada. O cenário piora quando se analisa que 23% dos *shoppers* partem para comprar esse produto faltante em outra loja, o que prejudica a imagem do varejista e implica, em forte tendência, a essas pessoas mudarem de estabelecimento de preferência. Segundo pesquisa da AC Nielsen (2004) geralmente na terceira vez que um cliente não acha algo que foi comprar, ele deixa o seu carrinho com a metade da compra, muda de loja para nunca mais voltar e divulga o ocorrido para muita gente. Logo, a falta de um produto pode significar não somente uma venda perdida, mas sim, diversas oportunidades perdidas, ou até mesmo, a perda definitiva do cliente.

Olhando para o lado do fornecedor, percebe-se que o mercado em que a Unilever está inserida é bastante competitivo e, por isso, 64% dos *shoppers* que não encontram o produto da marca que desejavam, acabam comprando o mesmo produto só que de uma outra marca. Além de

gerar a perda de receita, esse fato oferece a oportunidade da fidelidade que o cliente tem com a marca ser abalada, podendo trazer uma perda de *market share* para o fornecedor.

Visto o quão significativa é a questão da ruptura tanto para o fornecedor dos produtos, quanto para os varejistas, é interessante buscar-se quais são as principais causas para a sua ocorrência. AC Nielsen (2004) fez tal levantamento. Veja abaixo.

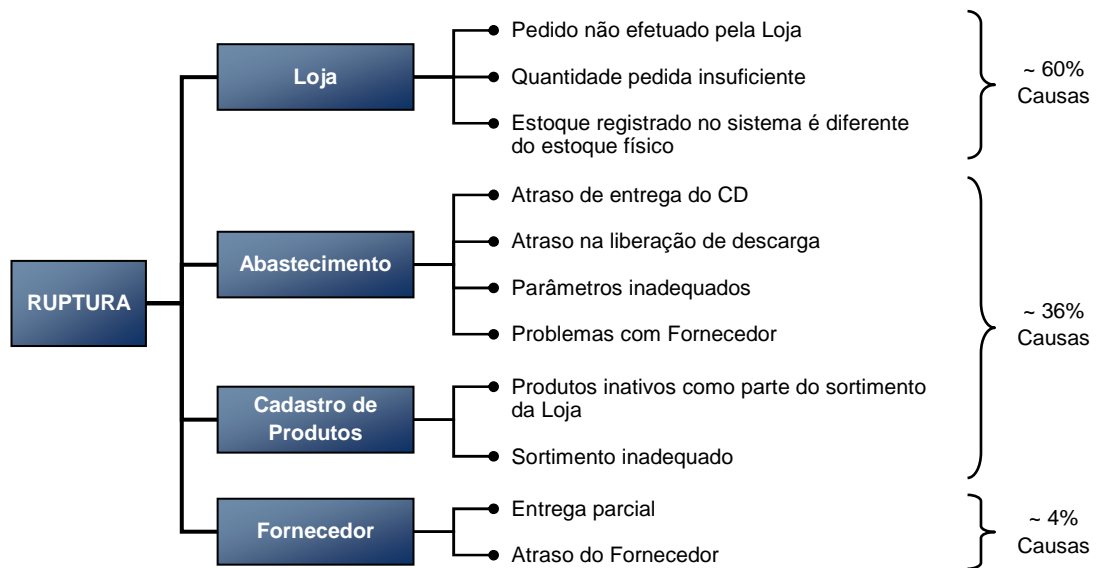


Figura 4.2 – Causas para a ocorrência da Ruptura

FONTE: AC Nielsen (2004).

Percebe-se que todas as causas apresentadas acima giram em torno de problemas operacionais ou de decisão inseridos na cadeia de suprimentos. Elementos como produção, transporte, estoques, estratégias e demanda são apenas alguns exemplos que possuem inúmeras variáveis afetando-os individualmente. Entretanto se não houver uma preocupação de se identificar os erros visualizando o inter-relacionamento desses elementos, dificilmente uma atuação corretiva será realmente funcional.

4.2 O PROBLEMA

Chopra e Meindl (2004) explicitam que o sucesso global de uma empresa está intimamente ligado ao alcance do alinhamento entre a sua estratégia competitiva e a estratégia da cadeia de suprimentos. Entretanto, atualmente percebe-se na relação fornecedor-varejista em estudo que nem sempre essa lógica é seguida à risca.

A estratégia competitiva do Wal-Mart é obter credibilidade e ser um varejista que oferece uma grande variedade de bens de consumo de boa qualidade, a preços baixos. Já a estratégia da Unilever é ser um fornecedor de produtos reconhecido por levar vitalidade para o dia-a-dia dos seus consumidores. Como a maioria dos produtos vendidos pelo Wal-Mart é comum e pode ser adquirida em diversas outras lojas e, a maioria dos produtos Unilever apresenta itens semelhantes de marcas concorrentes que podem substituí-la, o que deve ser prioridade para o atendimento simultâneo das estratégias de ambas as empresas é, sem dúvida alguma, o preço competitivo e a disponibilidade de produtos. Assim sendo, sugere-se que essa cadeia de suprimentos deva se concentrar na eficiência (baixo custo), mas sem nunca ignorar o nível de responsividade necessário (disponibilidade). Porém, o cenário atualmente encontrado não contempla totalmente essa realidade.

Pode-se dizer que na relação estudada tem-se, de um lado, um varejista que quer atingir o máximo de eficiência, atuando intensamente na busca por reduzir seus estoques e, de outro, um fornecedor que quer grande responsividade, buscando abastecer o varejo com o máximo que puder. Esse antagonismo de interesses tem sido um fator gerador de problemas nas vendas como um todo e, por isso, é interessante analisar-se cada lado separadamente.

Começando pelo Wal-Mart pode-se dizer que essa busca por reduzir drasticamente os níveis de estoque, acreditando na redução de seus custos, está atingindo diretamente a questão da disponibilidade de produtos. Conforme apresentado na Seção 3.2 as lojas do Wal-Mart efetuam seus abastecimentos seguindo um modelo reativo à demanda, isto é, realizam os pedidos apenas quando os valores de seus estoques atingem parâmetros estabelecidos. Entretanto, a forma como esse modelo vem sendo utilizado e o fato da demanda dos produtos Unilever ter um comportamento instável ao longo dos dias da semana, implicam na frequente ocorrência do pedido não chegar à loja a tempo de evitar sua falta ou, chegar em quantidade insuficiente para satisfazer a estratégia de visibilidade da empresa fornecedora.

As consequências da falta de produtos já foram apresentadas no item anterior, onde se foi demonstrado os grandes danos que ela pode trazer tanto para o varejista quanto para o fornecedor. Mas também, ter insuficiência quantitativa de algum item na loja, pode proporcionar diversas perdas.

Estudos da própria Unilever puderam comprovar que é real o impacto da visibilidade na venda dos produtos e, por isso, essa preocupação se tornou um dos pilares estratégicos da companhia. Muito passou a ser investido em pesquisas e materiais para a criação de um ponto de venda mais “atrativo”.

A Figura 4.3 mostra uma gôndola abastecida de acordo com a estratégia de visibilidade e outra afetada pela ruptura. É bastante visível a diferença de atratividade entre elas.



Figura 4.3 – Imagem de uma gôndola abastecida de acordo com a estratégia de visibilidade e de uma gôndola com ruptura

Não ter produto o bastante para colocar na gôndola de maneira adequada, não só gera a falta de visibilidade almejada para o item – o que com certeza atinge o volume de vendas – como também, pode implicar na perda (temporária) de espaço na gôndola para outros produtos com maior estoque, no intuito de se esconder os “buracos” formados na prateleira, até a chegada de um novo lote.

O caso de insuficiência para a execução de um ponto-extra na loja, também, é bastante relevante. Os pontos-extras são acordos comerciais estabelecidos entre a Unilever e o Wal-Mart. A falta quantitativa para a sua implementação geralmente ocorre devido ao fato de que é o setor logístico da rede varejista o responsável por fazer os cálculos e efetuar o pedido quando avisado do acordo firmado. Como esse setor tem pouco contato com o setor comercial do Wal-Mart e busca sempre manter níveis de estoque o mais baixo possível, muitas vezes são gerados pedidos insuficientes para a montagem desse ponto extra, isto é, se ele fosse montado já apresentaria sinais de ruptura. Como a Unilever paga um valor mensal para a execução de cada ponto extra acordado com o supermercado, não conseguir montá-lo, além de reduzir as possibilidades de venda e abrir espaço para outro produto ocupá-lo, há uma perda do investimento realizado para promoção do produto em questão.

Assim, pode-se perceber que falhas com pedidos não efetuados, quantidades pedidas insuficientemente e parâmetros mal calculados são os principais motivos de caráter decisório que levam à ocorrência da ruptura nas lojas do Wal-Mart, confirmando as estimativas apontadas na Figura 4.2.

Abordando agora o lado da Unilever, percebe-se que a forma de trabalho da mesma, também, não está operando no ótimo da cadeia. Podem-se citar duas questões que apontam para a necessidade de melhorias:

- O *Operational Plan* não possuir um método formal de elaboração e ser tratado como uma meta mais do que como uma real previsão da demanda; e,
- A equipe comercial ser principalmente cobrada para que a tonelagem total de itens vendidos atinja a soma da estimativa mensal, ao invés de basear-se em um plano de demanda mais direcionado e específico.

Os fatos acima citados geram a produção e a estocagem desnecessária de diversos produtos. Não se preocupando ao nível de SKU, o setor comercial passa a vender aquilo que conseguir “empurrar” para o varejista a fim de atingir a estimativa traçada, ao invés de se preocupar em oferecer todos os SKU’s fabricados pela empresa e indicados ao sortimento das lojas.

Ao fazer isso, toda a programação da produção pode estar sendo afetada. Vender ao varejista muito a mais do que estava previsto, de qualquer item que seja, exigirá da produção uma reposição mais rápida do estoque para não prejudicar a demanda prevista para os demais meses. Além disso, a venda em excesso pode acarretar na devolução de produtos por parte do cliente caso esteja chegando o prazo de vencimento e os mesmos não tenham tido demanda suficiente.

Por outro lado, vender quantidades muito inferiores do previsto, gerará um maior tempo de estoque e, conseqüentemente, uma menor eficiência. E, também, vender menos pode implicar em investimentos adicionais na promoção de ações de desova dos itens para que eles não estraguem em seus estoques. Todas essas, são perdas que poderiam ser evitadas.

Como o Wal-Mart é uma *Key Account* da Unilever, são poucos os produtos que faltam nas lojas por incapacidade de produção, já que as contas-chave têm preferência para o atendimento de suas demandas, buscando-se obter para elas uma alta responsividade. Justamente por isso, uma previsão de demanda mais aderente implicaria não só na responsividade almejada pela empresa, como também em uma melhor eficiência reduzindo custos de estocagem e diminuindo os gastos com desovas ou devoluções do cliente por excesso de produtos.

Tendo em vista os pontos expostos acima pode-se perceber que ambas as empresas estão falhando na busca pelo alinhamento estratégico, principalmente, quando se trata da

disponibilidade de produtos *versus* a eficiência da cadeia. Assim, compreende-se que a existência de um modelo de previsão mais preciso que saiba avaliar os impactos de cada ação estratégica e que leve em conta métodos quantitativos e qualitativos, deixando de ser apenas baseado na experiência e conhecimento dos profissionais envolvidos, será um facilitador para se obter menores estoques nas lojas e se reduzir os riscos de excessos ou faltas.

Desse modo, se as empresas conseguirem analisar e olhar abertamente para a cadeia de suprimento buscando otimizá-la como um todo e sabendo mensurar os reais impactos de cada uma das suas operações e decisões, com certeza obterão uma grande vantagem competitiva frente às demais cadeias de suprimento.

4.3 O OBJETIVO DO TRABALHO

Este trabalho se propõe a elaborar um modelo de previsão para a cadeia em estudo que permita a compreensão do comportamento da demanda e das influências que a mesma sofre mediante a ações comerciais próprias e/ou da concorrência. Inicialmente, pretende-se desenvolver um método quantitativo de projeção de séries temporais, inexistente na empresa, a ser complementado por informações de um método explicativo, que também será criado. O intuito é demonstrar que tal integração de informações pode tornar o modelo ainda mais robusto e melhorar a previsão.

A criação desse modelo tem por objetivo gerar informações mais precisas e adequadas para a resolução dos problemas já citados, todos relacionados à indisponibilidade de produtos nas lojas e ao dilema entre responsividade e eficiência.

Entendendo a demanda, será mais fácil a definição de como abastecer e gerenciar os estoques do varejo da melhor maneira. Logo, o trabalho visa oferecer para a cadeia maiores conhecimentos sobre a demanda de forma a propiciar condições para uma melhoria do modelo de abastecimento que, se bem sucedida, irá:

- Minimizar as aquisições, os níveis de estoques e os custos operacionais de reposição;
- Reduzir as faltas de produtos e as rupturas de gôndolas; e,
- Manter um nível de atendimento mínimo exigido.

Combinar bem esses fatores, é um grande passo para a otimização do funcionamento dessa cadeia de suprimentos.

Dessa maneira, a idéia é proporcionar uma visão para o fornecedor a ser compartilhada com o varejista, com o intuito de se atingir o que Chopra e Meindl (2004) chamaram de escopo estratégico interfuncional entre as empresas, ou seja, um cenário onde todos os participantes coordenam, em todos os seus setores, a estratégia comum para atender da melhor maneira as necessidades dos clientes finais, buscando maximizar o excedente de toda a cadeia e não apenas os lucros individuais.

Nesse contexto, a prática do planejamento, previsão e reabastecimento colaborativos (CPFR – *Collaborative Planning, Forecasting and Replenishment*) aponta para uma melhoria das relações de parceria entre os envolvidos. Assim, com a CPFR, que será melhor explicada no próximo capítulo, busca-se deixar cada vez mais claro que estrategicamente não importa quem é o responsável pela decisão dentro da cadeia, mas sim, se a decisão tomada esta sendo de boa qualidade e realizada em parceria.

Ao final desse trabalho, espera-se que os participantes da cadeia mudem sua postura individualista recente (por vezes, atual) para trabalharem com uma atitude mais voltada aos interesses de seus consumidores. De acordo com estudo realizado pela ECR Brasil (2000), se as empresas mudarem suas visões aproximando-as de alguns princípios da Resposta Eficiente ao Consumidor (*Efficient Consumer Response* – ECR), como mostrado na Tabela 4.1., o alinhamento estratégico poderá ser atingindo muito mais facilmente.

Tabela 4.1 – Mudanças esperadas nas visões de trabalho

FONTE: Adaptado de ECR Brasil (2000).

DE	PARA
Planejamento de vendas com bases históricas	Identificação do que é desejado pelo consumidor
Compra norteadas pelo “feeling” dos compradores e vendedores	Compra realizada com dados qualificados no ponto de venda
Vendedores simplesmente “tiradores de pedido”	Vendedores gestores de processo
Baixa frequência de negócios e relacionamentos	Alta frequência de negócios e relacionamentos
Negociação para repor o que já foi vendido	Negociação para ofertar o que é comprado pelos consumidores
Enfoque no dia-a-dia	Abastecimento estratégico
Ações isoladas dos membros do canal	Ações conjuntas entre os membros do canal
“Vender ao varejo”	“Vender pelo varejo”

5. REVISÃO BIBLIOGRÁFICA

Neste capítulo serão expostos os principais conceitos presentes na literatura que se relacionam com o tema do trabalho proposto. A realização de tal estudo bibliográfico foi fundamental para embasar todos os diagnósticos realizados, bem como para fundamentar o traçado da resolução do problema apresentado. Nas próximas linhas serão abordados os principais pontos relacionados ao gerenciamento de estoques, ao CPFR e à previsão de demanda.

5.1 GESTÃO DE ESTOQUES NO VAREJO

Pode-se dizer que competitividade é uma das palavras mais almejadas e, simultaneamente, temidas no vocabulário corporativo atual. Com a acelerada evolução da sociedade e os rápidos avanços tecnológicos obtidos nas últimas décadas, foi inevitável a transformação contínua do mercado em um ambiente cada vez mais acirrado. Neste contexto, obter vantagens competitivas perante os concorrentes tem sido o grande objetivo da maioria das empresas e, assim sendo, para aquelas que trabalham com produtos no varejo, a boa gestão dos estoques tornou-se uma questão fundamental.

Estoques podem ser definidos como quantidades ociosas de bens úteis mantidas, sob controle, aguardando o seu uso futuro (SANTORO, 2009), ou seja, tratam-se das matérias-primas ou produtos acabados que são acumulados, devido aos mais diversos motivos, para serem utilizados em algum momento adiante. Assim, pode-se dizer que os principais papéis executados pelos estoques são os de aumentar a parcela de demanda do mercado que pode ser atendida; reduzir custos por meio da economia de escala; e, garantir a disponibilidade de produtos para os consumidores, protegendo-os das faltas.

Enfim, Santoro (2009) explicita que o objetivo global da necessidade de modelagem dos estoques é minimizar custos diretamente ou indiretamente através da redução do custo ocasionado pela falta, ou seja, pelas perdas de vendas e, conseqüentemente, de margens.

Apesar da aparente simplicidade da definição, gerir estoques otimamente é uma tarefa extremamente complexa que envolve inúmeras variáveis e, por isso, são diversas as formas de gestão que podem ser aplicadas. Uma das grandes questões que explicitam a dificuldade em lidar com o tema está em torno de um dilema muito comum a respeito do que se deve priorizar. A dúvida sempre recai entre a eficiência da operação e a disponibilidade dos produtos e, por isso, essa discussão é um bom ponto de partida para a escolha de um modelo.

5.1.1 TRADE-OFF CUSTO DE ESTOQUE X RESPONSABILIDADE

Chopra e Meindl (2004) alertam para o fato de que estoque é o principal fator gerador de custos de uma cadeia de suprimento, porém, ao mesmo tempo, a sua existência também exerce um forte impacto na responsividade da mesma.

Obviamente, a busca por um excelente nível de serviço tem seu preço. Ter uma elevada disponibilidade de produtos significa se sujeitar a grandes níveis de estoque e, conseqüentemente, a trabalhar com custos de manutenção da armazenagem bastante altos. Dessa maneira, a lógica diz que quanto maior for a responsividade procurada, maiores são os custos de estoques envolvidos em uma cadeia. Vale ressaltar que estes últimos, a partir de certo ponto, crescem de maneira exponencial já que a responsividade possui a demanda como limite superior e, portanto, não pode ser infinita. A Figura 5.1 mostra bem essa situação.




Figura 5.1 – Curva de custo de estoque em relação à responsividade

FONTE: Adaptado de Chopra e Meindl (2004).

Diante desses fatos a gestão de estoque deve procurar balancear e identificar o ponto onde o potencial de lucro do procedimento seja maximizado, isto é, onde a receita adicionada do custo de falta que deixa de ser incorrido, compense o aumento do custo de estoque proporcionado pela maior responsividade.

O antagonismo de comportamentos entre essas duas características ressalta a importância de sempre se procurar o alinhamento estratégico entre os diversos componentes da cadeia de suprimentos. Para que tal alinhamento possa ser alcançado deve-se almejar que todas as atividades desempenhadas pela cadeia estejam de acordo com as necessidades dos clientes. Assim, o grau de responsividade definido para o conjunto deve ser coerente com a incerteza implícita que a demanda de um determinado item possui (CHOPRA; MEINDL, 2004).

Portanto, para obter um alto nível de desempenho, Chopra e Meindl (2004) afirmam que as empresas devem conduzir sua estratégia competitiva (e a incerteza implícita da demanda resultante) e sua estratégia de cadeia de suprimento (e a responsividade resultante) em direção à zona de alinhamento estratégico.




Figura 5.2 – Alinhamento estratégico mediante os níveis de responsividade e incerteza da demanda

FONTE: Chopra e Meindl (2004).

Logo, conclui-se que para realizar o alinhamento estratégico as empresas devem seguir a lógica de que quanto maior for a incerteza da demanda, mais responsiva deve ser a cadeia; e, em contrapartida, quando maior a certeza da demanda, mais eficiente deve ser a cadeia.

Esclarecido o dilema de prioridades, é válida a apresentação dos diversos modelos de gestão que os estoques podem se sujeitar. Vejamos abaixo.

5.1.2 MODELOS DE ESTOQUES

Antes de iniciar a apresentação dos variados modelos de gestão de estoques existentes na literatura é válido esquematizar quais são as verdadeiras etapas de um processo de abastecimento dos estoques.

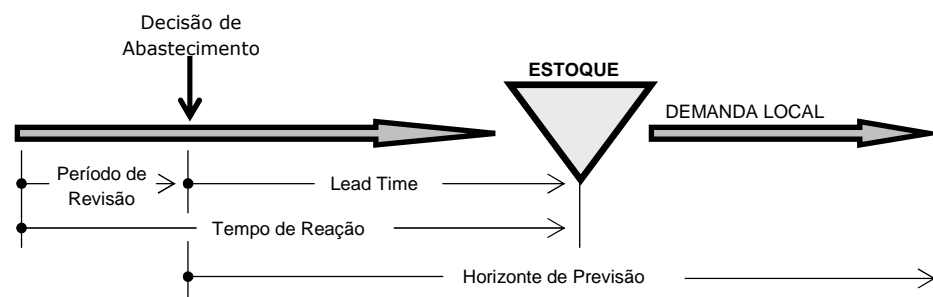


Figura 5.3 – Processo de abastecimento de estoques

FONTE: Adaptado de Santoro (2009).

Levando em consideração as definições temporais explicitadas na Figura 5.3, iniciamos agora a apresentação dos principais modelos de gestão de estoques que se classificam basicamente em dois tipos: os modelos ativos (com utilização da previsão de demanda) e os modelos reativos (sem utilização da previsão de demanda).

➤ **MODELOS REATIVOS**

Nesses modelos, os estoques são gerenciados de maneira respondente (ou reativa) às vendas de determinado bem, isto é, os estoques somente são abastecidos conforme as vendas vão acontecendo e alguma informação alerta para a necessidade de ações serem tomadas. Nesse método nenhuma técnica de previsão de demanda é utilizada diretamente para a tomada de decisões. Na verdade as decisões advêm da análise dos níveis de estoques em comparação a parâmetros, informações de nível de pedido e/ou estoques máximos.

A operação desses casos pode se dar, principalmente, de três maneiras distintas conforme é mostrado a seguir.

Reposição do Máximo Periódico

Trata-se de um modelo cujo procedimento de decisão quanto à ordem de compra se dá no final de cada período. Nesse caso é realizada uma comparação entre o estoque disponível a curto prazo (estoque físico mais o “a receber”) e o valor do ponto de pedido. Se o valor do primeiro for superior ao do segundo nada se faz, entretanto, se for inferior é realizado um pedido para a reposição máxima do estoque.

$$\text{Ordem de Compra} = \begin{cases} (\text{EstMáx} - \text{EstDispCP}) & \text{se } \text{EstDispCP} < \text{PtoPed} \\ 0 & \text{se } \text{EstDispCP} > \text{PtoPed} \end{cases}$$

Onde, EstMáx = estoque máximo

EstDispCP = estoque disponível a curto prazo (estoque físico + estoque “a receber”)

PtoPed = ponto de pedido

Santoro (2009) ressalta para o fato de que o estoque máximo (EstMáx) é um parâmetro do modelo e só pode ser fisicamente atingido se nenhuma venda acontecer durante todo o período de espera (*lead time*) da encomenda.

Reposição da Base Contínuo

Trata-se de um modelo cujo procedimento de decisão se dá após cada retirada do estoque efetuando-se uma ordem de pedido igual à diferença entre o estoque máximo e o estoque disponível a curto prazo. Para o caso de se existir uma Necessidade Líquida Mínima – que nada mais é do que um lote mínimo de pedido – a ordem só deve ser realizada se a diferença citada for superior a ela.

$$Ordem\ de\ Compra = \begin{cases} (EstMáx - EstDispCP) & \text{se não existe } NLíqMín \\ (EstMáx - EstDispCP) & \text{se } (EstMáx - EstDispCP) > NLíqMín \\ 0 & \text{se } (EstMáx - EstDispCP) < NLíqMín \end{cases}$$

Onde, $NLíqMín$ = necessidade líquida mínima

Pode-se notar que para os casos de inexistência da $NLíqMín$, o estoque máximo é tido como o ponto de pedido e, por isso, qualquer que seja a saída do estoque é emitido uma ordem para sua total reposição.

Lote Fixo Contínuo

Trata-se de um modelo cujo procedimento de decisão quanto à ordem de compra se dá após a cada retirada do estoque. Nesses casos é realizada uma comparação entre o estoque disponível a curto prazo e o valor do ponto de pedido definido. Se o valor do primeiro for superior ao do segundo nada se faz, entretanto, se for inferior é realizado um pedido de n lotes de tamanhos já fixados.

$$Ordem\ de\ Compra = \begin{cases} n \cdot LotFix & \text{se } EstDispCP < PtoPed \\ 0 & \text{se } EstDispCP > PtoPed \end{cases}$$

Onde, n = número inteiro mínimo que garante após a compra que $EstDispCP \geq PtoPed$
 $LotFix$ = lote fixo

Santoro (2009) ressalta que este método também pode ser chamado de Modelo do Lote Econômico quando o lote fixo em questão é calculado otimizando-se uma determinada função de custos.

➤ MODELOS ATIVOS

Nesses modelos, os estoques são gerenciados de maneira a antecipar as vendas de determinado bem, ou seja, utilizam-se da previsão de demanda para as suas tomadas de decisões quanto ao abastecimento dos estoques.

Cálculo das Necessidades

Trata-se de um modelo cujo procedimento de decisão quanto à ordem de compra se dá no final de cada período. Nesse caso avalia-se se qual a situação da Necessidade Líquida de pedidos apurada na data t e com previsão para chegar após o *lead time* de abastecimento. Essa $NLíq$ é calculada considerando a demanda prevista no tempo de reação, menos o estoque disponível a curto prazo (estoque físico mais o “a receber”), mais o estoque de segurança. Se a quantidade obtida nesse cálculo for positiva, deve-se fazer um pedido de igual valor. Caso seja menor ou igual a zero, nada se faz.

$$NLíq_{t,t+LT} = \sum_{i=1}^{TRe} preDem_{t,t+i} - \sum OCompra_{t+i-LT,t+i} - EstFís + EstSeg$$

$$Ordem\ de\ Compra_{t,t+LT} = \begin{cases} NLíq_{t,t+LT} & se\ NLíq_{t,t+LT} > 0 \\ 0 & se\ NLíq_{t,t+LT} \leq 0 \end{cases}$$

Onde, LT = lead time

TRe = tempo de reação

$NLíq_{t,p}$ = necessidade líquida em t a ser entregue no período p adiante

$PreDem_{t,p}$ = previsão de demanda feita em t , referente ao período p adiante

$OCompra_{t,p}$ = quantidade a comprar decidida em t a ser entregue no período p adiante

EstFís = estoque físico

EstSeg = estoque de segurança

Vale ressaltar que para o caso de se existir uma Necessidade Líquida Mínima, o valor da ordem de compra é igual a $NLíq$, se $NLíq > NLíqMín$; caso contrário, a ordem de pedido é igual a $NLíqMín$.

Santoro (2009) ressalta para o fato de que em modelos ativos, o cálculo das ordens de compras não leva em conta os custos de preparação, podendo assim, serem gerados pedidos muito pequenos e, conseqüentemente, com elevados custos de aquisição. Portanto, para minimizar esse problema regras de formação de lotes devem ser formuladas.

Apresentados todos os principais modelos de gestão de estoques, a Tabela 5.1 foi elaborada com a finalidade de fazer uma comparação resumida entre eles, principalmente quanto ao âmbito de quais são as variáveis necessárias para a aplicação de cada um deles.

Tabela 5.1 – Principais modelos de gestão de estoques

FONTE: Santoro (2009).

MODELOS VARIÁVEIS	REATIVOS			ATIVO
	PER	CONT		PER
	Reposição do Máximo	Reposição da Base	Lote Fixo	Cálculo das Necessidades
Período de Revisão	X			X
Lead Time	X	X	X	X
Ponto de Pedido	X		X	
Estoque Máximo	X	X		
Lote Fixo			X	
Estoque Segurança	*	*	*	X

* Estoque de Segurança contido implicitamente em outros parâmetros

Nesse momento é válido destacar que o autor desse trabalho acredita que o gerenciamento de estoques com base em modelos ativos é a melhor alternativa dentre as apresentadas e a que possibilita, com maior facilidade, o encontro do equilíbrio entre responsividade e eficiência. Devido a essa consideração, será percebido ao longo desse trabalho que a solução desenvolvida e apresentada mais adiante é bastante propícia para a implementação dessa forma de gerenciamento na cadeia de suprimentos analisada.

➤ ESTOQUE DE SEGURANÇA

Como o próprio nome sugere trata-se da quantidade de itens que deve ser mantida em estoque para assegurar a disponibilidade de produtos ao consumidor, ou seja, sua função é garantir o nível de atendimento desejado dada a condição de existência de variabilidade de oferta e/ou de demanda. A variabilidade do lado da oferta é ocasionada por desvios de previsão de abastecimento. Já do lado da demanda, é ocasionada devido às variações de demanda, em casos de modelos reativos; ou, aos desvios de previsão de demanda, em casos de modelos ativos (SANTORO, 2009).

Assim sendo, pode-se dizer que o tamanho de um estoque de segurança é função de três fatores principais: nível de atendimento desejado ou falta permitida, previsibilidade ou variabilidade do abastecimento, e, previsibilidade ou variabilidade das vendas.

O nível de atendimento geralmente é definido com base nas características do item que está se vendendo e de seu mercado (tipo de cliente, concorrência, etc.). As variabilidades de ofertas geralmente estão relacionadas a atrasos de fornecimento ou entregas com itens de boa qualidade inferiores ao esperado. Por fim, as variabilidades de demanda comumente estão vinculadas a excedentes de vendas em relação ao padrão médio ou a desvios superiores das vendas em relação às previsões de demanda.

5.2 PLANEJAMENTO, PREVISÃO E REABASTECIMENTO COLABORATIVOS

O CPFR (*Collaborative Planning, Forecasting and Replenishment*) é uma prática de gestão que combina a inteligência e o conhecimento dos parceiros de negócio no planejamento e atendimento da demanda. O CPFR combina as melhores práticas de vendas e marketing com os processos de planejamento e execução de *supply chain* para aumentar a disponibilidade de produtos nos pontos de vendas e, simultaneamente, reduzir custos com estoques, transportes e logística (VICS ASSOCIATION, 2004).

Essa prática procura disseminar o comportamento de colaboração mútua entre os participantes de uma cadeia de suprimentos, visando o estabelecimento de um trabalho coordenado no âmbito de planejamento, previsão de demanda e reabastecimento, através da co-gestão de processos e, principalmente, do compartilhamento de informações.

Carvalho e Dias (2000) definem o CPFR como um programa que pretende, precisamente, preencher os *gaps* do ECR (*Efficient Consumer Response*), mas, simultaneamente, enfatizar os pontos relevantes deste último e construir algo mais voltado para a demanda. Incidindo no elemento-chave da cadeia – o consumidor final – o CPFR torna-se mais realista e vantajoso que o ECR, que é geralmente voltado para o fornecimento, buscando agilizar as empresas e reduzir custos, mas como poucos benefícios realmente percebidos pelo cliente (CARVALHO; DIAS, 2000).

Com o CPFR, prega-se que, através da integração dos processos de demanda e fornecimento, melhorias palpáveis são experimentadas pelas empresas no que se diz respeito à eficiência, crescimento das vendas e redução de estoques para toda a cadeia, sem contudo, deixar de satisfazer as necessidades do consumidor final. Por meio da troca de informações entre parceiros, busca-se garantir de maneira eficiente, a presença do produto certo, na hora certa e no local correto.

Levando em conta as informações apresentadas, VICS Association (2004) destaca alguns dos principais benefícios, trazidos pela implementação do CPFR. Dentre eles estão:

- Redução dos custos variáveis, onde o excedente pode passar a ser investido em marketing e no desenvolvimento de novos produtos.
- Redução dos custos fixos e despesas com infraestrutura, vinculada à diminuição dos níveis de estoque da cadeia de distribuição.
- Redução de despesas operacionais.
- Aumento do nível de serviço e crescimento progressivo das vendas, consistentemente com as expectativas de acionistas.

Tendo em vista a relevância da questão de vontade de consumo e fornecimento, a previsão da demanda torna-se um ponto muito relevante dentro do CPFR. Nesse contexto, é válido aqui destacar que há dois principais tipos de abastecimento colaborativo: o *Retailer Managed Release* (RMR) e o *Vendor Managed Release* (VMR).

O RMR, como o próprio nome sugere, tem um pouco mais da gestão guiada pelo varejista., que deve compartilhar com o fornecedor informações “prontas” de previsões de demanda, plano de pedidos e realização de eventos, para que o mesmo programe sua produção e saiba os volumes de produtos que serão necessários para o abastecimento de cada loja.

Já o VMR tem a gestão mais centrada no fornecedor. Nesse caso, o varejista disponibiliza, através de uma rede de comunicação, informações de históricos de vendas, níveis de estoques, eventos planejados, entre muitas outras. Em posse de tais dados, o fornecedor é responsável por organizar o abastecimento das lojas, gerenciando adequadamente os níveis de estoque das mesmas. Obviamente, a participação do varejista não é vetada nesse processo decisório. No VMR, fornecedores e varejistas planejam juntos a realização de ações e eventos e propõem, conforme necessário, mudança nos parâmetros de abastecimento para melhorar a colaboração.

5.3 PREVISÃO DE DEMANDA

Trata-se de um tema importantíssimo para a fundamentação desse trabalho e, por isso, é merecedor de uma abordagem conceitual bastante completa. Os motivos de uso, as etapas de aplicação e a apresentação/equacionamento dos modelos mais relevantes são alguns dos principais pontos encontrados na literatura e, portanto, detalhados a seguir.

5.2.1 POR QUÊ PREVER ?

No mundo empresaria atual, a comum existência de um *lead time* entre a consciência de um evento e a ocorrência do mesmo, é a principal razão para a necessidade de planejamento e previsão (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998). Quanto mais uma empresa souber usar esse *lead time* a seu favor, maiores serão as chances de ações apropriadas serem tomadas em tempo hábil.

Complementando tal definição, O'Donovan (1983) diz que a gestão de uma organização está sujeita a frequentes tomadas de decisões e, assim sendo, o objetivo da previsão é justamente reduzir o risco implícito do ato de decidir, através de uma antecipação eficaz dos valores futuros de variáveis importantes.

De forma semelhante, Santoro (2009) afirma que a previsão não é uma decisão em si, mas sim, uma informação fundamental para quem quer planejar e decidir bem. De acordo com o autor, existe previsão sem planejamento, entretanto, não existe nenhum planejamento sem previsão.

Nesse contexto a necessidade constante das organizações tomarem decisões vem do fato de que existem muitos eventos internos e externos às mesmas que dão dinamicidade ao fluxo de ações que devem ser efetuadas. Apesar do sucesso de uma companhia depender de ambos os tipos de eventos, é válido ressaltar que a previsão aplica-se a apenas elementos afetados por eventos externos – ditos, também, incontroláveis – e não, por eventos internos – ditos, também, controláveis (SANTORO, 2009).

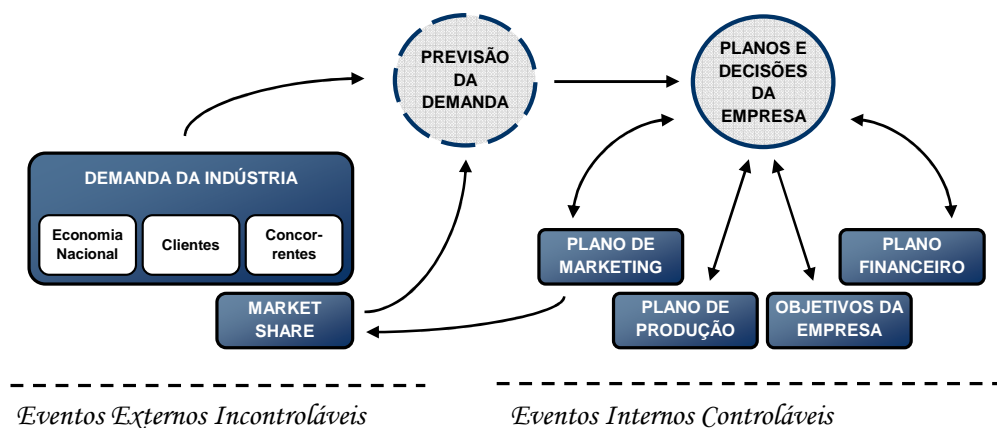


Figura 5.4 – Fluxo de informação da previsão de demanda e planejamento dos negócios

FONTE: Adaptado de Makridakis, Wheelwright e Hyndman (1998).

Cada vez mais as empresas tentam inibir o “acaso” e, por isso, trabalhar com a previsão possibilita a elas um comportamento mais racional e lógico dentro do ambiente em que estão inseridas. Assim sendo, percebe-se o quanto a previsão da demanda é uma ferramenta fundamental que alimenta com informações relevantes a gestão de uma organização, auxiliando-a nos seus processos de planejamento e tomadas de decisão.

Entretanto, o ato de prever não é uma atividade padronizada que pode ser aplicada da mesma maneira em toda e qualquer situação. Diferentes casos apresentam *lead times* particulares para se trabalhar uma decisão e, portanto, cada necessidade exige horizontes de previsão distintos. Makridakis, Wheelwright e Hyndman (1998) define os principais casos de utilização da previsão vinculando-os aos seus mais frequentes horizontes de tempo:

- *Curto Prazo*: Programação dos recursos da empresa – o uso eficiente dos recursos de uma organização requer a programação da produção, do transporte, do fluxo de caixa, das pessoas, entre outros.
- *Médio Prazo*: Aquisições de novos recursos – o *lead time* para a aquisição da matéria-prima, para a contratação de recursos humanos ou para a compra de maquinários e equipamentos pode variar de poucos dias a muitos anos. A previsão é necessária para otimizar esse intervalo de decisão para aquisições futuras.
- *Longo Prazo*: Determinar a necessidade de recursos – todas as organizações devem decidir que recursos elas vão querer ter em longo prazo e, por isso, necessitam programar investimentos para que possam prosperar. Para tais determinações é imprescindível a existência de uma boa previsão e de gerentes que saibam interpretá-la tomando as decisões apropriadas.

Tendo em vista todo o conteúdo abordado até o momento, percebe-se o quanto a previsão é um instrumento necessário nas atividades de uma organização. Apesar dessa importância, Corrêa (2009) adverte que é bastante comum as empresas cometerem erros quanto ao tema. O autor destaca que frequentemente as organizações confundem os conceitos de previsão com o de meta e acabam considerando as metas como se fossem previsões. Diante desse fato, é relevante explicitar tal diferenciação. Previsões são especulações do comportamento futuro do mercado demandante, enquanto que metas são as parcelas dessa demanda que a empresa deseja atender (CORRÊA, 2009). Portanto, é muito importante que esses conceitos fiquem claros nas companhias para que o planejamento e as decisões possam ser efetivamente bem realizados.

5.2.2 TIPOS DE PREVISÃO

Para lidar com tantas situações diferentes, até o dia de hoje muitas técnicas já foram desenvolvidas para a realização da previsão. Entretanto, os modelos de previsão da demanda podem ser geralmente categorizados em apenas dois principais tipos: métodos qualitativos e métodos quantitativos.

Métodos Qualitativos

Makridakis, Wheelwright e Hyndman (1998) definem os modelos qualitativos como sendo aqueles que apresentam pouca ou nenhuma informação quantitativa disponível, mas sobre o qual existem conhecimentos qualitativos suficientes.

Santoro (2009) nomeia tais métodos como métodos de *Predição*, os descrevendo como sendo modelos aplicados aos casos em que o futuro não guarda relação clara com o passado e, portanto, não pode ser determinado com base no mesmo. Dessa forma, as previsões são obtidas não por meios matemáticos, mas sim, através do julgamento de especialistas e da análise de conhecimentos acumulados.

São exemplos de métodos qualitativos: pesquisa de mercado, consenso da força de vendas, painel de especialistas, elaboração de cenários, entre outros.

Métodos Quantitativos

Makridakis, Wheelwright e Hyndman (1998) definem esses modelos como sendo aqueles que apresentam informação quantitativa suficiente à disposição e os classificam em dois grupos: métodos de *Projeção* (ou *Séries Temporais*) e métodos de *Explicação* (ou *Causais*).

Os modelos de séries temporais são aqueles que preveem a continuação de padrões históricos, isto é, são aqueles que assumem que o padrão futuro será uma reprodução do padrão passado. Dessa maneira, os dados históricos são colhidos, analisados e projetados para a obtenção dos seus comportamentos no futuro. São exemplos de modelo de projeção: média simples, média móvel, suavizações exponenciais, decomposição, entre outros.

Já os modelos de explicação são aqueles que buscam entender como algumas variáveis afetam a demanda. Admite-se aqui, também, a relação de dependência entre o passado e o futuro, porém, o foco desses modelos é entender o porquê da demanda para, assim, melhor prevê-la. São exemplos de modelo de explicação: regressões, modelos econométricos, entre outros.

5.2.3 ETAPAS PARA APLICAÇÃO DA PREVISÃO

Makridakis, Wheelwright e Hyndman (1998) apresentam cinco etapas básicas que devem ser seguidas para a aplicação de qualquer modelo quantitativo de previsão de demanda. Tal premissa será utilizada como base para a realização deste trabalho e, por isso, essas etapas serão descritas abaixo.

Etapa 1: Definição do Problema

Essa fase consiste no entendimento profundo de todo o cenário onde os *gaps* foram identificados. Nela procura-se levantar informações suficientes para se avaliar como o modelo de previsão poderia ser utilizado; como ele se encaixaria dentro da estrutura da organização; a quem ele seria destinado; e, se realmente seria uma ferramenta de agregação para a empresa, ou não. Trata-se de uma das fases mais difíceis no âmbito da previsão.

Além disso tudo, nessa etapa devem ser definidas algumas variáveis importantes como, por exemplo, o horizonte de previsão com o intuito de se direcionar quais são as informações que precisam realmente ser levantadas

Etapa 2: Coleta de Informações

Nessa fase há a necessidade de colher-se todas as informações relevantes para serem utilizadas no modelo escolhido. Há pelo menos dois tipos de dados disponíveis que devem ser impreterivelmente levantados: dados estatísticos históricos (geralmente numéricos); e, informações baseadas em julgamentos de pessoas-chave com experiências acumuladas.

Etapa 3: Análise Preliminar dos Dados

Essa etapa consiste na análise inicial de todas as informações levantadas na fase anterior para se ter um maior conhecimento sobre elas. A idéia é promover a realização de uma cuidadosa análise visual dos dados por meio de gráfico; obter médias, desvios padrão, máximos e mínimos; diagnosticar a presença de padrões, tendências, sazonalidades, ciclos e *outliers* (pontos extremos); analisar as informações dos especialistas; etc.

Essa análise preliminar ajuda a sugerir uma classe de métodos quantitativos que podem ser úteis para a definição do modelo de previsão.

Etapa 4: Escolha do Modelo e Determinação dos Parâmetros

Escolhidos os possíveis modelos que poderão ser utilizados, os mesmos são testados para que, no final, um deles possa ser escolhido com base nos resultados apresentados.

Normalmente, para se avaliar a acurácia de um modelo, medidas de erros de previsão são utilizadas. Entretanto, se essa avaliação fosse realizada considerando a data presente do estudo, a comparação dos valores previstos com os valores reais só poderia ser realizada depois de alguns períodos. Para contornar essa resposta não imediata, é importante adotar-se um procedimento de definição de três diferentes períodos: o período de inicialização, que se refere ao intervalo de tempo de onde são colhidas as informações históricas; o período de validação, que se refere ao intervalo de tempo onde são realizadas projeções para a comparação com os dados reais já obtidos; e, o período de projeção, que é o período onde o modelo irá realizar a previsão ainda a ser comparada.




Figura 5.5 – Definição dos períodos de previsão

FONTE: Adaptado de Santoro (2009).

Etapa 5: Uso e Avaliação do Modelo Escolhido

Tendo escolhido o modelo ele está pronto para realizar previsões, devendo o mesmo ser testado e validado por todos os seus usuários conforme a sua utilização. É relevante ressaltar que nenhum modelo estará totalmente aprovado enquanto só tiver sido testado no período de validação, ou seja, sua performance só será propriamente comprovada quando o modelo realizar previsões aceitáveis de períodos futuros (projeção).

Tendo explicitado as principais etapas de elaboração, escolha e aplicação de um modelo de previsão, demonstra-se no próximo item o como avaliar a precisão e adequação dos mais diversos casos escolhidos para testes e, na sequência, serão apresentados os principais métodos utilizados pela literatura para a previsão de demanda.

5.2.4 ACURÁCIA DA PREVISÃO

Em previsão de demanda a medição da acurácia dos modelos passíveis de utilização é um fator extremamente importante no diagnóstico de adequação dos mesmos, isto é, é fundamental se identificar o quanto cada um deles está apto, ou não, a reproduzir os dados que já são conhecidos. Tal medição é realizada por meio de indicadores de desempenho que, muitas vezes, também são utilizados para a comparação entre os modelos.

Os indicadores mais utilizados nesse procedimento são, geralmente, baseados em erros de previsão. Estes, por sua vez, nada mais são do que a diferença entre o valor real observado e o valor previsto para um mesmo período de tempo.

$$e_t = Y_t - F_t \quad (5.1)$$

Onde, Y_t = valor real observado no período de tempo t
 F_t = valor previsto para o período de tempo t

A equação (5.1) define o erro de previsão para um único período de tempo. Como no processo de validação de um modelo, normalmente, são considerados n períodos de tempo, é importante definir os principais indicadores de desempenho que os levem todos em conta. Assim, apresentar-se-ão abaixo as medidas que mais se destacam nesse processo de medição da precisão. Vale comentar que para todas elas, quanto menor for valor do indicador, melhor é a previsão.

Erro Médio (ME)

O ME (*Mean Error*) nada mais é do que a média aritmética de todos os n erros de previsão envolvidos em um modelo. O grande problema associado ao uso do ME é que o mesmo está sujeito a apresentar um valor mais baixo já que valores positivos e negativos de erros podem se anular. Ou seja, esse indicador pode sugerir uma precisão que não corresponde com a realidade.

$$ME = \frac{1}{n} \cdot \sum_{t=1}^n e_t \quad (5.2)$$

Onde, n = número de períodos considerados

Erro Absoluto Médio (MAE)

O MAE (*Mean Absolute Error*) busca suprimir o problema encontrado no ME transformando primeiramente todos os erros em números positivos e, só em seguida, calculando a média dos resultados. Esse indicador tem a vantagem de ser mais compreensível e melhor interpretar os resultados.

$$MAE = \frac{1}{n} \cdot \sum_{t=1}^n |e_t| \quad (5.3)$$

Erro Quadrático Médio (MSE)

O MSE (*Mean Squared Error*) segue a mesma idéia do MAE, porém, nesse caso, os erros são transformados em números positivos não com a utilização de seus módulos, mas sim, com elevação ao quadrado. Manusear matematicamente esse indicador é mais fácil que os demais apresentados e, por isso, ele acaba sendo bastante utilizado em otimizações estatísticas.

$$MSE = \frac{1}{n} \cdot \sum_{t=1}^n e_t^2 \quad (5.4)$$

Apresentados esses três primeiros indicadores é importante ressaltar que a interpretação do valor dado por cada um deles é totalmente dependente do tamanho da escala dos dados levantados. Portanto, um mesmo valor de MAE, por exemplo, em duas medições distintas, podem significar precisões completamente antagônicas. Dessa maneira, esses indicadores não são totalmente confiáveis para a comparação de diferentes séries temporais, ou ainda, de diferentes intervalos de tempo.

Para contornar essa situação e viabilizar tais comparações, aconselha-se o uso de indicadores de desempenho que utilizem erros percentuais de previsão em suas medidas e, não, erros absolutos como ocorre com os indicadores anteriores. Os erros percentuais podem ser definidos conforme a equação (5.5).

$$PE = \left(\frac{Y_t - F_t}{Y_t} \right) \cdot 100 \quad (5.5)$$

Onde, Y_t = valor real observado no período de tempo t
 F_t = valor previsto para o período de tempo t

Os principais indicadores com essas características são apresentados a seguir.

Erro Percentual Médio (MPE)

O MPE (*Mean Percentage Error*) nada mais é do que a média aritmética de todos os n erros percentuais de previsão envolvidos no modelo. Assim como ocorre com o ME, o grande problema do MPE é o fato dele considerar porcentagens positivas e negativas, tornando-se sujeito a distorcer o valor final após a realização das somas.

$$MPE = \frac{1}{n} \cdot \sum_{t=1}^n PE_t \quad (5.6)$$

Erro Absoluto Percentual Médio (MAPE)

O MAPE (*Mean Absolute Percentage Error*) busca contornar o problema de distorção que pode ser encontrado no MPE, transformando todos os erros percentuais em números positivos antes da realização da média.

$$MAPE = \frac{1}{n} \cdot \sum_{t=1}^n |PE_t| \quad (5.7)$$

É válido ressaltar que nenhum dos dois indicadores percentuais acima pode ser calculado caso existam valores reais nulos na série de estudo. De forma semelhante, para valores reais muito pequenos, as medidas de erro também perdem o sentido.

Erro Absoluto Percentual Médio Ponderado (WMAPE)

O WMAPE (*Weighted Mean Absolute Percentage Error*) nada mais é do que um indicador que busca contornar os problemas de invalidez da medição para valores reais muito pequenos ou nulos.

$$WMAPE = \frac{\sum_{t=1}^n |Y_t - F_t|}{\sum_{t=1}^n Y_t} \quad (5.8)$$

Apresentados esses indicadores é interessante citar que todos eles são formas de medição da amplitude (ou “tamanho”) dos erros e os riscos que ela incorre. Porém, segundo Corrêa (2009) além da amplitude, um outro acompanhamento é importante de ser realizado em uma previsão: o chamado viés dos erros. A análise deste tem a finalidade de identificar a presença de erros sistemáticos no modelo, para assim, atuar-se para melhorá-lo.

Sinal de Rastreabilidade (TS)

O TS (*Tracking Signal*) é um dos principais indicadores utilizados para acompanhar as possíveis ocorrências de viés de previsão. Ele é calculado em todos os períodos do modelo através da divisão da soma acumulada das diferenças entre os valores de previsão e os valores reais observados, pela média da soma acumulada do módulo das mesmas diferenças.

$$TS = \frac{\sum_{t=1}^n (F_t - Y_t)}{\sum_{t=1}^n \frac{|F_t - Y_t|}{n}} \quad (5.9)$$

Esse indicador passa, então, a ser acompanhado para garantir que seu valor sempre seja encontrado entre o intervalo que varia de -4 a $+4$. Se em algum momento o TS exceder tais limites, deve-se iniciar uma investigação mais detalhada da questão, já que, estatisticamente, são grandes as chances de o modelo estar gerando previsões enviesadas.

5.2.5 MÉTODOS QUALITATIVOS

Conforme já abordado nesse capítulo, os métodos qualitativos de previsão são caracterizados por incorporar em suas análises fatores como julgamentos, experiências, opiniões e intuições, em geral, todos subjetivos. São especialmente úteis quando dados quantitativos precisos e completos são muito caros, inexistentes ou difíceis de serem obtidos (CORRÊA, 2009). Deve-se optar por eles, preferencialmente, em previsões de médio a longo prazo.

Segundo Makridakis, Wheelwright e Hyndman (1998) apesar desses métodos poderem ser utilizados separadamente em um processo de previsão da demanda, frequentemente eles são empregados em combinação com algum método quantitativo. De acordo com os autores modelos qualitativos são muito mais usados como um instrumento de suporte à decisão dos planejadores e um complemento à previsão quantitativa, do que como um método que fornecerá uma previsão numérica propriamente dita.

Hanke e Reitsch (1998) fazem uma observação bastante pertinente em sua obra ao destacar que, por mais “puro” que seja um método qualitativo de previsão ele ainda basear-se-á em dados históricos. Isso se deve ao simples fato das análises desses casos serem feitas por meio de julgamentos que, por sua vez, são formados, em grande parte das vezes, por manipulações mentais dos dados históricos já conhecidos.

Assim, a natureza não-científica de modelos desse tipo torna difícil a padronização, ou até mesmo, a validação de sua exatidão (BALLOU, 2003).

A seguir, uma breve descrição de cada um dos principais métodos é explicitada.

Pesquisa de Mercado

Esse é um modelo de avaliação do comportamento da demanda através do levantamento dos fatores mais relevantes que influenciam a preferência do consumidor. Geralmente tal pesquisa tem como principal ferramenta a aplicação direta de questionários e a realização de entrevistas corpo-a-corpo com uma amostra do possível mercado demandante.

Trata-se de um método que apresenta uma menor validade em termos de horizonte de previsão, gerando informações que podem se referir a apenas o curtíssimo prazo, já que se baseia na opinião do público comum, bastante instável, influenciável e nem sempre fiel a suas respostas. Além disso, devido às inúmeras variáveis envolvidas nesse procedimento, o método está mais suscetível a erros de orientação e interpretação das informações e, portanto, apresenta menor confiabilidade.

Por fim, devido à grande quantidade de dados necessários para a obtenção de resultados mais satisfatórios, a pesquisa de mercado pode demorar e ter um custo consideravelmente elevado.

Método Delphi

Trata-se de um modelo que busca o consenso de um grupo de especialistas a respeito do comportamento de determinada demanda sem que haja interação pessoal entre eles, buscando esquivá-los das influências mútua.

Dessa forma, um questionário é enviado a alguns especialistas previamente selecionados para que seja respondido individualmente e devolvido à equipe analista. De acordo com as respostas obtidas, o questionário é readaptado e enviado novamente aos mesmos respondentes. Recebidos de volta, passam por uma nova readaptação, iniciando mais uma vez o ciclo. Assim, uma série de questionários é enviada até se obter um consenso no qual a opinião de todos os especialistas tenha sido considerada.

Devido a essas interações que ocorrem nesse método, o tempo para a obtenção de um resultado pode ser bastante longo e, o custo, elevado. Entretanto, trata-se de uma forma de modelo qualitativo de previsão com boa precisão e que obtém dados sem viés algum.

Painel de Especialistas

Trata-se de um modelo qualitativo cuja idéia é a mesma pretendida no Método Delphi: buscar um grupo de especialistas para que trabalhem em grupo e possam obter um consenso que expresse uma boa projeção. A grande diferença desse método para o anterior é que, nesse caso, a comunicação entre os envolvidos ocorre direta e pessoalmente, ou seja, é realizada uma reunião (ou mais) para que possam ser discutidos todos os pontos relevantes e para que cada um expresse suas opiniões pessoais.

Por ser um modelo que necessita de menos iterações em seu procedimento, o custo e o tempo despendidos são sensivelmente menores que no método anterior. Entretanto, o resultado do painel pode ser influenciado pelas características e opiniões pessoais de alguns membros com maior liderança, maior poder persuasão ou, até mesmo, maior prestígio que os demais. Por esse motivo, pode ser considerado um modelo mais frágil.

Analogia Histórica

Trata-se de um modelo que busca identificar produtos que possuam dados históricos suficientes e sejam similares ao objeto de estudo para se realizar uma análise comparativa e poder gerar uma melhor estimativa. Costuma-se chamar esses itens com padrões semelhantes de “produtos-espelhos”.

Com o intuito de se obter o melhor resultado possível, normalmente, é realizado um levantamento prévio do grau de semelhança entre os produtos comparados e das possíveis causas que os levariam a apresentar diferentes comportamentos de demanda.

Por apoiar-se em uma base concreta de dados esse método apresenta uma precisão razoável de médio e longo prazo. Seus resultados podem demorar a sair, mas o custo envolvido é relativamente baixo.

Consenso da Força de Vendas

Esse é um modelo de previsão qualitativa que parte do princípio que a equipe de vendas é o setor de uma empresa que está mais próximo dos seus clientes e, portanto, apresenta conhecimento suficiente para estimar com melhor qualidade as necessidades, tendências e eventuais alterações comportamentais dos mesmos. Todas as opiniões são colhidas por meio de questionários aplicados às diferentes equipes, sendo realizadas as previsões com bases nas respostas obtidas.

A grande desvantagem desse método é o fato de, geralmente, as previsões realizadas se tornarem bases para as metas do setor comercial. Dessa forma, pode acontecer dos números finais serem intencionalmente subestimados para que, assim, as equipes possam atingi-los mais facilmente.

5.2.6 MÉTODOS QUANTITATIVOS

Conforme já abordado nesse capítulo, os métodos quantitativos são aqueles que tomam como base uma série histórica de dados sobre uma determinada variável, com o intuito de identificar padrões de comportamento que possam ser projetados para o futuro (CORRÊA, 2009).

Makridakis, Wheelwright e Hyndman (1998) afirmam que os modelos quantitativos só podem ser aplicados nas seguintes condições:

- Existência e disponibilidade de informações sobre o passado.
- Essas informações poderem ser numericamente quantificadas.
- Poder-se considerar a Hipótese da Continuidade, isto é, assumir-se que comportamentos passados irão continuar no futuro.

Partindo de tais premissas, os principais modelos quantitativos de previsão serão apresentados, nas seções que se seguem, de acordo com suas duas formas de classificação, também já citadas anteriormente.

➤ MÉTODOS DE PROJEÇÃO (OU SÉRIES TEMPORAIS)

Os métodos de projeção têm como principal objetivo descobrir padrões no comportamento de uma sequência histórica de dados, colhida em intervalos de tempos igualmente espaçados, e extrapolá-los para o futuro.

Esses modelos tratam seus casos de previsão do futuro como meras projeções do passado, isto é, consideram o tempo como sua única variável explicativa. Portanto, não há preocupação alguma em se tentar descobrir se existem ou, quais são, os fatores que afetam o comportamento dos dados envolvidos.

Sendo assim, Hanke e Reitsch (1998) definem tais métodos com técnicas estatísticas que se focam estritamente nos comportamentos, nas mudanças e nas oscilações dos dados ao longo da série temporal.

De acordo com Makridakis, Wheelwright e Hyndman (1998) os dados de séries temporais apresentam tradicionalmente quatro principais tipos de componentes: horizontalidade, sazonalidade, ciclicidade e tendência. Ballou (2003) completa essa lista com um quinto elemento: a aleatoriedade.

- *Horizontalidade*: trata-se de um padrão normalmente presente em produtos cujas as vendas não se alteram significativamente ao longo do tempo, isto é, os valores da demanda flutuam em torno de um valor dito “estacionário”.
- *Sazonalidade*: padrão que se destaca quando a demanda é influenciada por fatores sazonais como estações do ano, dias da semana, feriados, etc.
- *Ciclicidade*: trata-se de um padrão encontrado em demandas que apresentam crescimentos e quedas em períodos não fixados, típicos da sazonalidade. Tal comportamento se dá devido à influência de alguma variável como, por exemplo, flutuações econômicas.
- *Tendência*: padrão que se destaca quando há uma linha de crescimento ou queda da demanda ao longo do tempo.
- *Aleatoriedade*: trata-se de variações da série histórica de dados que não são provenientes de variáveis presentes no modelo de previsão.

É válido destacar que, geralmente, as séries temporais são compostas não só por um dos padrões acima citados, mas sim, por uma combinação deles.

Dada tal visão sobre o tema, serão apresentados a baixo os métodos de séries temporais mais relevantes.

Decomposição de Séries Temporais

Método que busca decompor a série temporal de forma a identificar o comportamento de cada componente separadamente. Geralmente, esse processo de decomposição visa explicitar dois padrões fundamentais já apresentados: a tendência e a sazonalidade.

Dessa forma, o método de decomposição assume que as séries temporais são compostas da seguinte maneira:

$$Demanda = Padrões + Erros = f(Tendência, Sazonalidade, Erros)$$

O objetivo do processo de decomposição é, principalmente, isolar cada componente da série temporal com a maior precisão possível. O conceito básico dessa separação é empírico e consiste em remover primeiramente a componente de tendência e, em seguida, isolar a sazonalidade da aleatoriedade (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998). Separados os componentes eles são analisados e projetados individualmente para posteriormente serem novamente compostos e fornecerem a previsão.

De maneira geral, há duas diferentes abordagens para a realização da decomposição: a decomposição aditiva e a multiplicativa.

A aditiva, como o próprio nome sugere, trata o valor da demanda como resultado da soma de todos os componentes acima citados. É o modelo mais apropriado quando a magnitude da sazonalidade não varia com o passar do tempo.

$$Y_t = T_t + S_t + E_t \quad (5.10)$$

Onde, Y_t = valor real observado no período de tempo t
 T_t = componente de tendência no período de tempo t
 S_t = componente de sazonalidade no período de tempo t
 E_t = componente de aleatoriedade (erro) no período de tempo t

Já a multiplicativa, como também o nome sugere, trata o valor da demanda como resultado da multiplicação dos mesmos componentes. Trata-se de um modelo mais apropriado quando a sazonalidade apresenta variações crescentes e decrescentes proporcionalmente ao nível de observação das séries.

$$Y_t = T_t \cdot S_t \cdot E_t \quad (5.11)$$

Apesar desse método ser apresentado por alguns como um modelo de previsão da demanda, Makridakis, Wheelwright e Hyndman (1998) defendem que a decomposição é mais uma ferramenta para entender determinada série temporal do que um método de previsão propriamente dito. Esse argumento provém do fato de que é bastante complexo projetar cada componente individualmente para depois uni-las. Dessa maneira, os autores indicam o uso do método como uma forma de análise preliminar dos dados históricos para auxiliar no processo de escolha e aplicação de um modelo de previsão.

Média Simples

É um modelo que calcula a previsão da demanda através da média aritmética de todos os valores passados até então observados. É o método mais simples de previsão e que, normalmente, só é utilizado para casos caracterizados por possuírem demandas horizontais fortemente estacionárias.

$$F_{t+1} = \frac{1}{t} \cdot \sum_{i=1}^t Y_i \quad (5.12)$$

Onde, F_{t+1} = previsão para o período seguinte ao período atual t

Como esse método considera todas as medições históricas para o cálculo da previsão, percebe-se que conforme o tempo passa e o número de dados disponíveis aumenta, mais constante o modelo se torna.

Média Móvel

Esse método consiste na realização da previsão através da média aritmética de uma quantidade fixa dos últimos valores observados na série. Recebe tal nome pois a cada novo dado disponível a média é recalculada substituindo o valor mais antigo que considerava por esse mais recente. Dessa maneira, o modelo procura basear suas previsões na idéia de que observações que estão mais próximas temporalmente tendem, também, a estarem mais próximas no que diz respeito aos seus valores.

$$F_{t+1} = \frac{1}{k} \cdot \sum_{i=t-k+1}^t Y_i \quad (5.13)$$

Onde, k = número de últimos valores/períodos que serão considerados no cálculo da média

A grande dificuldade desse método é definir corretamente qual é a quantidade de períodos k que deve ser considerada. Em geral, quanto menor for esse valor, maior será a rapidez de resposta às variações de comportamento da demanda.

Assim como na média simples, esse método não é indicado para casos de demanda que apresentem alguma tendência e/ou sazonalidade. Além disso, a média móvel não é utilizada com tanta frequência visto que os métodos de suavização exponencial são, geralmente, melhores e mais recomendados.

Suavização Exponencial Simples

Trata-se de um método que parte do mesmo princípio que a média móvel, isto é, também procura valorizar os valores mais recentes da série temporal. Apesar da similaridade, a suavização diferencia-se do modelo anterior por dar maior importância aos últimos dados através da ponderação exponencial dos mesmos de acordo com a proximidade ao período de previsão. Tal priorização ocorre com o uso da constante de ponderação α que deve satisfazer a condição de $0 < \alpha < 1$.

$$F_{t+1} = \alpha Y_t + (1 - \alpha) F_t \quad (5.14)$$

Onde, α = constante de ponderação exponencial

Essa equação nos mostra que o método da suavização exponencial reduz drasticamente o comum problema de armazenamento de dados que as empresas têm. Para a realização da previsão, não é preciso um grande histórico de informação, ou seja, apenas o dado mais recente, a última previsão realizada e um valor para α precisam ser utilizados.

A questão da ponderação dos valores históricos, pode ser melhor observada quando se abre a equação (5.14) substituindo o termo F_t e, em seguida, os termos subsequentes F_{t-1} , F_{t-2} , ..., conforme demonstrado abaixo.

$$F_{t+1} = \alpha Y_t + \alpha(1 - \alpha)Y_{t-1} + \alpha(1 - \alpha)^2 Y_{t-2} + \alpha(1 - \alpha)^3 Y_{t-3} + \dots + \alpha(1 - \alpha)^{t-1} Y_1 + (1 - \alpha)^t F_1 \quad (5.15)$$

Uma outra forma comum de expressar a equação (5.14) é:

$$F_{t+1} = F_t + \alpha(Y_t - F_t) \quad (5.16)$$

Percebe-se, portanto, que a idéia desse modelo é utilizar o valor de previsão definido para o período anterior e ajustá-lo de acordo com o erro observado. Em outras palavras, a próxima previsão é uma correção da anterior em direção oposta ao erro obtido na mesma.

Uma questão muito importante nesse método é saber definir um valor ótimo para α . Após inúmeros estudos, a literatura parece ter chegado a um consenso e recomenda que valores entre 0,05 e 0,35 sejam utilizados. Pela simplicidade do modelo, seu uso é mais recomendado para séries que não apresentam tendências e/ou sazonalidade.

Método de Holt - Suavização Exponencial com Tendência

Esse modelo foi criado com o intuito de se permitir a previsão da demanda para os casos em que os dados apresentam tendência (linear) de crescimento ou queda. O modelo anterior, se utilizado para esses casos, responderia às variações da demanda de forma muito mais lenta.

Para gerar a previsão, o método de Holt baseia-se na estimativa do nível (base) da série no período de tempo t e na estimativa do grau de inclinação da linha de tendência da mesma. Nesse modelo são utilizadas duas constantes de suavização: uma para o cálculo da base (α); e outra, para o cálculo da tendência (β). Ambas devem satisfazer a condição de $0 < \alpha, \beta < 1$.

$$L_t = \alpha Y_t + (1 - \alpha)(L_{t-1} + b_{t-1}) \quad (5.17)$$

$$b_t = \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1} \quad (5.18)$$

$$F_{t+m} = L_t + mb_t \quad (5.19)$$

Onde,
 L_t = nível da série no período t
 α = constante de ponderação exponencial para a base
 b_t = tendência da série no período t
 β = constante de ponderação para a tendência
 m = número de períodos a frente que se deseja prever

Os valores de α e β normalmente são escolhidos de forma que a combinação entre ambos minimize o valor do erro. Vale ressaltar que se a série em estudo estiver sujeita a grandes variações de tendência, um maior valor para o parâmetro β irá fornecer respostas mais imediatas e a acompanhará mais eficazmente. Para o caso de se apresentar pequenas variações, valores menores para β são mais indicados.

Suavização Exponencial com Sazonalidade

Diferente de tudo que foi apresentado até o momento, esse modelo permite a realização da previsão de demanda para os casos em que os dados da série apresentam comportamento com alguma sazonalidade.

Para gerar a previsão, o método baseia-se na estimativa do nível (base) da série no período de tempo t e na estimativa do índice de sazonalidade da mesma. Semelhantemente ao anterior, o modelo utiliza duas constantes de suavização: uma para o cálculo da base (α); e outra, para o cálculo da sazonalidade (γ). Ambas devem satisfazer a condição de $0 < \alpha, \gamma < 1$.

Assumindo como base de dados a sazonalidade multiplicativa (caso mais comum de ser encontrado), o modelo se alicerça nas seguintes equações:

$$L_t = \alpha \frac{Y_t}{S_{t-s}} + (1 - \alpha)L_{t-1} \quad (5.20)$$

$$S_t = \gamma \frac{Y_t}{L_t} + (1 - \gamma)S_{t-s} \quad (5.21)$$

$$F_{t+m} = L_t \cdot S_{t-s+m} \quad (5.22)$$

Onde, S_t = sazonalidade da série no período t
 γ = constante de ponderação para a sazonalidade
 s = comprimento da sazonalidade (i.e. número de meses ou trimestres no ano)

Da mesma maneira que nos casos anteriores, o parâmetro γ deve ser ajustado de forma que, junto a α , apresente o melhor resultado possível, isto é, de menor erro. Esse é um modelo que necessita de um maior número de dados para estimar o índice sazonalidade.

Método Holt-Winters – Suavização Exponencial com Tendência e Sazonalidade

Trata-se de um modelo que agrega os dois métodos anteriores, isto é, foi elaborado para a previsão da demanda de séries formada por dados que apresentam um comportamento com tendência linear e com sazonalidade, simultaneamente.

$$L_t = \alpha \frac{Y_t}{S_{t-s}} + (1 - \alpha)(L_{t-1} + b_{t-1}) \quad (5.23)$$

$$b_t = \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1} \quad (5.24)$$

$$S_t = \gamma \frac{Y_t}{L_t} + (1 - \gamma)S_{t-s} \quad (5.25)$$

$$F_{t+m} = (L_t + mb_t)S_{t-s+m} \quad (5.26)$$

Mais uma vez, os valores dos parâmetros α , β e γ devem ser obtidos de forma a otimizar o modelo, buscando a minimização dos erros.

➤ MÉTODOS DE EXPLICAÇÃO (OU CAUSAIS)

Os métodos de explicação têm como principal objetivo a busca pelo entendimento do porquê da demanda para, assim, poder realizar uma boa previsão. Diferentemente dos modelos de projeção, a previsão aqui não é necessariamente dependente do tempo, mas sim, uma função de determinados fatores que a influenciam. Dessa maneira, o foco dos modelos causais é investigar como e, em que grau, certas variáveis afetam o comportamento de uma demanda. A grande dificuldade, entretanto, é encontrar quais são essas variáveis explicativas e, por isso, esses métodos são considerados bastante sofisticados e necessitam de grande quantidade de dados disponíveis.

Atualmente, existem diferentes técnicas para esse tipo de previsão, entretanto, a ferramenta mais comumente utilizada em métodos de explicação é a análise de regressão e, por isso, esse trabalho se restringirá somente ao seu detalhamento.

Regressão Linear Simples

Esse método busca a explicação do comportamento da demanda através do relacionamento linear de uma variável Y a ser prevista, chamada dependente, com uma única variável X explicativa, denominada independente.

$$Y = a + bX + e \quad (5.27)$$

Hanke e Reitsch (1998) definem a linha de regressão simples como a reta que se ajusta de maneira a minimizar a soma das distâncias ao quadrado de todos os pontos em relação a ela mesma, na direção vertical. Nesse contexto, é preciso determinar os valores para a e b de maneira que a reta se ajuste da melhor maneira possível ao conjunto de dados estudados. Para tanto, o método dos mínimos quadrados pode ser utilizado.

Encontrados esses valores e, conseqüentemente, determinada a equação de regressão, os dados reais da variável dependente Y podem ser comparados aos valores obtidos a partir da reta “aproximada” traçada, denominada \hat{Y} . Dessa maneira, pode-se encontrar o grau de correlação R entre essas duas variáveis. Geralmente, em regressão, a correlação é utilizada na forma quadrática R^2 , passando a ser chamada de coeficiente de determinação. Este, por sua vez, é responsável por expressar percentualmente o quanto a variação de uma variável está relacionada com a variação da outra.

É interessante dizer que para regressão linear, a correlação entre Y e \hat{Y} é exatamente a mesma que a correlação entre Y e X , e pode ser expressa por:

$$R^2 = r_{Y\hat{Y}}^2 = r_{XY}^2 = \frac{\sum (\hat{Y}_i - \bar{Y})^2}{\sum (Y_i - \bar{Y})^2} \quad (5.28)$$

Onde, \bar{Y} = média dos valores de Y

Se ao calcular tal coeficiente verificar-se que R^2 apresenta um alto valor, há grandes chances da linha de regressão desenhada estar apropriada. Entretanto, isso não é o suficiente. Para o suporte de tal conclusão, Makridakis, Wheelwright e Hyndman (1998) sugerem o uso de ferramentas complementares, tais como: a análise do gráfico de resíduos *versus* a variável explicativa – que ao ser plotado não deve apresentar qualquer tipo de tendência – e, principalmente, a aplicação de testes estatísticos como o *teste-F*.

O *teste-F* é interessante de ser utilizado, pois ele permite a checagem da real existência de relação significativa entre as variáveis analisadas. Para os casos em que há forte relacionamento, espera-se que F apresente um valor elevado.

A partir de F obtém-se também o *valor-P*, que indica qual seria a probabilidade de obtenção do valor de F encontrado se a inclinação da reta (b) fosse zero. Assume-se que a regressão pode ser considerada relevante quando o *valor-P* é menor do que 0,05 (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998).

Regressão Linear Múltipla

Diferentemente da regressão simples, esse método busca a explicação do comportamento da demanda através do relacionamento linear da variável Y com duas ou mais (k) variáveis independentes.

$$Y = b_0 + b_1 X_{1,i} + b_2 X_{2,i} + \dots + b_k X_{k,i} + e_i \quad (5.29)$$

Dada a equação, de forma semelhante ao modelo anterior, é preciso se determinar os valores de todos os seus coeficientes b_k buscando que a reta de regressão se ajuste aos dados de modo a minimizar a soma dos erros ao quadrado. Novamente, para a efetuação de tal procedimento, o método dos mínimos quadrados pode ser utilizado.

Da mesma forma que na regressão linear simples, o grau de relacionamento entre a variável dependente e todas as k variáveis independentes ao mesmo tempo (e não uma a uma), pode ser mensurado por meio do coeficiente de determinação R^2 , do *teste-F* e do *valor-P*.

Para o bom funcionamento dos modelos de regressão múltipla associados a séries temporais, Makridakis, Wheelwright e Hyndman (1998) alertam para alguns pontos importantíssimos que devem ser considerados. Os principais são:

- Resíduos devem ser independentes entre si, sem a presença de multicolinearidade – situação na qual duas variáveis explicativas estão altamente correlacionadas.
- Resíduos devem apresentar distribuição normal.
- Se necessária a inclusão de dados mais qualitativos na análise de regressão múltipla, devem ser utilizadas variáveis binárias (*dummy variables*), que assumem os valores 1 ou 0 dependendo da ocorrência, ou não, da característica considerada.

Dadas as premissas acima, falta apenas saber como se escolher as variáveis que serão consideradas no modelo. Inicialmente, vem à cabeça que tal escolha pode ser feita analisando qual modelo apresenta o maior valor para R^2 . Entretanto, como esse coeficiente não considera os graus de liberdade da equação, esse critério determinaria como melhor modelo aquele que apresentasse o maior número de variáveis explicativas, dado que o R^2 necessariamente aumenta a cada variável adicionada à equação. Assim sendo, uma boa alternativa para tal situação é a análise do chamado *R^2 -ajustado*, equacionado abaixo.

$$\bar{R}^2 = 1 - (1 - R^2) \cdot \frac{n - 1}{n - k - 1} \quad (5.30)$$

Onde, n = número de observações
 k = número de variáveis explicativas do modelo

Existem alguns métodos computacionais que auxiliam nesse processo de testar os modelos com diversas combinações de variáveis, especificando aquele que apresenta o melhor valor de *R^2 -ajustado*. Entre eles, pode-se destacar o *best subset regression* e o *stepwise forward-with-a-backward-look*. No primeiro, são realizados testes com todas as combinações de variáveis possíveis, indicando no final, os modelos que apresentam maiores valores de *R^2 -ajustado*. Já no segundo, as variáveis candidatas ao modelo são adicionadas e removidas conforme critério determinado, de forma a se identificar a combinação mais adequada.

6. MODELAGEM DA PREVISÃO DE DEMANDA

Caracterizado o problema e o atual processo de venda / abastecimento dos produtos Unilever ao varejo, inicia-se aqui o traçado da solução proposta à cadeia, fundamentada nos principais conceitos teóricos publicados na literatura e explicitados no capítulo anterior.

Como já discutido nesse trabalho, a questão mais problemática encontrada no cenário estudado está em torno das inúmeras perdas incorridas ao fornecedor e ao varejista devido à indisponibilidade de produtos nas gôndolas das lojas. Muitas dessas ocorrências são justificadas por um erro de decisão de abastecimento ou, até mesmo, pela ineficiência do modelo atualmente em vigor. O dilema entre eficiência e responsividade pode ser apontado como uma das grandes causas dessas situações.

Tendo em vista essa realidade, será realizado a partir de agora, um estudo para o entendimento do comportamento da demanda do mercado em questão, visando a geração e o fornecimento de informações e conhecimentos mais precisos para que uma melhor decisão seja tomada. Com o uso desses novos artifícios, acredita-se que uma melhoria no modelo de abastecimento do varejo certamente será alcançada.

Antes de iniciar o desenvolvimento do modelo citado é necessário entender e especificar em que contexto do atual processo de planejamento da demanda ele estará incluído. Assim sendo, o item a seguir buscará determinar em qual etapa do planejamento esse modelo pretende atuar para que sua aplicação mantenha-se sempre alinhada com a resolução do problema diagnosticado.

6.1 CONTEXTUALIZAÇÃO NO PROCESSO DE PLANEJAMENTO

Como apresentado no Capítulo 3 o processo de planejamento da demanda na Unilever está todo relacionado à definição do *Annual Plan*, considerado o guia para a estratégia maior da companhia e a meta que deve ser atingida ao longo do ano a que ele se refere. Com o passar dos trimestres, o AP sofre algumas modificações e revisões que dão origem a um plano um pouco mais específico denominado *Annual Quarter Plan*. Este, por sua vez, ao ser mensalmente revisado dá origem ao plano de mais curto prazo da empresa: o *Operational Plan*.

É válido relembrar que nenhum desses planos é elaborado com o uso de modelos formais de previsão de demanda, sendo definidos com base no desempenho das vendas do ano anterior, nas tendências de mercado, no investimento disponível e no conhecimento dos envolvidos.

Trata-se, portanto, de uma definição mais qualitativa definida por meio da intuição e consenso dos executivos participantes de sua elaboração, sem uma abordagem quantitativa fornecida por algum método de previsão específico.

Assim sendo, a criação de um modelo mais formal de antecipação da demanda poderia ser adequado para a elaboração de qualquer um dos planos citados visando o aperfeiçoamento do sistema. Entretanto, por se tratarem de planos bastante diferentes entre si – inclusive quanto a hierarquia de planejamento – cada um desses casos exigiria o desenvolvimento de um método de previsão com abordagens e tratamentos de dados completamente distintos. Por esse motivo, uma dessas fases de planejamento teve de ser priorizada.

Como o foco desse trabalho é combater os problemas de indisponibilidade de produtos nas lojas do varejo e essa é uma questão que envolve o dia-a-dia dos pontos de venda, fica bastante evidente que um modelo que visualize o comportamento a curtíssimo prazo é o mais adequado para o caso. Por esse motivo, definiu-se que a criação do modelo deveria estar atrelada ao acompanhamento do OP onde, de certa forma, atuará para suprir o *gap* atualmente existente nessa etapa: a não existência de um período de replanejamento.

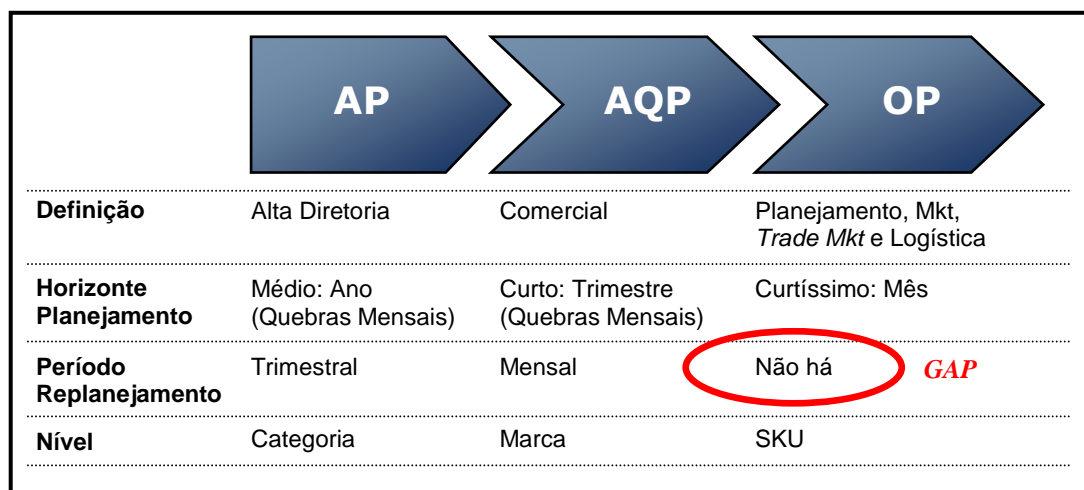


Figura 6.1 – *Gap* no acompanhamento do OP

Ter um método desenvolvido para antecipar a demanda do mês vigente das vendas permitirá, não só que o gerente da conta acompanhe de perto a performance da venda de suas marcas e tenha uma visão mais completa das principais oportunidades comerciais, mas também, que haja uma melhoria no abastecimento do varejo, já que será possível se adiantar ao comportamento da demanda e ter tempo hábil para agir antes da ocorrência da ruptura de algum item.

Estrutura do Modelo

Contextualizado onde o modelo atuará no processo de planejamento da demanda, é chegado o momento de destacar como se dará sua estrutura de previsão. Pelo fato dele estar sendo desenvolvido para a tomada de decisões em curtíssimo prazo, estipulou-se que o método trabalhará com uma base de dados diária.

Apesar disso, o modelo foi elaborado para poder fornecer um maior conhecimento da demanda e permitir que um melhor abastecimento do varejo seja realizado. Dessa forma, para manter a coerência com seu objetivo, o horizonte de previsão definido para o modelo foi determinado através da soma entre o período de revisão e o *lead time* de abastecimento.

Dado que são muitos os produtos manipulados pela empresa de estudo, foi considerado que cada previsão do modelo será atualizada a cada dois dias, sendo esse então o valor do período de revisão. Tendo o *lead time* médio de abastecimento de cerca de cinco dias (ver Seção 3.2), pode-se definir que o horizonte de previsão considerado é de sete dias.

O nível de previsão desse modelo também foi definido considerando a grande quantidade de itens que a Unilever produz. Seria inviável a aplicação de um método de previsão para cada um dos SKU's da companhia e, por isso, optou-se por fazer uma consolidação um pouco mais abrangente que fosse efetiva o suficiente para melhorar a prevenção das perdas de oportunidades de vendas para os itens e, ao mesmo tempo, fosse viável de se acompanhar constantemente.

Assim, o nível de previsão definido foi o de família da marca, que nada mais é do que o grupo de produtos de uma mesma marca que apresenta os mesmos atributos e consequentemente o mesmo preço de venda. Portanto, esse nível é basicamente a consolidação de todos os SKU's muito semelhantes entre si, ou melhor, que se diferem apenas quanto à variante do item (fragrância, sabor, especialidade, etc.).

Fazendo essa consolidação, o número de amostras possíveis de serem analisadas reduz-se consideravelmente e, ainda assim, o nível de previsão não é tão generalista. Apesar disso, obter uma previsão também no nível de SKU não pode ser algo desconsiderado. Para isso, o modelo determina que, após a previsão de demanda da família da marca, deve-se realizar um procedimento já utilizado atualmente: a definição do SOA (*Share Of Assortment*). Logo, obtida a quantidade de venda prevista, promove-se uma “divisão” desse valor entre todos os SKU's envolvidos na análise, assumindo como critério de rateio a representatividade de suas vendas nas últimas semanas.

Para suprimir qualquer dúvida a respeito da consolidação considerada, a Figura 6.2 fornece uma visão mais completa de quais são os agrupamentos de produtos mais comumente realizados na Unilever, posicionando cada um deles do nível mais macro (Divisão de Negócio) até o mais micro (SKU).



Figura 6.2 – Formas de agrupamento dos produtos

6.2 ABRANGÊNCIA DO ESTUDO

Antes de iniciar a apresentação concreta do desenvolvimento de todo esse estudo é extremamente importante destacar-se como o mesmo será conduzido e qual foi a abrangência determinada.

Como já dito no início desse documento, o trabalho se dará em torno do processo de vendas dos produtos das divisões HPC e FOODS da Unilever às lojas Wal-Mart Supercenter. Entretanto, para possibilitar a realização de um estudo real e mais próximo ao dia-a-dia de abastecimento de um hipermercado, algumas outras definições quanto às amostras que seriam utilizadas tiveram de ser traçadas.

Como a empresa em estudo é uma gigante do ramo de bens de consumo e apresenta milhares de produtos espalhados por dezenas de lojas dessa bandeira em todo o país, seria completamente impossível a realização de um estudo considerando todas as possibilidades desse universo. Assim, esse trabalho se preocupou em selecionar uma amostra reduzida de variáveis, mas, em contrapartida, detalhar profundamente toda a metodologia de análise para que fornecedor e varejista tomem conhecimento de sua importância e possam replicá-la facilmente a qualquer caso desejado.

Dessa maneira a amostra escolhida considera os dados de apenas uma loja – a mais representativa em vendas de produtos Unilever – pois a existência de variações de dados como preços, rupturas de gôndolas e eventos promocionais entre as lojas da rede poderiam causar distorções nas análises do estudo, caso fossem utilizados os dados de mais de uma, simultaneamente, no mesmo modelo.

Conforme abordado na seção anterior, o novo modelo foi estruturado para que organize suas previsões conforme o nível de família da marca. Assim, produtos “irmãos” serão agrupados e terão suas demandas previstas de forma única para, na sequência, ocorrer um rateio que determina a previsão por SKU.

Para ser mostrada a consistência e validade do método para todo o portfólio da empresa, foram selecionadas como amostras três famílias de marcas distintas, cada uma pertencente a uma das divisões de negócios incluídas no estudo. A Tabela 6.1 mostra a caracterização de cada família escolhida para a realização desse trabalho.

Tabela 6.1 – Caracterização das amostras escolhidas para o estudo

DIVISÃO	MARCA	FAMÍLIA DA MARCA	COMPOSTA POR
PC	MARCA A	FAMÍLIA I	20 SKU's
HC	MARCA B	FAMÍLIA II	10 SKU's
FOODS	MARCA C	FAMÍLIA III	17 SKU's

Apesar de todas essas amostras serem estudadas, apenas os experimentos referentes à Família I da Marca A de PC serão completamente expostos no corpo desse documento. Essa decisão foi tomada para que a análise de pelo menos um dos itens pudesse ser profunda e bastante didática de forma a proporcionar um fácil entendimento e viabilizar a replicação para os demais. As outras duas marcas citadas possuem alguns de seus principais resultados, também, apresentados ao longo do corpo, porém os gráficos e explicações analíticas estão melhor detalhados no Anexo I desse documento.

Devido a questões de confidencialidade dos dados da empresa os nomes das marcas, das famílias das marcas e dos produtos que as compõe não serão revelados. Além disso, todos os dados numéricos apresentados nesse estudo foram indexados através de um fator multiplicativo definido pelo autor de forma a manter a validade das análises e resultados, mas omitir os dados reais da empresa.

6.3 LEVANTAMENTO DOS DADOS

O levantamento de dados é uma das tarefas de maior importância na elaboração de qualquer modelo de previsão. Escolher dados certos e, principalmente, confiáveis é uma etapa fundamental para o sucesso de todo estudo de antecipação da demanda, afinal, nenhuma previsão consegue ser mais precisa do que os dados nos quais ela se baseia.

Como o trabalho se propõe a elaborar e simular um modelo quantitativo de previsão de demanda, obter séries históricas completas de vendas é puramente essencial. Dessa forma, através do banco de dados da própria rede Wal-Mart, foram levantadas séries referentes às vendas diárias dos itens analisados durante um período de dois anos.

Nesse momento, é importante ressaltar que os dados de entrada em um sistema de previsão devem ser cuidadosamente observados para evitar que distorções sejam geradas. Para o caso em questão – previsão com base em séries históricas de vendas – é necessária uma atenção especial para o relevante ponto de que a venda não necessariamente representa a demanda. Isso se explica devido ao fato de que a vontade de consumo nem sempre é satisfeita pela oferta dos produtos, ou seja, pode acontecer de em determinado dia haver a demanda por um item, mas o mesmo não se encontrar disponível para venda. Logo, nessa situação, tem-se um dado de venda que é inferior ao que seria a demanda daquele dia.

Para contornar esses casos, Santoro (2009) sugere a realização de um tratamento dos dados de entrada do sistema de previsão procurando-se corrigir as quantidades vendidas com a avaliação das faltas diagnosticadas.

Como nem a Unilever, nem o Wal-Mart mantêm um histórico de faltas dos produtos comercializados em suas bases de dados, foi necessária a realização de uma estimativa de quais leituras apresentavam um valor de venda inferior à demanda real. Para tanto, o autor criou uma metodologia que corrigiu potenciais dados subestimados quando encaixados em condições pré-estabelecidas. Tal análise foi realizada SKU por SKU antes da consolidação em família da marca, pois, caso contrário, a falta de determinado produto poderia ser camuflada pelo “excesso” de estoque de outro, não permitindo as devidas correções.

Dessa forma, os dados diários foram corrigidos somente quando satisfaziam, simultaneamente, duas condições que relevaram, principalmente, a quantidade de venda e os níveis de estoque apresentados. Tais condições são apresentadas e mais bem detalhadas a seguir.

Condição 1: Quantidade em Estoque na Loja < Média Total de Vendas (média dos dois anos)

Apresentar, em determinado dia, um nível de estoque menor do que a média de vendas de toda a amostra de dados, significa que a loja, muito provavelmente, está trabalhando com baixos estoques, o que pode impactar diretamente no volume vendido. Ter quantidades insuficientes do produto na loja pode ocasionar a situação do consumidor desejá-lo comprar, mas não o encontrar por ele não estar tão visível quanto os demais produtos ou, ainda, devido ao fato das poucas unidades até então disponíveis terem sido todas vendidas. Além disso, para estoques iguais a zero, significa que o produto realmente não se encontrava na loja.

Condição 2: Quantidade Vendida no Dia < Média de Vendas dos Quatro Últimos Mesmos Dias das Semanas Anteriores

Esse fato é levado em consideração apenas para verificar se a possível insuficiência de estoque afetou o volume de vendas esperado, isto é, se realmente a demanda pelo produto foi maior do que a venda naquele dia. Nessa comparação, considerou-se que se a quantidade vendida fosse superior à média de vendas dos últimos quatro mesmos dias da semana, a demanda era realmente igual à venda; caso contrário, o valor da demanda era igualado a essa média. Considerar os últimos mesmos dias da semana foi uma decisão tomada, pois, conforme será demonstrado na seção a seguir, pôde-se comprovar a existência de sazonalidade diária e, por isso, a venda de uma quarta-feira, por exemplo, é mais bem justificada pelas vendas das últimas quartas-feiras, do que pelas vendas dos últimos dias.

Colocadas essas restrições para os históricos de todos os SKU's da Família I da Marca A e feitas devidas arrumações, transformou-se a curva de vendas em uma curva de demanda. Nesse procedimento, verificou-se a ocorrência de correções que incrementaram aproximadamente 2,5% do valor de vendas; um número relativamente baixo que demonstra, para esse caso, que em grande parte das vezes as vendas corresponderam à demanda por essa família. Para os outros dois casos em estudo, a porcentagem de correção também foi baixa.

6.4 ANÁLISE PRELIMINAR DOS DADOS

Tendo em mãos a série histórica da demanda dos dois últimos anos das famílias escolhidas, é bastante recomendável a realização de uma análise em torno dessas informações antes de se iniciar o desenvolvimento de um modelo de previsão.

Um estudo preliminar como o sugerido tem o intuito de conhecer mais profundamente o comportamento dos dados e de identificar quais são os principais componentes da série temporal e com que força eles se manifestam nela. Dessa forma, essa é uma ótima oportunidade de se investigar e já perceber nesses dados a presença, ou não, de componentes tais como tendência, sazonalidade ou, até mesmo, ciclicidade.

Entretanto, nenhuma investigação fará sentido sem antes haver uma apresentação dos dados levantados e, por isso, esse será o ponto de partida. Escolhidas as famílias das marcas em estudo, foram levantados todos os históricos de vendas de todos os SKU's que fazem (ou fizeram) parte desses grupos durante o período de 01 de Outubro de 2007 a 30 de Setembro de 2009. Na sequência os dados colhidos foram todos submetidos, separadamente, às correções já apresentadas e somados para, enfim, fornecer a curva de demanda. A curva da Família I é apresentada na Figura 6.3.




Figura 6.3 – Curva de demanda diária da Família I da Marca A

Observando o gráfico é possível ter uma noção superficial de qual é o hábito de consumo dos clientes da loja analisada. O que chama bastante atenção nessa figura é a grande e brusca variação existente na demanda todos os dias e a frequência com que picos e vales aparecem ao longo de toda a série. Tais fatos nos remetem a uma desconfiança inicial de que a demanda dessa família apresenta uma sazonalidade que, a princípio, aparenta ser diária. Entretanto, continuemos com as análises.

Além da visão diária dos dados da série temporal, outra observação bastante interessante de se ter nesse início é a visão semanal. Consolidar as informações diárias para que o comportamento da demanda seja visto com o passar das semanas pode ser bastante útil para indicar que caminhos são bons (ou não) de serem percorridos.

Para que fosse gerada uma amostra de dados que fornecesse realmente alguma informação relevante para análises, foi necessária a criação de um critério que definisse como seriam consolidadas as semanas do mês. A Tabela 6.2 explicita os agrupamentos realizados.

Tabela 6.2 – Critério de consolidação dos dados diários em semanas do mês

SEMANA	DIAS DO MÊS
1ª SEMANA	01 – 07
2ª SEMANA	08 – 14
3ª SEMANA	15 – 21
4ª SEMANA	22 – 28
5ª SEMANA	Restante

Dessa forma, as quatro primeiras semanas de todos os meses são formadas sempre pela mesma base de dias, o que fornece uma vantagem analítica de seus comportamentos. Como os meses não possuem o mesmo número de dias, a quinta semana foi criada para absorver essas diferenças e para permitir que as demais semanas possuissem exatos sete dias. Feitas tais considerações, gerou-se a curva de demanda da Família I, com visão semanal.




Figura 6.4 – Curva de demanda semanal da Família I da Marca A

Semelhantemente à sensação tida com o gráfico de demanda diária, observar essa outra maneira de se expor o comportamento da série histórica também gera uma grande desconfiança de que há nela uma sazonalidade, porém agora, de ordem semanal.

Diante de tais fatos, foi decidido o levantamento de dados numéricos a respeito da participação de cada dia da semana e de cada semana do mês na demanda total da Família I, levando em consideração toda a série histórica disponível (Tabela 6.3). Com essas informações busca-se mais um argumento para embasar se as conclusões obtidas pelas observações dos gráficos são, ou não, coerentes.

Tabela 6.3 – Participação da demanda por dia da semana e semana do mês

DIA DA SEMANA	SEMANA DO MÊS					TOTAL
	1ª SEM	2ª SEM	3ª SEM	4ª SEM	5ª SEM	
DOM	4,72%	3,50%	3,59%	3,20%	1,13%	16,13%
SEG	3,27%	2,54%	2,20%	2,11%	0,88%	11,01%
TER	2,81%	2,27%	2,11%	1,84%	1,27%	10,30%
QUA	3,90%	2,91%	2,23%	2,82%	1,41%	13,27%
QUI	3,30%	2,54%	2,05%	2,68%	1,07%	11,64%
SEX	4,71%	3,28%	2,78%	3,20%	1,11%	15,08%
SÁB	6,92%	4,62%	4,76%	4,47%	1,80%	22,57%
TOTAL	29,62%	21,66%	19,71%	20,32%	8,69%	100,00%

Analisando a tabela verifica-se que o sábado é o dia da semana que apresenta maior representatividade de vendas, superando consideravelmente os demais dias. Na segunda colocação aparece o domingo, acompanhado de perto pela sexta-feira. Isso demonstra claramente que grande parte dos consumidores deixa para realizar suas compras nos dias que tem mais tempo disponível, os finais de semana, que também são os dias que mais possuem eventos na loja como degustação, demonstração de produtos e distribuição de brindes.

Já entre as semanas do mês, verifica-se que a primeira semana é líder de vendas e, obviamente, a quinta é a que menos vende já que ela considera as vendas de, no máximo, três dias. Uma possibilidade para tamanho destaque para a primeira semana é o fato dos consumidores possuírem mais dinheiro no início do mês e, assim, tornarem-se mais propensos às despesas.

É interessante notar que tanto as linhas quanto as colunas da Tabela 6.3 mantêm, na maior parte das vezes, a coerência apresentada na linha total. Esse pode ser considerado um indício de que as sazonalidades realmente existem.

Entretanto, apesar de todas as evidências encontradas até o momento, não é possível afirmar com toda a certeza que há sazonalidade em uma série temporal, através da mera observação de gráficos e informações consolidadas. Isso tudo não é suficiente, nem totalmente confiável, já que a análise visual pode nos conduzir a enganos. Para tanto, Makridakis, Wheelwright e Hyndman (1998) definem o estudo da autocorrelação como uma ferramenta extremamente útil para analisar séries temporais e verificar a existência de sazonalidade, ciclos ou outros padrões nos dados.

A autocorrelação é um coeficiente comparativo que serve para medir o grau de relação que os dados de uma série temporal têm consigo mesma ao ser defasada de n períodos. Assim, uma defasagem de $n = 1$ período, mede o quanto observações consecutivas da série estão relacionadas (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998). Adicionalmente a isso, Hanke e Reitsch (1998) destacam que se uma série temporal apresenta sazonalidade, um valor (em módulo) mais significativo de autocorrelação – isto é, visivelmente superior aos demais – irá ocorrer a cada n períodos. Nesses casos, portanto, esse valor de defasagem n será equivalente ao período de sazonalidade da série.

Diante de tais informações foram calculadas as autocorrelações da série temporal diária com defasagens de $n = 1$ a $n = 28$ dias, o que significa avaliar a relação apresentada entre os dados durante quatro semanas de ciclo, com defasagens diárias. Obtidos esses valores, o correlograma apresentado na Figura 6.5 pôde ser plotado.




Figura 6.5 – Correlograma da demanda diária da Família I da Marca A

Observando o correlograma gerado pode-se perceber que os valores de autocorrelação para as defasagens $n = 1$, $n = 7$, $n = 14$, $n = 21$ e $n = 28$ se sobressaem perante os demais coeficientes. Como a ocorrência de valores mais significativos está se dando a cada 7 períodos, pode-se concluir que os dados da série diária da Família I tem grande correlação com os seus próprios dados defasados de 7 dias, o que comprova definitivamente a existência de sazonalidade entre os dias da semana.

Feita toda essa análise com a série de dados diária, é hora de repeti-la para a série com os dados consolidados semanalmente. O procedimento é basicamente o mesmo, porém, uma adaptação foi necessária e, por isso, precisa ser explicitada. Conforme apresentado na Tabela 6.2, os dados referentes às quintas semanas de cada mês são obtidos através da soma da demanda do dia 29 até o final do mês. Como o número de dias considerados pode ser no máximo três, e pior, é nulo no caso do mês de fevereiro – já que o mesmo tem apenas 28 dias – considerar essa semana para a análise de autocorrelação poderia distorcer o resultado. Por esse motivo, para o cálculo dos coeficientes de autocorrelação dessa série, todos os dados referentes às quintas semanas do mês foram excluídos da amostra.

Dessa forma, utilizando-se apenas dos dados referentes às quatro primeiras semanas de cada mês, as autocorrelações foram calculadas com defasagens de $n = 1$ a $n = 20$, o que significa avaliar a relação apresentada entre os dados durante cinco meses de ciclo, com defasagens semanais. A Figura 6.6 mostra o correlograma resultante de tais cálculos.




Figura 6.6 – Correlograma da demanda semanal da Família I da Marca A

Visualizando o correlograma plotado percebe-se que os valores de autocorrelação para as defasagens $n = 1$, $n = 4$, $n = 8$, $n = 12$, $n = 16$ e $n = 20$ se sobressaem perante os demais coeficientes. Como a ocorrência de valores mais significativos está se dando a cada 4 períodos, pode-se concluir que os dados da série semanais tem grande correlação com os seus próprios dados defasados de 4 semanas. Como foram considerados apenas 4 semanas por mês nas amostras para os cálculos, comprova-se aqui, também, a definitiva existência de sazonalidade entre as semanas do mês.

Vale ressaltar que os testes realizados com as Famílias II e III das Marcas B e C, respectivamente, apresentaram comportamento muito semelhante ao da Família I, tanto para os dados diários quanto para os semanais. Aparenta-se, assim, que a característica de sazonalidade não é particularidade dos produtos, mas sim, um comportamento do mercado varejista.

Analísado o caráter sazonal, é interessante agora, se iniciar uma nova análise que verifique se também é encontrada na série temporal outra componente muito importante: a tendência.

Apesar de ser a primeira idéia que vem à cabeça, traçar uma linha de tendência diretamente na série histórica de demanda levantada não é a melhor opção de análise, pois a presença de sazonalidade nos dados pode influenciar o grau de inclinação da reta. Portanto, para se saber mais precisamente qual é a tendência de uma série, é preciso utilizar como base de análise os dados temporais dessazonalizados.

Como apresentado no Capítulo 5, Makridakis, Wheelwright e Hyndman (1998) sugerem a utilização da decomposição de séries temporais como uma ferramenta bastante útil para análises preliminares e, por isso, ela será utilizada para auxiliar a dessazonalização da demanda. Entretanto, como também visto, há duas diferentes abordagens para esse método. Considerando as características apresentadas pela sazonalidade da Família I estudada, a decomposição multiplicativa mostrou-se ser mais apropriada.

Esse método prevê “quebrar” a série de dados históricos, separando suas componentes básicas: tendência, sazonalidade e aleatoriedade. Tal procedimento é realizado através de quatro etapas simples:

- *Etapa 1:* Obtenção da componente “ciclo de tendência”
- *Etapa 2:* Traçado da curva “destendenciada”
- *Etapa 3:* Estimativa dos índices da componente sazonalidade
- *Etapa 4:* Obtenção da componente aleatoriedade

Obtém-se a componente “ciclo de tendência” por meio da aplicação, a cada dado da série, da média móvel centrada de ordem igual ao período de um ciclo. Calculados tais dados, basta retirá-los da série original, através da divisão simples dos valores reais pelos de “ciclo de tendência”, resultando assim, na curva “destendenciada”.

Tomando como base essa nova curva, cada índice de sazonalidade é estimado através da realização da média de todos os valores pertencentes a seu respectivo período sazonal. Para o caso estudado, por exemplo, foram feitas as médias dos valores de todas as segundas-feiras, de todas as terças-feiras e assim sucessivamente, até a estimativa dos sete índices de sazonalidade para os dias da semana. Na sequência, o mesmo foi feito para a estimativa dos cinco índices para as semanas do mês. Obteve-se o índice final para cada data através da ponderação (multiplicação) dos índices dos dias da semana e das semanas do mês.

Por fim, para a obtenção da aleatoriedade, retirou-se da série original, o “ciclo de tendência” e o índice de sazonalidade já calculados.

Tendo todos esses dados em mãos, a curva de demanda foi dessazonalizada através da simples retirada do índice de sazonalidade, do dado original. Como se trata de uma decomposição multiplicativa, tal operação foi realizada por meio da divisão do segundo pelo primeiro. Feito isso, os dados foram consolidados mês a mês – para tornar a visualização gráfica melhor – e traçada a linha de tendência, como mostra a Figura 6.7.




Figura 6.7 – Linha de tendência da Família I da Marca A

Visualizando a linha de tendência traçada na curva de demanda dessazonalizada e observando que seu R^2 é muito baixo, pode-se assumir, sem dúvida alguma, que o comportamento da demanda é constante e, portanto, que não há tendência nessa série.

Repetido o procedimento para as outras duas famílias participantes do estudo, percebe-se que a Família II da Marca B apresenta um comportamento bastante semelhante ao explicitado acima em que a demanda pode ser considerada constante. Já os dados da Família III da Marca C apresentam um valor de R^2 um pouco mais significativo, diferenciando-se dos demais, e apresentando um comportamento de tendência positiva.

6.5 SELEÇÃO DO MODELO DE PREVISÃO

Em posse dos dados históricos das demandas e já tendo um conhecimento maior sobre o comportamento das mesmas, é chegado o momento de selecionar o método de previsão mais adequado para se usar.

Como já ficou claro, a proposta desse trabalho é desenvolver um modelo de previsão para as Famílias das Marcas da Unilever, buscando propiciar mais e melhores informações sobre suas demandas, a fim de se evoluir o modelo de abastecimento do varejo e minimizar as indisponibilidades de produtos nas lojas, sem contudo, esquecer-se da eficiência.

Dado esse objetivo, fica evidente que buscar-se-á aqui a criação de um modelo quantitativo de previsão, já que, atualmente, a empresa estudada carece da existência de um. A intenção desse trabalho é desenvolver primeiramente um modelo de projeção que se utilize apenas de séries históricas de demanda para realizar a previsão; e, na sequência, caso necessário, buscar aperfeiçoá-lo por meio de informações geradas em uma análise causal, criando-se assim um modelo integrado mais adequado para a previsão da demanda.

Entretanto, para escolher que técnica de previsão utilizar na elaboração do modelo, basear-se em apenas um fator de decisão raramente é suficiente e, por esse motivo, uma análise de múltiplos critérios deve ser considerada.

Wheelwright e Makridakis (1980) sugerem que seis fatores principais devam ser relevados e analisados para a escolha de um modelo de previsão. Foi justamente com base nesses critérios (e nas técnicas explicitadas no Capítulo 5) que a seleção foi realizada. Veja as descrições a seguir.

1) Horizonte de Previsão

Para a decisão de qual técnica de antecipação da demanda utilizar, é importantíssimo considerar o horizonte de previsão desejado. Os métodos geralmente apresentam uma melhor aplicabilidade dependendo do tamanho desse período, se adaptando melhor a determinadas faixas de horizonte.

Como o caso estudado visa o desenvolvimento de um modelo para o curtíssimo prazo com um horizonte de previsão de sete dias, não há significativas restrições quanto aos métodos de projeção que podem ser utilizados.

2) Comportamento da Demanda

Como já abordado nesse documento, os dados de uma série temporal de demanda podem apresentar alguns comportamentos típicos como horizontalidade, sazonalidade, ciclicidade, tendência e aleatoriedade.

Dado que os diferentes modelos apresentam capacidades distintas de adaptação à existência desses comportamentos, identificar e ter conhecimento da presença de um, ou mais, desses padrões nos dados em análise é algo indispensável.

3) Propriedades do Método

Esse critério é tido como um julgamento mais qualitativo em torno das possibilidades de modelos, onde são levantadas as facilidades e as dificuldades de cada um deles como uma forma de comparação.

4) Custo Associado ao Método

De nada adianta o desenvolvimento de um modelo de previsão com boa precisão se os custos vinculados ao mesmo forem proibitivos. Assim sendo, para a escolha de um método é importante ponderar se os custos gerados pelo o mesmo são recompensados pelos ganhos propiciados.

Pode-se destacar que os custos mais relevantes associados a um modelo de previsão são os custos de desenvolvimento do modelo, de coleta e armazenagem dos dados e, de operação e monitoramento.

5) Complexidade do Modelo

Trata-se de um dos fatores mais relevantes de ser apurado. Para O'Donovan (1983) a principal razão de modelos matematicamente mais completos e sofisticados não serem efetivamente utilizados pelas empresas é justamente a sua complexidade. O autor acredita que se os usuários do modelo de previsão não entenderem como ela foi gerada, é muito grande a chance deles não terem confiança no método e o abandonarem. Além disso, o maior tempo de resposta da previsão comumente associado a modelos complexos pode tornar sua aplicabilidade mais difícil.

Assim, é válida a reflexão sobre o que é melhor: um modelo super elaborado, complexo e inútil, ou, um modelo suficientemente preciso, compreendido por seus usuários e útil?

6) Acurácia do Método

Muitos acreditam erroneamente que o modelo que apresenta maior precisão é o melhor e deve ser o escolhido. Entretanto, apesar da importância desse fator ser realmente muito grande, verificar a acurácia do método significa avaliar se a precisão atingida por ele condiz com as expectativas e necessidades da previsão. Assim sendo, não necessariamente o modelo de maior precisão é o melhor e, portanto, para a efetuação da escolha, deve-se fazer um balanço entre a necessidade para a qual ele está sendo desenhado e os demais critérios aqui expostos.

Destacados todos os principais fatores é possível se iniciar a avaliação dos modelos e o procedimento de escolha do mais adequado para as necessidades apresentadas. O primeiro passo é notar que, dado o comportamento do caso da Família I da Marca A e os aspectos acima apresentados, muitos métodos já poderiam ser eliminados.

Como visto há pouco, a demanda dessa Família apresenta sazonalidade evidente e tendência insignificante. Somente a descoberta desse fato já elimina grande parte dos modelos candidatos e restringe as alternativas entre apenas a Suavização Exponencial com Sazonalidade e a Decomposição Multiplicativa. Entretanto, foi visto diversas vezes que Makridakis, Wheelwright e Hyndman (1998) não aconselham o uso da decomposição como um método de projeção, mas sim, como uma ferramenta de auxílio para o entendimento da demanda que, inclusive, já foi utilizada no estudo aqui apresentado. Portanto, diante desses argumentos, o modelo escolhido para a previsão de demanda deveria ser a Suavização Exponencial com Sazonalidade.

É interessante abrir-se aqui um parêntese e destacar que, por raciocínios análogos, percebe-se previamente que, para a Família II, o método de Suavização Exponencial com Sazonalidade também deveria ser o escolhido e, para a Família III, o Método Holt-Winters.

Apesar de aparentemente os modelos de projeção já estarem definidos, o presente trabalho irá simular todos os modelos candidatos apresentados no Capítulo 5 – com exceção da Decomposição, por motivos já justificados – para todas as Famílias estudadas. Isso será feito, pois, mesmo com a discussão apresentada acima nos levando a possíveis conclusões, analisar a precisão de todos os modelos é uma etapa fundamental e necessária – já que é um dos principais critérios de seleção – para ver se os indícios encontrados realmente apontam para a melhor alternativa.

Além disso, vale considerar que por mais que as Famílias I, II e III sejam as bases de desenvolvimento desse estudo, a metodologia deve ser bem explicada justamente para poder ser reaplicada às outras Famílias da empresa. Assim, como não é raro do melhor modelo para um, não ser o melhor para outro (vide as sugestões antecipadas para as Famílias I e III, por exemplo), é interessante a abordagem de todos os casos para um maior conhecimento de suas adequações. Simulando os modelos candidatos é possível observar se a alternativa escolhida é, ou não, aquela que apresenta maior precisão, e também, o quanto os demais modelos se encaixariam no caso analisado.

Vale relembrar que os testes explicitados a seguir serão referentes à Família I da Marca A, porém com breves menções dos resultados obtidos para as outras duas Famílias.

6.5.1 TESTES DOS MODELOS

Para que os modelos pudessem ser testados, foi necessário o estabelecimento de premissas que seriam aplicadas a todos eles, sem exceção. A primeira delas, já explicitada, é que todos os modelos deverão considerar um horizonte de previsão de sete dias. Já a segunda, é referente à determinação dos períodos de previsão que, conforme explicado no Capítulo 5, se dividem em um período de inicialização e outro de testes (ou validação) que devem ser considerados antes da projeção propriamente dita.

Dado que a série temporal analisada conta com informações históricas de dois anos, foi decidido que a fase de inicialização seria equivalente à primeira metade dos dados e a fase de testes, à segunda metade. O esquema a seguir aponta, especificamente, as datas de início e término de cada fase.




Figura 6.8 – Determinação dos períodos de previsão da Família I da Marca A

FONTE: Adaptado de Santoro (2009)

É válido ressaltar que os erros calculados para todos os modelos são referentes aos desvios observados entre os valores das projeções realizadas para o futuro “adotado” e os valores realmente ocorridos, em outras palavras, os erros são medidos unicamente durante o período de testes da série.

Feitas tais considerações, todos os modelos foram formulados e simulados pelo autor com o auxílio do *software MS Excel*. É interessante pontuar que para os modelos de Suavização Exponencial Simples, Suavização Exponencial com Tendência, Suavização Exponencial com Sazonalidade e Método Holt-Winters a escolha dos parâmetros α , β e/ou γ existentes em cada um deles foi feita no intuito de se encontra o menor erro possível. Isso foi conseguido através de programações elaboradas em VBA (para cada um dos modelos) que realizaram buscas exaustivas testando todas as possíveis combinações desses parâmetros, variando-os de 0 a 1 com passo de 0,01.

Por fim, é importante dizer que o MAPE foi a medida de erro escolhida para ser otimizada e comparada entre os diferentes modelos. A Tabela 6.4 apresenta os resultados obtidos em todas as simulações testadas para a Família I da Marca A.

Tabela 6.4 – Erros obtidos com os diferentes modelos de previsão

MODELO DE PREVISÃO	MAE	MAPE
Média Simples	1.562,07	28,73%
Média Móvel (k = 07 dias)	1.297,56	24,06%
Média Móvel (k = 14 dias)	1.443,24	27,24%
Média Móvel (k = 21 dias)	1.444,46	27,65%
Média Móvel (k = 28 dias)	1.331,40	25,81%
Média Móvel (k = 35 dias)	1.354,39	26,58%
Suavização Exponencial Simples	1.259,40	23,30%
Suavização Exponencial com Tendência	1.247,83	23,24%
Suavização Exponencial com Sazonalidade	1.183,41	22,00%
Método Holt-Winters	1.185,09	21,78%

Observando os resultados demonstrados na tabela, são válidos alguns comentários para o melhor entendimento dos números e a explicação da escolha do modelo.

O valor do MAPE obtido na simulação feita com a média móvel de $k = 7$ dias chama a atenção, pois mostrou um desempenho razoável quando comparado com os demais, apesar da simplicidade do modelo. Um dos prováveis motivos para essa ocorrência é o fato de o horizonte de previsão ser de sete dias e, por causa disso, muito da sazonalidade entre os dias da semana ser amenizada já que em toda previsão um, e somente um, de cada dia da semana estará sendo considerado.

Dentre os processos de suavização, o modelo que considera apenas a sazonalidade apresenta o segundo menor valor de MAPE, ficando atrás apenas do Método Holt-Winters. Entretanto, ao se analisar o valor do MAE percebe-se que ele é sensivelmente melhor. Esse fato demonstra que a diferença entre esses dois métodos é mínima e, por isso, não muito significativa.

Junto a isso, é necessário se lembrar dos demais critérios de seleção definidos nesse estudo. O Método Holt-Winters, por considerar simultaneamente tendência e sazonalidade, é mais complexo, de maior dificuldade de entendimento para possíveis operadores e exige um maior tempo de simulação para o encontro da melhor combinação de parâmetros.

Além disso, atentando-se para o comportamento da demanda, foram constatadas a presença de sazonalidade e a ausência de tendência nos dados da Família I da Marca A. Apesar da sazonalidade entre os dias da semana ser amenizada pelo o horizonte de previsão de sete dias, a série também apresenta um comportamento sazonal entre as semanas do mês, que por não ser minimizado pelo horizonte escolhido torna-se um fato que favorece e justifica a escolha do modelo de Suavização Exponencial com Sazonalidade. Por outro lado, não se pode esquecer que a sazonalidade também é considerada pelo Método Holt-Winters, entretanto, a inexistência de tendência na demanda estudada, o desfavorece muito.

Assim, diante de todas essas constatações, percebe-se que o modelo mais adequado de ser selecionado é realmente o de Suavização Exponencial com Sazonalidade, confirmando a escolha anteriormente sugerida.

Fazendo também todas as simulações para as Famílias II e III, foram analisados os erros obtidos junto com os demais critérios de seleção definidos para esse estudo, chegando-se à conclusão de que os modelos de Suavização Exponencial com Sazonalidade e Holt-Winters são, respectivamente, os mais adequados. Percebe-se, mais uma vez, que houve o alinhamento com as sugestões antes realizadas.

6.5.2 O MODELO ESCOLHIDO

Depois de escolhido o método de Suavização Exponencial com Sazonalidade para a Família I da Marca A, essa seção vai demonstrar um pouco mais profundamente a sua aplicação, bem como os resultados obtidos. Vale lembrar que as Famílias II e III têm um breve aprofundamento de seus resultados no Anexo I desse documento.

Conforme visto no Capítulo 5, a formulação proposta para a Suavização Exponencial com Sazonalidade é:

$$L_t = \alpha \frac{Y_t}{S_{t-s}} + (1 - \alpha)L_{t-1} \quad (6.1)$$

$$S_t = \gamma \frac{Y_t}{L_t} + (1 - \gamma)S_{t-s} \quad (6.2)$$

$$F_{t+m} = L_t \cdot S_{t-s+m} \quad (6.3)$$

Obviamente, o modelo desenvolvido também utiliza essas equações como base para seus cálculos. Tudo começa com a preparação do período de inicialização que vai fornecer de *input* para o período de testes, estimativas de valores iniciais para a componente nível L_t e, também, para os sete fatores de sazonalidade S_t referentes aos dias da semana. Como se pode perceber, de acordo com o equacionamento apresentado, não se considera naturalmente na análise os impactos causados pela sazonalidade entre as semanas do mês. Dessa maneira, o autor desse trabalho criou uma forma de ajuste para que os outros cinco fatores semanais também fossem considerados.

Tal ajuste segue a seguinte lógica: de acordo com a data para qual se está realizando a previsão deve-se acrescentar o fator de sazonalidade semanal correspondente. Este fator é o mesmo já obtido pelo método de Decomposição durante a análise preliminar dos dados. Assim sendo, é feita uma ponderação entre a sazonalidade diária já calculada pelo modelo e a sazonalidade semanal que, até o momento, não era considerada. Tal ajuste só deve ser implementado no momento da realização da previsão, isto é, na equação (6.3), que passa a ser formulada da seguinte maneira.

$$F_{t+m} = L_t \cdot S_{t-s+m} \cdot SS_{t+m} \quad (6.4)$$

Onde, SS_{t+m} = fator de sazonalidade semanal corresponde à data $t + m$

Feitas tais considerações, é necessária a preparação da previsão de acordo com a necessidade do modelo que está sendo desenvolvido. Como o principal intuito dessa ferramenta é prever o comportamento da demanda e poder antecipá-lo de forma a melhorar o abastecimento do varejo, a correta consideração do horizonte de previsão é fundamental. Já foi visto que o horizonte definido para o caso estudado é de sete dias, entretanto, é preciso prestar atenção para que o cálculo esteja alinhado com o objetivo da ferramenta. Assim, o modelo deve efetuar uma previsão não para sete dias adiante da data presente, mas sim, uma previsão que consolide todas as previsões do dia seguinte até o sétimo dia. Tal cálculo pode ser efetuado com base na equação (6.5).

$$F_{HP=7} = \sum_{m=1}^7 F_{t+m} = L_t \cdot \sum_{m=1}^7 (S_{t-s+m} \cdot SS_{t+m}) \quad (6.5)$$

Feito isso, são consolidados os valores das demandas reais referentes ao mesmo período para o qual foi realizada a previsão e, então, são comparados com o valor projetado. É sobre o desvio entre essas duas medidas que consideram a soma das demandas reais e previstas dos sete dias subsequentes à data observada, que são calculados os erros do modelo.

Estando formulado todo o período de testes, é simulada a programação em VBA que analisa, através de uma busca exaustiva, as 10.201 possíveis combinações entre os parâmetros α e γ , com o objetivo de descobrir quais são os valores que, se aplicados, minimizam o MAPE do modelo.

Para facilitar o entendimento de todas as informações explicitadas acima, a Tabela 6.5 foi elaborada de forma a demonstrar um pequeno trecho da base de dados utilizada no modelo, já apresentando as respectivas previsões.

A partir dessa tabela percebe-se que logo na sequência do período de inicialização, vem o período de testes onde os valores das componentes nível e sazonalidade são atualizados diariamente e considerados para o cálculo da previsão.

Para demonstrar a flexibilidade do modelo, foram realizadas duas previsões com horizontes distintos. A primeira delas considera um horizonte comum de ser utilizado: o período de um dia; já a segunda, trabalha com o horizonte que realmente é importante para as necessidades desse estudo. É interessante ressaltar que, obviamente, a previsão realizada para sete dias não é simplesmente a soma das previsões diárias durante o mesmo período de tempo já que, na primeira, todas as previsões são realizadas com base em uma única data.

Tabela 6.5 – Fragmento da tabela utilizada no modelo de previsão

DATA	DEMANDA REAL	NÍVEL L_t	SAZONALIDADE S_t	SAZONALIDADE SS_t	PREVISÃO HP=1DIA	DEMANDA 7DIAS	PREVISÃO HP=7DIAS	MAE	MAPE
24/09/2008	586		0,763						
25/09/2008	896		0,678						
26/09/2008	997		0,894						
27/09/2008	1.472		1,330						
28/09/2008	1.167		0,930						
29/09/2008	1.027		0,614						
30/09/2008	1.138	1.440	0,617						
01/10/2008	1.091	1.438	0,763	1,10	1.209	-	-	-	-
02/10/2008	897	1.408	0,675	1,10	1.073	-	-	-	-
03/10/2008	1.010	1.335	0,882	1,10	1.385	-	-	-	-
04/10/2008	1.784	1.337	1,330	1,10	1.954	-	-	-	-
05/10/2008	1.344	1.365	0,935	1,10	1.368	-	-	-	-
06/10/2008	973	1.422	0,621	1,10	923	-	-	-	-
07/10/2008	1.218	1.566	0,631	1,10	964	8.317	9.233	916	11,0%
08/10/2008	810	1.435	0,745	0,95	1.134	8.036	9.051	1.015	12,6%
09/10/2008	682	1.325	0,660	0,95	920	7.821	8.713	892	11,4%
10/10/2008	642	1.169	0,852	0,95	1.110	7.453	8.070	617	8,3%
11/10/2008	1.143	1.089	1,305	0,95	1.478	6.812	7.813	1.001	14,7%
12/10/2008	830	1.036	0,923	0,95	967	6.298	7.793	1.495	23,7%

Para demonstrar uma das formas mais comuns de estudos de previsão, bem como, a forma que mais se adequa às necessidades para o qual o modelo foi desenvolvido, seguem abaixo as curvas que comparam a demanda real ocorrida durante o período de testes e os resultados obtidos com as previsões de horizontes de um e de sete dias.




Figura 6.9 – Curva de previsão X Curva real (Horizonte de Previsão de 1 dia)




Figura 6.10 – Curva de previsão X Curva real (Horizonte de Previsão de 7 dias)

Convém ressaltar que todos os resultados obtidos com a previsão $HP = 7$, apresentados na figura acima, já consideram nos seus cálculos os valores de parâmetros que minimizaram o MAPE do modelo. Como esse horizonte é a prioridade do estudo, os parâmetros por ele encontrados foram, também, os utilizados na previsão diária, já que a mesma foi feita com um intuito mais demonstrativo do que de uso efetivo.

Dessa maneira, os valores dos parâmetros utilizados e do erro total, resultantes da aplicação do modelo ao período de testes dos dados da Família I da Marca A, estão dispostos na tabela abaixo.

Tabela 6.6 – Principais resultados do modelo escolhido

SUAVIZAÇÃO EXPONENCIAL COM SAZONALIDADE	
Parâmetro α	0,26
Parâmetro γ	0,09
MAPE	22,00%

Como o valor do erro apresentado pelo modelo ainda pode ser considerado elevado, conclui-se que apenas a série histórica de dados não é suficiente para se fazer uma previsão precisa o bastante. Logo, é interessante a realização de uma análise causal buscando descobrir as principais variáveis que afetam a demanda da Família I da Marca A e como elas impactam na mesma para, assim, inseri-las no modelo de projeção na tentativa de uma redução do erro.

6.5.3 MELHORIA DO MODELO ESCOLHIDO

Analizado o estudo da análise de projeção dos dados da Família I da Marca A através da Suavização Exponencial com Sazonalidade, verificou-se que o erro do modelo ainda se encontra um pouco elevado dada a necessidade para o qual foi desenhado. Entretanto, tal estudo considera estritamente os dados históricos de vendas para a previsão da demanda, o que provavelmente, justifica esse erro, já que a mesma pode ser influenciada por muitas outras variáveis além da série temporal.

Assim sendo, o intuito nesse momento é tentar descobrir, por meio de uma análise causal, quais são essas variáveis que mais afetam o comportamento da demanda. Como serão estudados os possíveis impactos de diversas variáveis na demanda da Família I, utilizar-se-á nessa análise a Regressão Linear Múltipla.

Antes do início desse novo estudo é necessária a explicitação de todos os dados que foram possíveis de serem levantados. Deve-se ressaltar que é importante não só a coleta dos dados da Família da empresa em estudo, mas ainda, o máximo de informações também da concorrência, já que esta pode influenciar (e muito) o comportamento da demanda estudada. Abaixo seguem as informações conseguidas para a Regressão.

1) Preço

Como a análise do modelo é destinada à Família de uma Marca e o preço de todos os itens participantes desse grupo é o mesmo, não há riscos de ocorrerem distorções na consideração dessa variável. Os dados referentes a preços foram levantados para o produto da empresa estudada, bem como para os sete principais concorrentes da mesma.

É válido dizer que o histórico conseguido dessas informações não dispunha dos preços praticados dia-a-dia, mas sim, uma média durante intervalos regulares de tempo que normalmente se alternavam entre 15 ou 20 dias. Apesar disso, pode-se considerar que tais dados são relevantes para a análise e, por isso, serão utilizados.

2) Presença em Encartes

Entende-se por encarte todos os materiais gráficos disponíveis e entregues, na entrada das lojas, que contém a imagem e o preço dos produtos anunciados. São exemplos típicos de encartes os tablóides, as lâminas e os *flyers*.

Trata-se de uma atividade comumente utilizada e, por isso, bastante relevante para entrar no estudo. Como essa é uma variável binária, ela assume valor 1 para os dias em que o produto estiver presente em algum encarte, ou, valor 0 para quando estiver ausente. Nesse caso também foi possível levantar um histórico da Família em estudo, bem como dos principais concorrentes.

3) *Existência de Ponto Extra*

Como já definido anteriormente, ponto extra é a colocação dos produtos em um local que propicie uma exposição adicional a sua gôndola de costume. A existência de um ponto extra aumenta a visibilidade do produto e o expõe de maneira a ser encontrado mais facilmente pelo *shopper*.

Por ser de maior dificuldade de obtenção, essa variável só foi conseguida para a Família estudada. Assim como o caso anterior, essa também é uma *dummy variable* que assume valor 1 para a existência do ponto extra ou valor 0 para a ausência.

4) *Existência de Oferta*

Define-se a oferta todo e qualquer pacote promocional que oferece alguma vantagem especial para o consumidor que adquiri-lo. Podem-se citar como exemplos as embalagens do tipo “Leve X, Pague $(X - I)$ ”, “Leve X e ganhe $K\%$ de desconto” ou “Compre o produto Y e ganhe o produto Z”. Neste último caso é válido ressaltar que só é considera oferta do produto se ele for o “cavalo” da promoção, isto é, se ele for o produto Y da sentença.

Mais uma vez trata-se de uma variável binária, cujos dados históricos só foram obtidos para a Família I.

5) *Sazonalidade (dias da semana e semana do mês)*

Conforme já comprovado, os dados da Família I apresentam sazonalidade tanto nos dias da semana quanto nas semanas do mês. Já que elas explicam parte da demanda, essas variáveis também devem ser consideradas na análise e, para isso, assumem o formato binário.

Entretanto é necessária uma atenção especial: para o caso de sazonalidade, o modelo não deve incluir todos os períodos sazonais em seu equacionamento a fim de evitar a multicolinearidade. Assim, nos dias da semana, por exemplo, não se considera o domingo que passa a ser representado quando todas as demais variáveis assumem valor 0. O mesmo raciocínio é feito para a não colocação da quinta semana nos dados de semanas do mês.

6) Vendas Passadas

Por fim, outra variável escolhida para ser acrescentada ao modelo é a de vendas passadas que, conforme também já verificado, afetam o comportamento da demanda. Essa variável será testada de duas maneiras distintas: a primeira com defasagem de um dia, representando a explicação da demanda dadas as informações do dia anterior; e, a segunda com defasagem de sete dias, representando a explicação da demanda dadas as informações de uma semana antes. Tais variáveis foram nomeadas como Demanda (-1) e Demanda (-7), respectivamente.

Apresentadas todas as variáveis, é válido um resumo de quais delas estão disponíveis somente para a Família I da Marca A e, também, quais envolvem os principais produtos diretamente concorrentes – obviamente excluindo-se os dados de sazonalidade e vendas passadas, particulares da família estudada.

Tabela 6.7 – Variáveis independentes disponíveis

PRODUTO	PREÇO	ENCARTES	PONTO EXTRA	OFERTAS
Família I	X	X	X	X
Concorrente 1	X	X		
Concorrente 2	X	X		
Concorrente 3	X	X		
Concorrente 4	X	X		
Concorrente 5	X			
Concorrente 6	X	X		
Concorrente 7	X	X		

Todos os dados acima foram inicialmente levantados para o período desde março até novembro de 2008, datas nas quais foram encontrados históricos completos que pudessem fazer parte dessa análise. Com todas essas informações foram geradas 29 séries de dados a serem consideradas no modelo. Um trecho da tabela que contém essas séries é apresentada no Anexo II desse documento.

Assim, levando em consideração essa grande quantidade de dados necessária, a dificuldade de conseguir seus históricos e que a metodologia de aplicação da Regressão Linear Múltipla é a mesma para qualquer produto que se deseje estudar, essa é a única etapa desse trabalho que será realizado exclusivamente para a Família I da Marca A. Entretanto, por meio de sua explanação, o procedimento pode ser replicado posteriormente a qualquer Família de produtos da empresa.

Levantados os dados, é preciso selecionar quais das variáveis realmente serão consideradas no modelo. A partir dessa etapa até a obtenção da equação de Regressão Linear Múltipla o autor desse trabalho usufruiu-se do auxílio do *software* estatístico MINITAB.

Para a seleção das variáveis independentes, foi utilizada a função *stepwise forward-with-a-backward-look* do MINITAB. Porém, antes de iniciá-la foi necessário descobrir quais das variáveis disponíveis apresentavam grande relação com a demanda para que, assim, servissem de *starter* do processo.

Considerando esse fato, foi gerada a correlação entre todas as variáveis e estabeleceu-se que as duas de maior R^2 , quando comparadas com a demanda, fossem as escolhidas para iniciar a função *stepwise*. Além disso, nesse método, definiu-se como critério de entrada a apresentação de um *valor-P* menor do que 0,05 e como critério de saída a apresentação de um *valor-P* maior do que 0,05. Após a iteração de 10 passos, a função *stepwise* forneceu como saída 8 variáveis independentes que juntas forneciam o R^2 -ajustado mais adequado.

Selecionadas as variáveis, foi realizada a Regressão Linear Múltipla que, depois de completa, forneceu as seguintes saídas:

Tabela 6.8 – Características das variáveis independentes fornecidas pela Regressão Linear Múltipla

VARIÁVEL INDEPENDENTE	COEFICIENTE	VALOR-P	VIF
Constante	-396,40	0,039	-
Segunda-Feira	-205,85	0,000	1,058
Sábado	541,43	0,000	1,033
1ª Semana	202,62	0,000	1,254
Preço Concorrente 4	692,00	0,001	1,267
Encarte Família I	201,17	0,000	1,666
Encarte Concorrente 7	-149,29	0,001	1,794
Demanda (-1)	0,4863	0,000	1,329
Ponto Extra Família I	118,85	0,002	1,375

O *Variance Inflation Factor* (VIF) é o fator que mede o impacto da colinearidade entre as variáveis de um modelo de Regressão. Studenmund (2001) define que se o valor do VIF é maior do que 5, isso pode ser um sinal da existência de multicolinearidade, caso contrário, esse problema não existe. Observando a Tabela 6.8 percebe-se, portanto, que não há nenhuma correlação entre as variáveis independentes selecionadas. Caso algum item apresentasse valor de VIF superior a 5, ele deveria ser eliminado da amostra e o modelo precisaria ser rodado novamente.

Analisando ainda a tabela é possível verificar que os coeficientes apresentados se mostram coerentes com suas variáveis correspondentes. Pode-se verificar que a presença em encarte e a existência de ponto extra da Família I indicam uma alavancagem nas vendas, algo que realmente se percebe na prática. Além disso, o coeficiente definido para o preço do concorrente 4 sugere que quanto maior o seu preço, maior é a venda da Família I; e, quanto menor o seu preço, menos intensa é a venda da Família estudada. É interessante tal ocorrência, pois esse fato mostra que, apesar dos itens não serem concorrentes diretos, uma redução no preço do concorrente 4 (um produto mais *premium*) leva a alguns consumidores da Família I migrarem para ele. Em contrapartida, o preço do concorrente estando um pouco mais elevado do seu habitual, ocasiona a migração inversa. Por fim, o coeficiente de presença em encarte do concorrente 7 indica uma redução nas vendas da Família I, o que se mostra bastante consistente visto que eles são concorrentes mais diretos.

As demais variáveis escolhidas se relacionam à sazonalidade ou vendas passadas e também se mostram coerentes já que, por exemplo, o sábado apresenta um coeficiente bastante elevado significando aumento da demanda nesse dia. Apesar de já verificada a existência de sazonalidade entre os dias da semana, a variável Demanda (-7) não aparece no modelo. Sua exclusão pode ser justificada pela forte correlação entre ela e as variáveis dos dias da semana que apresentam formas de atuação semelhante.

Além dessas características, o modelo também forneceu a análise de variância.

Tabela 6.9 – ANOVA da Família I da Marca A

	GL	SQ	QM	F	P
Regressão	8	37.916.530	4.739.566	90,93	0,000
Resíduos	266	13.864.100	52.121		
Total	274	51.780.630			
		$R^2 = 73,2\%$		$R^2\text{-ajustado} = 72,4\%$	

Vendo tais resultados percebe-se um valor de F elevado e um *valor-P* bem abaixo de 0,05, indícios que comprovam a relevância da equação de regressão gerada. Além disso, o modelo possui um $R^2\text{-ajustado}$ igual a 72,4%, significando que as variáveis independentes consideradas no equacionamento explicam 72,4% do comportamento da demanda, o que se pode considerar um número bastante razoável.

Por fim, para a comprovação total do bom funcionamento desse modelo de regressão, deve-se verificar os pontos apontados por Makridakis, Wheelwright e Hyndman (1998) como muito importantes: a independência e a distribuição normal dos resíduos. Para tanto, gráficos foram gerados pelo MINITAB, conforme se visualiza abaixo.

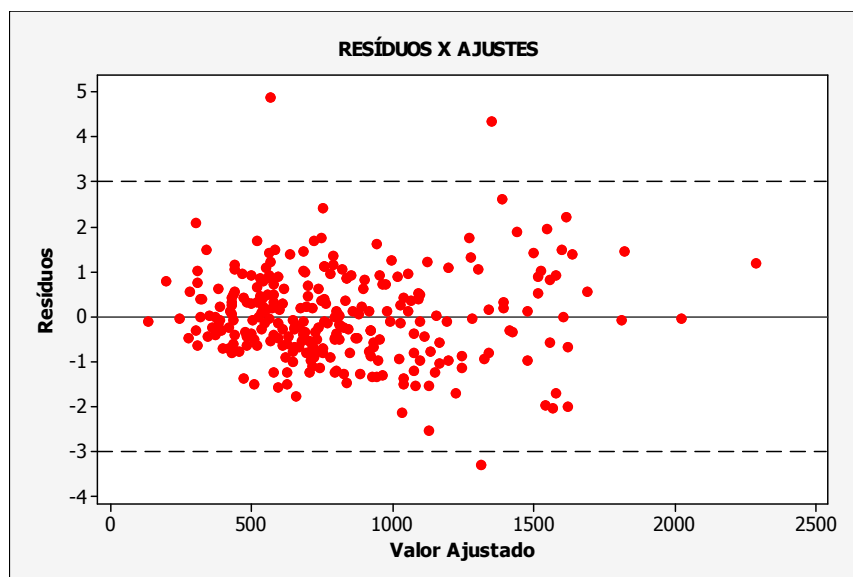


Figura 6.11 – Gráfico de resíduos da Família I da Marca A

Como o gráfico de distribuição dos resíduos não apresenta nenhuma tendência e os pontos estão alocados aleatoriamente em ambos os lados da linha horizontal, é possível concluir que a premissa de independência é respeitada. Vale ressaltar que a Figura 6.11 demonstra a presença de 3 *outliers* representados pelos pontos que excedem o limite de ± 3 .




Figura 6.12 – Gráfico de probabilidade normal para a Família I da Marca A

A Figura 6.12 demonstra que os resíduos estão muito próximos da linha que indica a distribuição normal dos mesmos, algo que pode ser comprovado pelo traçado da curva normal no histograma da Figura 6.13. Logo, a segunda premissa de comportamento dos resíduos também é respeita.




Figura 6.13 – Histograma da Família I da Marca A

Vale novamente destacar a identificação dos mesmos 3 *outliers* que visualmente se distanciam dos demais dados. Identificados esses *outliers* é necessário, como trabalho futuro, um aprofundamento na investigação dos mesmos para se tentar descobrir os motivos de seus comportamentos distintos.

Comprovada a relevância do modelo e tendo a equação de regressão em mãos, é chegado o momento de testar se a inclusão de tais informações no método desenvolvido de Suavização Exponencial com Sazonalidade, vai contribuir para com o aumento da precisão do mesmo, ou seja, vai reduzir o erro de previsão.

Para a realização da integração entre os dois modelos, devem ser levantados, primeiramente, os dados históricos, durante todo o período de testes do modelo de projeção, das variáveis consideradas na regressão.

Porém, antes de tal levantamento e do início dos cálculos de ajuste, é necessário verificar quais das variáveis independentes selecionadas serão realmente utilizadas nesse procedimento, já que o uso de algumas delas se mostra inadequado. Tais escolhas com os respectivos argumentos e os ajustes, são detalhados a seguir.

As variáveis referentes à sazonalidade e à venda passada não serão consideradas dado que essas condições já são naturalmente relevadas pelo modelo de projeção desenvolvido. Quanto à decisão para as demais variáveis, foi considerado como critério as suas capacidades de antecipação, sendo utilizadas apenas aquelas que podem ser previstas mais facilmente. Isso foi feito para verificar se o modelo criado já é adequado para uma implementação a curto prazo. Assim sendo, a variável preço do concorrente 4 será deixada de fora das análises já que sua previsão não é tão trivial. Portanto, devem ser levantados apenas os dados das outras três variáveis restantes.

Estando munido de tais informações, parte-se para o ajuste das previsões. O procedimento adotado foi o de adicionar o valor do coeficiente estimado para cada variável à previsão dos períodos em que foram constatadas as suas ocorrências. O encarte da Família I, o encarte do concorrente 7 e o ponto extra da Família I, apresentam coeficientes estimados de 201,17, -149,29 e 118,85, respectivamente. Para o exemplo de um período em que houve a ocorrência de um encarte para a Família I e, simultaneamente, um ponto extra para a Família I, o ajuste seria realizado através do cálculo: $(201,17 \cdot 1) + (-149,29 \cdot 0) + (118,85 \cdot 1) = 320,02$. Dessa forma, ao valor da previsão dessa data deveriam ser adicionadas 320 unidades.

Aplicando esse procedimento para todas as datas pertencentes ao período de testes do modelo de Suavização Exponencial com Sazonalidade e recalculando o valor do MAPE chega-se ao seguinte resultado:

Tabela 6.10 – Resultado do modelo integrado

	SUAVIZAÇÃO EXPONENCIAL COM SAZONALIDADE	MODELO INTEGRADO
MAPE	22,00%	18,16%

Observando a tabela acima, percebe-se que o desenvolvimento do modelo integrado reduziu o MAPE originalmente obtido. Apesar da medida final ainda não ser a ideal, comprovou-se aqui o funcionamento do modelo integrado e o atingimento do objetivo de redução do erro através de um maior conhecimento das variáveis que explicam a demanda.

Um melhor armazenamento dos dados e a inclusão de outras variáveis explicativas na regressão podem tornar a precisão ainda mais robusta. Logo, o modelo integrado pode ser considerado válido.

7. PROPOSTA DE IMPLEMENTAÇÃO

Após o desenvolvimento, testes e validação do modelo integrado de previsão para as Famílias de produtos da empresa em estudo, esse capítulo será destinado à apresentação da proposta de implementação desse modelo no dia-a-dia da companhia, destacando-se, principalmente, a ferramenta elaborada para a sua utilização e as adaptações que o processo atual de planejamento da demanda deverá sofrer.

7.1 A FERRAMENTA DE PREVISÃO

Seguindo a mesma lógica e ordem cronológica do desenvolvimento do modelo, serão propostas duas ferramentas de auxílio à previsão da demanda. A primeira delas é voltada à escolha da técnica mais adequada de previsão, enquanto a segunda, é destinada à realização da previsão integrada propriamente dita.

Ferramenta de Escolha

O objetivo dessa ferramenta – elaborada em *MS Excel* – é obter as informações iniciais do comportamento da demanda e fazer a comparação da precisão de todos os modelos de previsão, para que assim, seja selecionado aquele que se mostrar mais adequado. A Figura 7.1 apresenta o *layout* da tela menu dessa ferramenta.



Figura 7.1 – Tela menu da ferramenta de escolha do modelo de previsão

Na tela inicial, observa-se que a ferramenta: solicita a entrada dos dados diários de demanda referentes aos dois últimos anos; permite a visualização individual de cada modelo de previsão testado; e, ainda, disponibiliza uma visão resumida dos resultados alcançados nas simulações.

Almejando maior agilidade e menores esforços, essa planilha foi desenvolvida de forma que apenas a série histórica da demanda precise ser preenchida. Feito isso, todos os modelos se atualizam sozinhos com os dados. A única pendência restante é a necessidade de simulação dos parâmetros nos modelos de suavização exponencial para que sejam encontrados os menores erros. Isso é realizado nas áreas individuais de cada um desses modelos com apenas um clique, já que a busca pelo valor ótimo é previamente programada em VBA.

Realizadas as simulações, todos os modelos ficam corretamente atualizados, prontos para serem comparados. Para facilitar essa comparação, todos os resultados de precisão são consolidados em um único lugar onde, também, encontram-se os gráficos de autocorrelação (que indicam a presença, ou não, de sazonalidade nos dados) e de tendência. Tendo todas essas informações juntas, fica mais fácil realizar a seleção.

As Figuras 7.2 e 7.3 apresentam, respectivamente, a tela individual do modelo de Suavização Exponencial com Sazonalidade, utilizado como exemplo, e a tela do resumo dos principais resultados gerados.

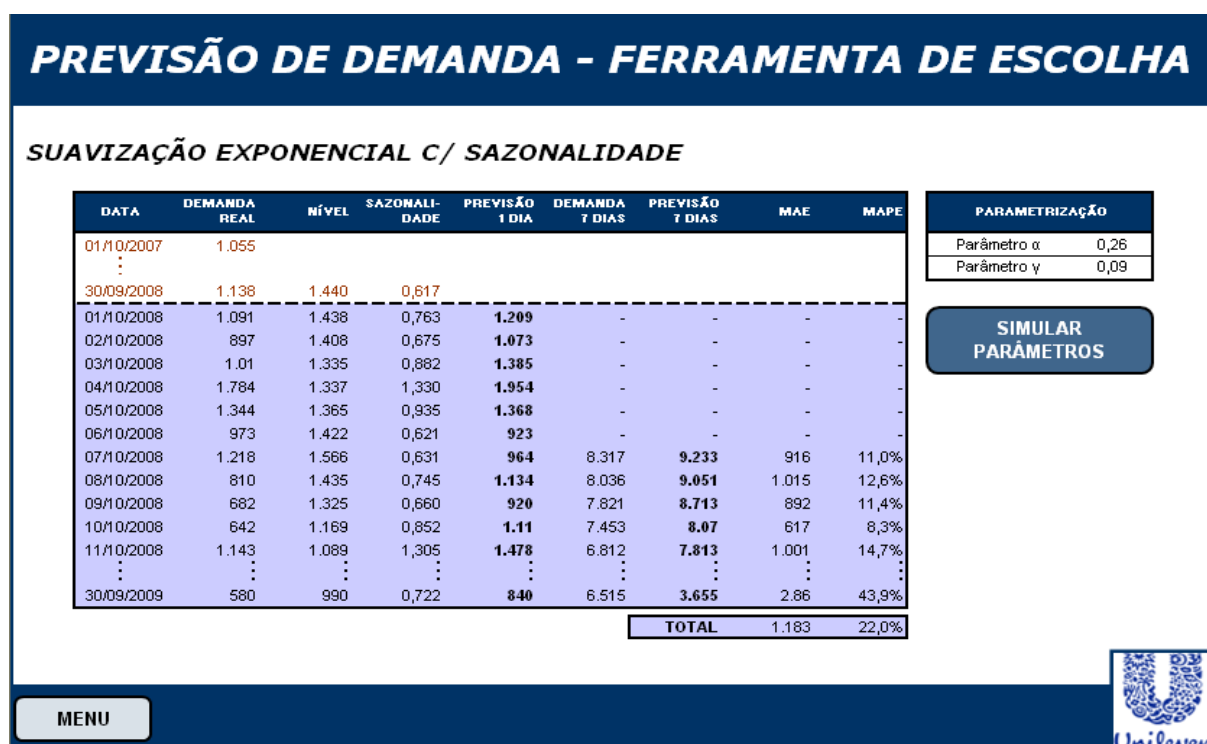


Figura 7.2 – Tela do modelo de Suavização Exponencial com Sazonalidade




Figura 7.3 – Tela do resumo de resultados

Ferramenta de Previsão Integrada

Após a utilização da ferramenta anterior e consequente escolha do modelo mais adequado, deve-se iniciar o processo de previsão integrada. Para isso, foi criada uma outra ferramenta.

PREVISÃO INTEGRADA DA DEMANDA

30/09/2009 Walmart

MARCA A

ATUALIZAR A DEMANDA REAL

FAMÍLIA I

INSERIR VARIÁVEIS EXPLICATIVAS

INSERIR COEFICIENTES DE REGRESSÃO

PREVISÃO DE DEMANDA

FAMÍLIA II

INSERIR VARIÁVEIS EXPLICATIVAS

INSERIR COEFICIENTES DE REGRESSÃO

PREVISÃO DE DEMANDA

FAMÍLIA III

INSERIR VARIÁVEIS EXPLICATIVAS

INSERIR COEFICIENTES DE REGRESSÃO

PREVISÃO DE DEMANDA

Figura 7.4 – Tela menu da ferramenta de previsão integrada da demanda

Também elaborada no *software MS Excel* essa segunda ferramenta antecipa a demanda por meio do método escolhido, já inserindo nas suas previsões os ajustes ocasionados devido às variáveis explicativas. Por esse motivo, nessa etapa há a necessidade de se trabalhar paralelamente com o *software MINITAB*.

Como pode ser visto na Figura 7.4 a ferramenta inicialmente necessita da atualização da demanda real; da inclusão dos coeficientes da equação de regressão (fornecidos pelo MINITAB); e, também, da indicação de existência ou não das variáveis explicativas mais relevantes. Inseridas essas informações, o cálculo da previsão é automático, dado que os parâmetros ótimos já foram escolhidos na etapa anterior.

No desenvolvimento da ferramenta decidiu-se que a mesma armazenaria um histórico de apenas dois meses de previsão para que fosse possível uma melhor visualização da evolução do erro total do modelo.

A Figura 7.5 mostra a tela referente à previsão integrada, que funciona da seguinte maneira: a cada atualização da demanda real, um novo valor é alocado no espaço em branco da planilha de previsão, ocasionando o cálculo automático de todos os demais campos. Os coeficientes de regressão e as informações da presença de determinada variável explicativa, exigidos no menu da ferramenta, são compilados e utilizados automaticamente no valor do campo “Ajuste” que, por sua vez, incrementa a previsão e integra o modelo causal com o modelo de projeção.

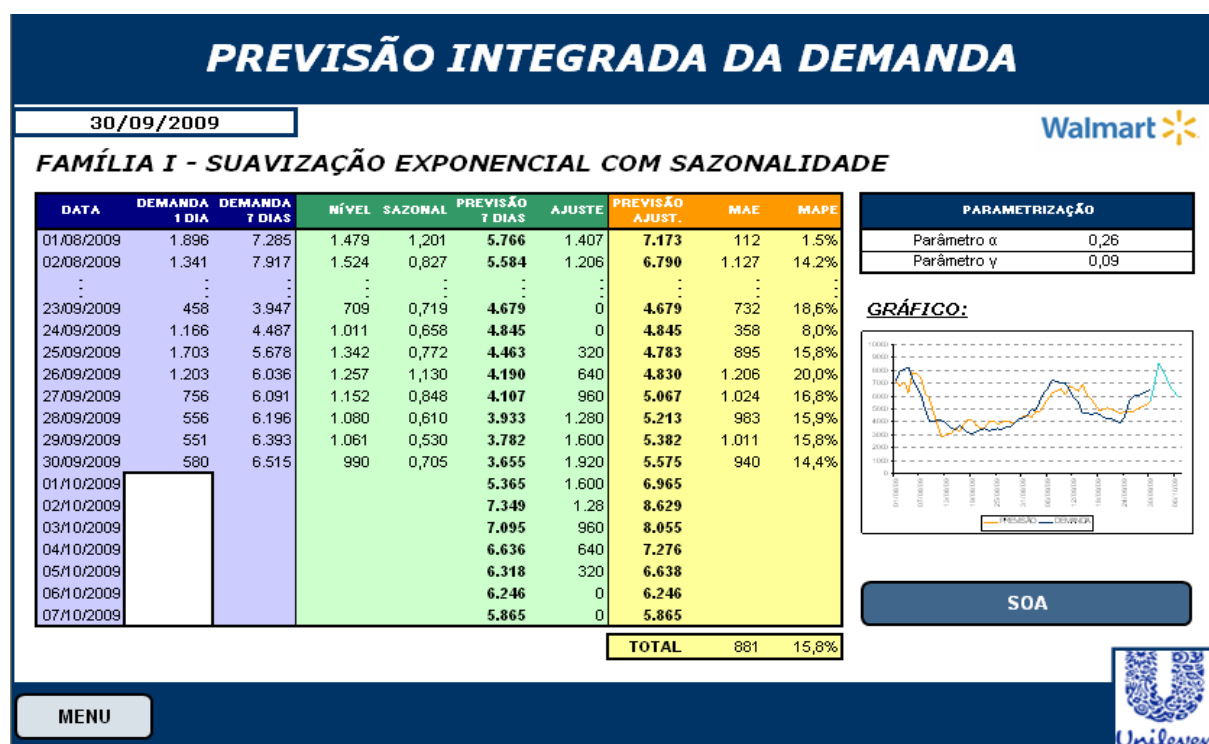


Figura 7.5 – Tela do modelo integrado de previsão da demanda

Para deixar mais claro e evitar confusões, é válido comentar que considerando o horizonte de previsão de sete dias, a previsão realizada no dia 23/09/2009 para os próximos sete dias, por exemplo, é apresentada no campo do dia 30/09/2009. Isso acontece, pois somente quando é atingida essa data, são possíveis a comparação com a demanda real e o cálculo do erro.

Percebe-se, portanto, que as ferramentas elaboradas são simples, intuitivas e de fácil manuseio e, por isso, não exigem muito treinamento para sua utilização.

7.2 PROPOSTA DE ADAPTAÇÃO DO PROCESSO DE PLANEJAMENTO

Concluído o desenvolvimento do modelo integrado de previsão da demanda, resta apenas explicitar como se dará o seu uso efetivo. Como já foi abordado no capítulo anterior, o modelo desenhado se contextualiza na fase de planejamento de curtíssimo prazo e acaba, de certa forma, atuando na frequente revisão do OP. Assim sendo, é necessário o desenho de um novo processo que integrará o planejamento da demanda, adaptando-o para essa nova realidade.

Esse novo cenário propõe a participação ativa de quatro áreas principais: *Supply Chain*, Planejamento, Comercial e Marketing.

O departamento de Marketing deve enviar ao setor comercial todas as informações a respeito de promoções, ofertas e propagandas pretendidas para cada Família de Produtos. Por esses serem dados normalmente planejados com certa antecedência, esse envio de informações não precisa ser tão frequente quanto serão as previsões, podendo-se estabelecer, por exemplo, o envio mensal.

A área Comercial ao receber tal material deve consolidá-lo junto às informações relevantes definidas por ela mesma, tais como, implantação de pontos extras e presença em encartes. Munidos desses dados e conseguindo, via sistema do varejista, as informações históricas de venda (que devem ser transformadas em demanda – vide Seção 6.3), a área Comercial está apta para realizar a previsão da demanda por meio do modelo integrado criado.

Tendo em mãos os resultados da previsão para os próximos sete dias, o setor de vendas deve encaminhá-los para a área de Planejamento. Esta, por sua vez, é responsável por receber esses dados e cruzá-los com as informações fornecidas pela área de *Supply* a respeito dos níveis de estoque da Unilever e das condições de abastecimento. Cria-se, assim, uma previsão consolidada que será base para a reunião de consenso, o próximo passo desse processo.

A reunião de consenso visa reunir as áreas de *Supply*, de Planejamento e Comercial para validar se a previsão consolidada faz sentido e, eventualmente, fazer intervenções de cunho mais qualitativo. O resultado desse encontro é a previsão de demanda aprovada.

Sabendo dessa última informação, o setor de vendas deve cruzar os valores estimados de demanda com os valores atuais de estoques nas lojas do Wal-Mart. Se nessa comparação for diagnosticado que não há necessidade de abastecimento das lojas, o processo se finaliza; caso contrário, deve-se providenciar uma reunião de consenso com o varejista.

Essa reunião vem de acordo com as práticas de compartilhamento de informações para uma boa tomada de decisão, sugeridas pela CPFR. Nesse encontro o fornecedor deve demonstrar para o varejista qual é a situação dos estoques de determinadas famílias *versus* a demanda prevista para as mesmas. O objetivo dessa etapa é atingir um consenso entre ambas as partes, resultando em uma decisão de abastecimento corretamente tomada.

Sugere-se que esse processo seja realizado pela empresa a cada dois dias e de preferência às segundas, quartas e sextas-feiras. Isso se justifica, pois, caso sejam tomadas decisões de abastecimento, essas datas são ideais para uma rápida solicitação do varejista, já que o mesmo realiza seus pedidos, geralmente, às terças, quintas e sábados.

A Figura 7.6 apresenta de maneira simplificada o desenho do novo processo acima descrito, com cada uma de suas etapas e, respectivos, participantes.

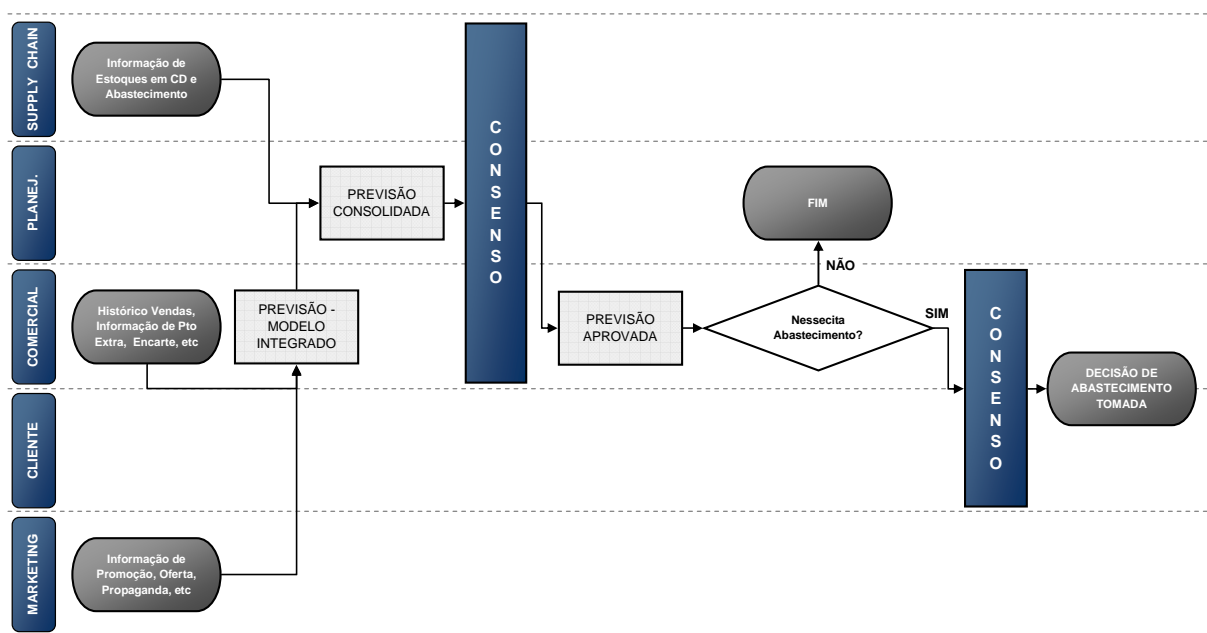


Figura 7.6 – Proposta do novo processo no Planejamento da demanda

8. CONCLUSÃO

Este capítulo é destinado às considerações finais de todo o estudo desenvolvido. Inicialmente será realizada uma abordagem resumida dos resultados, destacando-se, também, o problema diagnosticado e a solução proposta. Na sequência, para selar o encerramento desse projeto, serão apresentadas algumas sugestões e conselhos que devem ser seguidos para a continuação e o aperfeiçoamento do trabalho.

8.1 SÍNTESE E CONSIDERAÇÕES FINAIS

Dado o ambiente extremamente acirrado instaurado nos dias de hoje, buscar diferenciais para se sobressair perante os concorrentes tornou-se um hábito entre as grandes empresas de bens de consumo. A aproximação entre fornecedores e varejistas no desejo de satisfazer suas estratégias competitivas, bem como, as necessidades do consumidor final, os fazem caminhar em direção ao alinhamento estratégico. Atingindo este, a cadeia de suprimentos conquista uma enorme vantagem competitiva sobre todas as demais.

Na busca por esse cenário, o principal problema identificado na cadeia em estudo foi a frequente ocorrência da ruptura de gôndolas. A indisponibilidade ou insuficiência de produtos nas lojas, além de significar uma oportunidade de venda perdida e irrecuperável, pode implicar na perda definitiva do cliente para um produto ou loja concorrente. Logo, percebe-se que o fato impacta negativamente não somente o fornecedor dos bens de consumo, mas também, o varejista da cadeia.

Identificou-se como um dos principais motivos para a questão acima, a ocorrência de erros de decisão de abastecimento geralmente causados devido ao dilema da cadeia entre responsividade e eficiência. Dessa maneira, foi proposta a implementação de um modelo integrado de previsão de demanda, a ser utilizado pelo fornecedor e compartilhado com o varejista, seguindo a lógica de um sistema de parceria. Esse modelo é baseado em técnicas mais formais de previsão, atualmente inexistentes na empresa, utilizando-se de métodos quantitativos de projeção e de explicação.

O modelo primeiramente realiza a previsão de demanda através da projeção de séries temporais históricas. Na sequência, é realizada uma análise causal com o intuito de se identificar quais são as variáveis que mais impactam o comportamento da demanda. Feito isso, todas as informações resultantes das duas etapas são integradas, chegando-se a um resultado com maior precisão.

Para uma melhor aderência do modelo dada a necessidade diagnosticada, optou-se por trabalhar com um horizonte de previsão de sete dias e um nível agregado de família de produtos, que nada mais é do que o conjunto de SKU's que possuem os mesmos atributos e preços, diferindo-se apenas quanto as suas variantes. Após a realização da previsão, os valores obtidos devem ser distribuídos entre os componentes dessa família considerando as respectivas representatividades. Chega-se, assim, a uma antecipação em nível de item.

O resultado atingido com a aplicação do modelo de projeção e a melhoria de sua precisão em 17,5% após a integração dele com as informações obtidas pelo método causal, mostram que o modelo é pertinente e pode ser perfeitamente utilizado para atender as necessidades diagnosticadas. Apesar de o erro final ser ainda um pouco elevado, há diversas oportunidades de aprofundamento caso estejam disponíveis mais dados históricos para a avaliação causal e todas as informações sejam armazenadas de forma confiável e correta.

Além disso, a metodologia de transformação do histórico de venda em histórico de demanda, criada pelo autor, apresenta incertezas que não foram consideradas e que podem ter influenciado na medição do erro final. Portanto, o aperfeiçoamento dessa técnica de conversão e a obtenção de dados mais certos sobre o histórico de demanda, podem auxiliar bastante na melhoria da precisão do modelo. Percebe-se, portanto, que qualquer imperfeição nos dados históricos pode distorcer o resultado, tornando-o menos preciso do que se esperaria.

Contornada a questão de imprecisão, torna-se evidente que com as informações a respeito do comportamento e antecipação da demanda, fica mais fácil de se desenvolver um modelo de abastecimento dos estoques que implique em melhores decisões de reposição. Com isso, consegue-se melhorar a disponibilidade dos produtos e manter o nível apenas necessário de estoques, não prejudicando a eficiência.

Para o encaixe desse novo modelo nas atividades de planejamento da demanda da empresa, foi necessária a criação de um novo processo que envolve, principalmente, as áreas de Marketing, Planejamento, *Supply Chain*, Comercial e, ao final, também o cliente. Implementado corretamente, o modelo propicia condições muito favoráveis para uma decisão de abastecimento mais correta da que vem sido tomada.

Apesar da consistência do modelo, pode-se dizer que uma limitação apresentada é o fato da sua complexidade ser superior à do processo atualmente utilizado. A grande quantidade de produtos com que a empresa trabalha implicaria em diversas simulações que deveriam ser realizadas com bastante frequência. Além disso, o novo processo proposto necessitaria de

uma atenção e dedicação dos seus participantes já que ele sugere uma interação constante entre diferentes áreas. Assim sendo, muito provavelmente o quadro de funcionários deveria ser expandido para permitir um correto funcionamento do modelo, o que implica em um aumento de custos para a empresa.

Por esse motivo seria interessante uma análise cuidadosa em torno do custo-benefício desse novo método. Algo não tão trivial, dado que é complicado mensurar previamente os efetivos benefícios que o modelo de previsão vai trazer.

8.2 DESDOBRAMENTOS

Para que a previsão de demanda seja realizada de forma efetiva e traga benefícios palpáveis para a melhoria do abastecimento do varejo é necessária a implementação de toda metodologia explicitada nesse trabalho, bem como, do novo processo proposto. Além disso, sugere-se aqui que algumas adaptações também sejam realizadas nos atuais processos que, se mantidos, impedem o modelo de operar da maneira esperada.

A primeira proposta de mudança está relacionada ao fato dos vendedores serem cobrados por tonelagem de vendas, sem vínculos diretos às categorias. Continuando com essa atitude, o hábito de querer “empurrar” para o varejista o máximo de itens para atingir a meta vai continuar. O ideal é que a cobrança passe a ser realizada ao nível de família e de forma coerente às previsões realizadas, trabalhando-se para atender essa demanda corretamente. Tendo o valor antecipado da demanda também é possível avaliar se o número previsto está muito abaixo do que se era desejado para o crescimento traçado no AP e permite que ações comerciais sejam previamente planejadas, já se estimando o impacto, em quantidades vendidas, que as mesmas provavelmente vão causar.

Para que o modelo seja cada vez mais preciso, é necessário se instaurar na companhia uma política de armazenamento confiável dos dados históricos que servem de base para as próximas previsões. Ter corretamente as informações de demanda e de ações comerciais, ou de merchandising, são fundamentais para viabilizar a escolha e o desenvolvimento do modelo integrado.

Depois dessa elaboração, torna-se muito importante antecipar a realização das ações para que tais variáveis explicativas possam ajustar previamente os cálculos da previsão e possibilitem um resultado ainda mais condizente com a realidade.

Por fim faz-se necessário a elaboração de um modelo ativo de gestão de estoques com base nas previsões de demanda. Esse modelo deve seguir os conceitos explicitados no Capítulo 5 desse documento e tem seu desenvolvimento mais facilitado com os dados de previsão já em mãos. Uma sugestão muito relevante é que esse modelo seja desenvolvido não apenas considerando a previsão da demanda, mas também, levando em conta a estratégia de visibilidade da empresa que exige a presença de um número mínimo de itens na gôndola para inibir a presença de buracos nas prateleiras e chamar mais a atenção do consumidor no momento da sua compra.

Alinhando-se a esse ponto, é interessante que o modelo considere na sua decisão de pedidos a realização de pontos extras. A cada confirmação da implementação de algum, deve ser incrementada ao pedido uma quantidade adicional exclusivamente para montar o ponto extra com a visibilidade exigida e a estocagem definida.

Feitos tais apontamentos, chega-se aqui ao fim desse estudo. Pode-se considerar que os resultados e propostas efetuados são consistentes e, se bem desenvolvidos pela empresa fornecedora em parceria com o varejista, trarão benefícios palpáveis para uma melhor decisão de abastecimento das lojas e propiciarão o alinhamento estratégico que dará, para essa cadeia, maior destaque e vantagem sobre as demais.

REFERÊNCIAS BIBLIOGRÁFICAS

AC NIELSEN. **Ruptura: causas e impactos na cadeia de abastecimento e no comportamento do consumidor.** São Paulo, 2004.

ALVIM, A.C. **Previsão de demanda no varejo.** – Trabalho de Formatura. Departamento de Engenharia de Produção da Escola Politécnica da USP. São Paulo: EPUSP, 2003.

BALLOU, R.H. **Gerenciamento da cadeia de suprimentos: planejamento, organização e logística empresarial.** 4^a ed. Porto Alegre: Bookman, 2003.

CARVALHO, J.M.C.; DIAS, E.B. **E-logistics e e-business.** Lisboa: Sílabo, 2000.

CHOPRA, S.; MEINDL, P. **Gerenciamento da cadeia de suprimentos: estratégia, planejamento e operação.** São Paulo: Prentice Hall, 2004.

CORRÊA, H.L.; CORRÊA, C.A. **Administração de produção e operações: manufatura e serviços: uma abordagem estratégica.** 2^a ed. São Paulo: Atlas, 2009.

ECR BRASIL. **Reposição eficiente.** São Paulo, 2000.

HANKE, J.E.; REITSCH, A.G. **Business forecasting.** 6th ed. Upper Saddle River: Prentice Hall, 1998

ISHII, P.A. **Estudo do comportamento das vendas em uma empresa de sorvetes.** – Trabalho de Formatura. Departamento de Engenharia de Produção da Escola Politécnica da USP. São Paulo: EPUSP, 2005.

LATIN PANEL. **Revista abastecimento.** São Paulo, 2009.

MAKRIDAKIS, S.; WHEELWRIGHT, S.C.; HYNDMAN, R.J. **Forecasting: methods and applications.** 3rd ed. New York: John Wiley & Sons, 1998.

O'DONOVAN, T.M. **Short term forecasting: an introduction to the Box-Jenkins approach.** 1st ed. New York: John Wiley & Sons, 1983.

SANTORO, M.C. **Planejamento, Programação e Controle da Produção.** – Apostila da Disciplina PRO 2415. Departamento de Engenharia de Produção da Escola Politécnica da USP. São Paulo: EPUSP, 2009.

SANTORO, M.C.; FREIRE, G. **Análise comparativa entre modelos de estoque.** – Revista Produção, vol.18, no.1. São Paulo, 2008.

STUDENMUND, A.H. **Using econometrics: a practical guide.** New York: Addison Wesley Logman, 2001.

VOLUNTARY INTERINDUSTRY COMMERCE STANDARDS (VICS) ASSOCIATION
Overview: Collaborative Planning, Forecasting and Replenishment (CPFR), 2004.
Disponível em <www.vics.org/committees/cpfr> Acesso em 18 de julho, 2009.

WHEELWRIGHT, S.C.; MAKRIDAKIS, S. **Forecasting methods for management.** 2nd ed.
New York: John Wiley & Sons, 1980.

ANEXOS

I. RESULTADOS E ANÁLISES SUCINTAS DAS FAMÍLIAS II E III

Serão expostos aqui todos os gráficos e informações a respeito das Famílias II e III das Marcas B e C, utilizados como base para a aplicação da mesma metodologia apresentada no corpo desse documento. Os resultados dos procedimentos também são sucintamente explicitados, conforme pode-se observar a seguir.

Família II da Marca B




Figura A.1 – Curva de demanda diária da Família II da Marca B




Figura A.2 – Curva de demanda semanal da Família II da Marca B

Tabela A.1 – Participação da demanda por dia da semana e semana do mês

DIA DA SEMANA	SEMANA DO MÊS					TOTAL
	1ª SEM	2ª SEM	3ª SEM	4ª SEM	5ª SEM	
DOM	4,78%	4,02%	3,28%	3,12%	1,46%	16,66%
SEG	3,50%	2,77%	2,32%	2,19%	1,08%	11,87%
TER	3,10%	2,41%	2,27%	1,94%	1,33%	11,06%
QUA	3,53%	2,77%	2,57%	2,51%	1,37%	12,76%
QUI	3,02%	2,48%	2,32%	2,39%	1,07%	11,28%
SEX	4,24%	3,27%	2,56%	3,02%	0,98%	14,07%
SÁB	6,23%	5,50%	4,37%	4,13%	2,08%	22,31%
TOTAL	28,40%	23,22%	19,70%	19,31%	9,38%	100,00%




Figura A.3 – Correlograma da demanda diária da Família II da Marca B




Figura A.4 – Correlograma da demanda semanal da Família II da Marca B




Figura A.5 – Linha de tendência da Família II da Marca B

Observando todos os dados acima apresentados percebe-se que a demanda da Família II da Marca B apresenta um comportamento sazonal entre os dias da semana e as semanas do mês e é de tendência constante, já que o valor de R^2 é bastante baixo e pode ser considerado desprezível. Dessa maneira, desconfia-se que o modelo de Suavização Exponencial com Sazonalidade é o mais adequado para a série. Entretanto, para se ter certeza é necessária a simulação de todos os métodos para a avaliação das precisões.

Tabela A.2 – Erros obtidos com os diferentes modelos de previsão

MODELO DE PREVISÃO	MAE	MAPE
Média Simples	957,63	26,78%
Média Móvel (k = 07 dias)	881,91	24,41%
Média Móvel (k = 14 dias)	985,96	28,14%
Média Móvel (k = 21 dias)	922,92	26,26%
Média Móvel (k = 28 dias)	803,10	22,45%
Média Móvel (k = 35 dias)	856,09	23,82%
Suavização Exponencial Simples	764,35	21,22%
Suavização Exponencial com Tendência	821,16	22,48%
Suavização Exponencial com Sazonalidade	703,12	19,33%
Método Holt-Winters	759,27	20,83%

A tabela acima demonstra que o modelo de Suavização Exponencial com Sazonalidade é o que apresenta, dentre todos, o menor erro e, portanto, foi o selecionado, confirmando as expectativas. Abaixo seguem os gráficos que cruzam as curvas de previsão e de dados reais durante todo o período de testes do modelo escolhido.

➤ Suavização Exponencial com Sazonalidade




Figura A.6 – Curva de previsão X Curva real (Horizonte de Previsão de 1 dia)




Figura A.7 – Curva de previsão X Curva real (Horizonte de Previsão de 7 dias)

Tabela A.3 – Principais resultados do modelo escolhido

SUAVIZAÇÃO EXPONENCIAL COM SAZONALIDADE	
Parâmetro α	0,00
Parâmetro γ	0,08
MAPE	19,33%

Família III da Marca C




Figura A.8 – Curva de demanda diária da Família III da Marca C




Figura A.9 – Curva de demanda semanal da Família III da Marca C

Tabela A.4 – Participação da demanda por dia da semana e semana do mês

DIA DA SEMANA	SEMANA DO MÊS					TOTAL
	1ª SEM	2ª SEM	3ª SEM	4ª SEM	5ª SEM	
DOM	4,03%	3,60%	3,05%	2,73%	1,47%	14,87%
SEG	3,24%	2,62%	2,04%	1,97%	1,10%	10,97%
TER	3,00%	2,41%	2,22%	1,91%	1,27%	10,81%
QUA	4,09%	2,98%	3,03%	2,65%	1,52%	14,28%
QUI	3,47%	2,76%	2,63%	2,51%	1,21%	12,56%
SEX	4,20%	3,02%	2,72%	3,30%	1,23%	14,46%
SÁB	6,43%	4,97%	4,30%	4,26%	2,10%	22,05%
TOTAL	28,45%	22,36%	19,98%	19,32%	9,90%	100,00%




Figura A.10 – Correlograma da demanda diária da Família III da Marca C




Figura A.11 – Correlograma da demanda semanal da Família III da Marca C




Figura A.12 – Linha de tendência da Família III da Marca C

Observando todos os dados acima apresentados, percebe-se que a demanda da Família III da Marca C apresenta um comportamento sazonal entre os dias da semana e as semanas do mês e uma tendência de crescimento, já que o valor de R^2 é mais relevante e não pode ser desprezado. Dessa maneira, desconfia-se que o modelo de Suavização Exponencial com Sazonalidade e Tendência (Holt-Winters) é o mais adequado para a série. Entretanto, para se ter certeza é necessária a simulação de todos os métodos para a avaliação das precisões.

Tabela A.5 – Erros obtidos com os diferentes modelos de previsão

MODELO DE PREVISÃO	MAE	MAPE
Média Simples	769,36	28,33%
Média Móvel (k = 07 dias)	760,22	27,29%
Média Móvel (k = 14 dias)	820,01	30,13%
Média Móvel (k = 21 dias)	753,33	27,86%
Média Móvel (k = 28 dias)	632,49	23,51%
Média Móvel (k = 35 dias)	656,89	24,56%
Suavização Exponencial Simples	585,84	21,25%
Suavização Exponencial com Tendência	591,58	22,58%
Suavização Exponencial com Sazonalidade	581,79	22,25%
Método Holt-Winters	551,47	19,05%

A tabela acima demonstra que o Método Holt-Winters é o que apresenta, dentre todos, o menor erro e, portanto, foi o selecionado, confirmando as expectativas. Abaixo seguem os gráficos que cruzam as curvas de previsão e de dados reais durante todo o período de testes do modelo escolhido.

➤ Método Holt-Winters




Figura A.13 – Curva de previsão X Curva real (Horizonte de Previsão de 1 dia)




Figura A.14 – Curva de previsão X Curva real (Horizonte de Previsão de 7 dias)

Tabela A.6 – Principais resultados do modelo escolhido

MÉTODO HOLT-WINTERS	
Parâmetro α	0,02
Parâmetro β	0,02
Parâmetro γ	0,04
MAPE	19,05%

