

SOLENE NATHALIE LE CAM

**MODELO DE DECISÃO DE SUPRIMENTO
DE BENS DE CONSUMO PERECÍVEIS NO VAREJO
BASEADO NA PREVISÃO DE DEMANDA**

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

**São Paulo
2009**

SOLENE NATHALIE LE CAM

**MODELO DE DECISÃO DE SUPRIMENTO
DE BENS DE CONSUMO PERECÍVEIS NO VAREJO
BASEADO NA PREVISÃO DE DEMANDA**

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

Le Cam, Solene Nathalie

Modelo de decisão de suprimento de bens de consumo perecíveis no varejo baseado na previsão de demanda / S.N. Le Cam.

-- São Paulo, 2009.

109 p.

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

1. Previsão (Análise de séries temporais) 2. Demanda (Previsão) 3. Administração de estoques 4. Laticínios 5. Varejo I. Universidade de São Paulo. Escola Politécnica. Departamento de Engenharia de Produção II. t.

AGRADECIMENTOS

Aos meus pais, Patrick e Régine, que sempre me incentivaram a estudar, me deram todas as condições para que eu freqüentasse os melhores estabelecimentos, me apoiaram e tiveram confiança em meus projetos. E às minhas irmãs, Audrey e Gaëlle, por todo o apoio, amizade e carinho.

Ao meu noivo Guilherme, politécnico admirável que teve significativa influencia na escolha do meu “projeto brasileiro”, por sempre me apoiar, estar do meu lado e confiar em mim. À minha sogra, Priscila, por todo o carinho e paciência que teve durante a finalização do trabalho. Obrigada a vocês dois por todo o esforço e tempo passado na correção do meu português!

Ao professor Miguel Santoro pelas horas dedicadas, paciência e atenção dispensadas ao longo do ano. Obrigada pela confiança depositada, pela receptividade e pelo bom humor contagioso!

Agradeço profundamente aos meus amigos da Poli e da Centrale Lille e especialmente a minha “família franco-brasileira” (Amanda, Alexandre, Arthur, Benoît, Diego, Mika, Stéphanie, Vinicius e afiliados), que sempre foi uma referência e um apoio ao longo desses anos de faculdades na França e no Brasil.

Às minhas amigas francesas, e especialmente à Marie, que conseguiram me apoiar a distância nas horas mais difíceis da expatriação.

Ao pessoal da Danone por proporcionar uma excelente experiência profissional num ambiente de trabalho agradável.

Enfim, agradeço a todos que de alguma forma colaboraram, seja lá, seja aqui...

RESUMO

O presente trabalho teve seu foco na criação de um modelo de decisão de suprimento baseado na previsão de demanda, a ser usado pelos promotores da Danone na elaboração dos pedidos de produtos lácteos frescos em uma rede varejista. O objetivo é melhorar a disponibilidade dos produtos na gôndola, sem criar excessos de mercadoria estocada.

O problema dos erros de previsão de demanda foi identificado como a principal causa de ruptura no varejo. Por isso, estudou-se o comportamento da demanda e, a partir das características observadas, avaliaram-se dois modelos de previsão de demanda. O modelo de Decomposição Clássica se destacou como o de maior desempenho na maioria dos casos. Para a reposição dos estoques, foi utilizado o modelo de Cálculo de Necessidades e definidos dois indicadores de desempenho, um medindo a disponibilidade dos produtos na gôndola e o outro a cobertura média de estoques. Através de simulações, mostramos que o modelo de decisão construído apresenta um desempenho superior ao sistema atual em 98% dos casos testados e, contrariamente à situação atual, permite atingir as metas para ambos os indicadores de nível de serviço.

Palavras-chave: Previsão de Demanda. Gestão de Estoques. Modelo de Apoio a Decisão. Produtos Perecíveis. Varejo.

ABSTRACT

The current work focused on creating a supply decision model based on demand forecast, to be used by the Danone promoters to prepare orders of Fresh Dairy Products for a retailer. The objective is to improve product shelf availability, without excessive inventory.

Error in the demand forecasting was identified as the main stockout cause in retailers. Therefore, the demand behaviour was studied and with the help of the main observed characteristics, two demand forecast methods were assed. The Classical Decomposition method stood out as having the best performance for most cases. For inventory replenishment, the Requirements Planning model was used, and two performance indicators were defined, the first measuring the product shelf availability and the other the mean inventory coverage. Through the use of simulations, we've observed that the built decision model over performed the actual system in 98% of the tests and, in opposition to the actual situation, it allowed both service level indicators to attain their targets.

Keywords: Demand Forecasting. Inventory Management. Decision Support Model. Perishable Products. Retailer.

LISTA DE FIGURAS

<i>Figura 1-1: Malha logística da Danone no Brasil</i>	16
<i>Figura 1-2: Market Share (em valor) do segmento de produtos lácteos frescos (elaborada a partir de dados do instituto ACNielsen, 2008)</i>	16
<i>Figura 1-3: Market Share (em volume) do segmento de produtos lácteos frescos (elaborada a partir de dados do instituto ACNielsen, 2008).....</i>	17
<i>Figura 1-4: Perfil econômico do comprador de produtos lácteos frescos (% em vendas) (Danone – Guia de Categorias 2008).....</i>	17
<i>Figura 1-5: Organograma do departamento de Supply Chain</i>	18
<i>Figura 2-1: Importância das dimensões de serviço segundo os varejistas do Brasil inteiro (ILOS, 2009).....</i>	21
<i>Figura 2-2: Importância das dimensões segundo os varejistas do Sul do Brasil (ILOS, 2009).....</i>	21
<i>Figura 2-3: Melhores fornecedores em Disponibilidade de Produtos segundo os varejistas (ILOS, 2009).....</i>	22
<i>Figura 2-4: Comportamento do consumidor brasileiro diante da ruptura do produto desejado (AC Nielsen, 2004).....</i>	23
<i>Figura 2-5: Fluxograma do ciclo do pedido, da elaboração à alocação.....</i>	25
<i>Figura 2-6: Fluxograma do ciclo do pedido, da roteirização à entrega.....</i>	26
<i>Figura 2-7: Causas raízes das rupturas identificadas</i>	29
<i>Figura 2-8: Trade-offs na decisão das quantidades a pedir</i>	30
<i>Figura 3-1: Fluxograma do método de análise do comportamento de uma série temporal (adaptado de Makridakis e Wheelwright, 1978).....</i>	38
<i>Figura 4-1: Componentes de um sistema de gestão de estoques (adaptado de Santoro, 2006).....</i>	53
<i>Figura 4-2: Determinação do ponto de pedido</i>	55
<i>Figura 4-3: Esquema de decisão do Modelo de Cálculo de Necessidades (extraído de Santoro, 2006)</i>	57
<i>Figura 5-1: Divisão geográfica das lojas.....</i>	60
<i>Figura 5-2: Divisão das lojas por tipo de distribuição</i>	61
<i>Figura 5-3: Divisão das lojas por bandeira.....</i>	61
<i>Figura 5-4: Divisão das lojas por volume de venda.....</i>	62
<i>Figura 5-5: Divisão das lojas por nível de índice de ruptura</i>	62
<i>Figura 5-6: Produtos da marca Activia</i>	64
<i>Figura 5-7: Produtos da marca Danoninho</i>	64
<i>Figura 5-8: Produtos da família Corpus.....</i>	65
<i>Figura 5-9: Produtos da família Actimel.....</i>	65
<i>Figura 5-10: Produtos da marca Danette</i>	66
<i>Figura 5-11: Produtos da marca Danito.....</i>	66
<i>Figura 5-12: Produtos da marca Dan'up.....</i>	66
<i>Figura 5-13: Ciclo de vida do produto (adaptado de Slack; Chambers e Johnston, 2008).....</i>	67
<i>Figura 6-1: Regra de correção das vendas com a avaliação de faltas</i>	72
<i>Figura 6-2: Demanda do SKU B na loja L7.....</i>	73
<i>Figura 6-3: Autocorrelograma do SKU B na loja L7.....</i>	75
<i>Figura 6-4: Demanda do SKU D na loja L2</i>	76
<i>Figura 6-5: Autocorrelograma do SKU D na loja L2</i>	76
<i>Figura 6-6: Autocorrelograma da demanda semanal da loja L5.....</i>	77

<i>Figura 6-7: Autocorrelograma da demanda dezenal da loja L5.....</i>	78
<i>Figura 6-8: Divisão das séries históricas em três fases.....</i>	80
<i>Figura 6-9: Demanda e previsão do SKU C na loja L5 – Método de Holt Winter's (realizado no MiniTab®).....</i>	81
<i>Figura 6-10: Demanda e previsão do SKU C na loja L5 – Método de Decomposição Clássica (realizado no Microsoft Excel®)</i>	82
<i>Figura 7-1: Determinação dos componentes do sistema de gestão de estoques para a loja L6.....</i>	87
<i>Figura 7-2: Ilustração da detecção e aplicação de atraso no nosso modelo de decisão (exemplo do SKU B na loja L6, os números foram modificados)</i>	92
<i>Figura 7-3: Ilustração da aplicação de corte no nosso modelo de decisão (exemplo do SKU B na loja L6, os números foram modificados)</i>	93
<i>Figura 7-4: Ilustração da detecção de vencimento de produto no nosso modelo de decisão (exemplo do SKU D na loja L6, os números foram modificados).....</i>	94
<i>Figura 7-5: Regra de comparação do novo modelo de decisão com o sistema empírico atual.....</i>	95
<i>Figura 7-6: Comparação do desempenho dos dois modelos.....</i>	96

LISTA DE TABELAS

<i>Tabela 2-1: Possíveis causas de ruptura ligadas ao ciclo de pedido.....</i>	27
<i>Tabela 2-2: Possíveis causas de ruptura operacionais</i>	28
<i>Tabela 3-1: Resumo dos métodos apresentados e suas aplicações.....</i>	49
<i>Tabela 5-1: Características das lojas selecionadas</i>	63
<i>Tabela 5-2: Características dos SKUs escolhidos.....</i>	68
<i>Tabela 6-1: Percentagens de ocorrência dos comportamentos das 42 combinações</i>	75
<i>Tabela 6-2: Percentagens de ocorrência dos comportamentos tirando os SKUs e as lojas de baixo giro.....</i>	77
<i>Tabela 6-3: Índices de sazonalidade para o SKU C na loja L5</i>	82
<i>Tabela 6-4: Comparação de MAD no caso do SKU C na loja L5.....</i>	83
<i>Tabela 6-5: Resultados das simulações de previsão de demanda.....</i>	83
<i>Tabela 7-1: Componentes do sistema de gestão de estoques das lojas do estudo.....</i>	87
<i>Tabela 7-2: Comparação da média e do desvio padrão do Instock (%) da amostra</i>	97
<i>Tabela 7-3: Comparação da média e do desvio padrão da CobEstMed (dias) da amostra</i>	97
<i>Tabela 7-4: Lista dos SKU/loja cuja cobertura é superior a meta de 12 dias</i>	98

LISTA DE SIGLAS

CALNEC	Cálculo de Necessidades
CD	Centro de Distribuição
CobEstMed	Cobertura de Estoque Média
Dem	Demand
EstFis	Estoque Físico
EstSeg	Estoque de Segurança
ILOS	Instituto de Logística e Supply Chain
LotComp	Lote de Compra
MAD	Mean Absolute Deviation
MAPE	Mean Absolute Percentage Error
NLiq	Necessidade Líquida
OCompra	Ordem de Compra
PerRev	Período de Revisão
SKU	Stock Keeping Unit
TEsp	Tempo de Espera
TResp	Tempo de Resposta
WMAPE	Weighted Mean Absolute Percentage Error

SUMÁRIO

1 APRESENTAÇÃO DA EMPRESA.....	15
1.1 O GRUPO DANONE	15
1.2 A MISSÃO DO GRUPO.....	15
1.3 A DANONE NO BRASIL	15
1.4 O MERCADO DE PRODUTOS LÁCTEOS FRESCOS NO BRASIL	16
1.5 O ESTÁGIO	18
2 DESCRIÇÃO DO PROBLEMA	20
2.1 A BUSCA DA “RUPTURA ZERO”	20
2.1.1. <i>A Disponibilidade de Produtos como dimensão de serviço mais valorizada pelos varejistas.....</i>	20
2.1.2. <i>Danone: um líder com uma tendência desfavorável.....</i>	21
2.1.3. <i>Impacto da ruptura de estoque</i>	22
2.1.4. <i>A Perecibilidade: uma dificuldade a mais.....</i>	23
2.2 AS CAUSAS RAÍZES DE RUPTURA NAS LOJAS ESTUDADAS	24
2.2.1. <i>O ciclo do pedido.....</i>	24
2.2.2. <i>As possíveis causas de ruptura</i>	27
2.2.3. <i>Hierarquização das causas de ruptura</i>	28
2.3 O PROBLEMA	29
2.4 O OBJETIVO DO TRABALHO.....	30
2.5 RELEVÂNCIA PARA A EMPRESA	31
2.6 ROTEIRO DO TRABALHO	31
3 REVISÃO BIBLIOGRÁFICA – PREVISÃO DE DEMANDA	34
3.1 MODELOS DE PREVISÃO QUANTITATIVOS	35
3.2 ANÁLISE DE SÉRIES TEMPORAIS.....	36
3.2.1. <i>Decomposição Clássica.....</i>	36
3.2.2. <i>Análise de autocorrelação</i>	36
3.3 MODELOS DE PREVISÃO QUANTITATIVOS DE SÉRIES TEMPORAIS.....	39
3.3.1. <i>Modelo do último dado</i>	39
3.3.2. <i>Modelo da média simples</i>	40
3.3.3. <i>Modelo da média móvel.....</i>	40
3.3.4. <i>Modelo de suavização exponencial simples.....</i>	41
3.3.5. <i>Modelo de suavização exponencial com tendência (modelo de Holt)</i>	42
3.3.6. <i>Modelo de suavização exponencial com tendência e sazonalidade (modelo de Holt Winter's)</i>	43
3.3.7. <i>Modelo baseado na Decomposição Clássica.....</i>	44
3.4 MEDIDAS DE ERROS DE PREVISÃO E ESCOLHA DO MELHOR MÉTODO DE PREVISÃO	46
3.4.1. <i>Desvio Absoluto Médio (MAD).....</i>	47
3.4.2. <i>Desvio Quadrático Médio (MSD).....</i>	47
3.4.3. <i>Desvio Absoluto Percentual Médio (MAPE)</i>	47
3.4.4. <i>Desvio Absoluto Percentual Médio Ponderado (WMAPE)</i>	48
3.4.5. <i>Desvio Relativo Percentual Médio (MPE).....</i>	48
3.4.6. <i>Escolha do modelo.....</i>	48
4 REVISÃO BIBLIOGRÁFICA – GESTÃO DE ESTOQUES	50
4.1 DEFINIÇÃO E FUNÇÕES DE UM ESTOQUE	50
4.2 OBJETIVOS DA MODELAGEM DE ESTOQUES.....	52
4.3 MODELOS DE ESTOQUES.....	52

4.3.1.	<i>Classificação dos modelos</i>	53
4.3.2.	<i>Modelo de Reposição do Máximo</i>	54
4.3.3.	<i>Modelo de Reposição da Base</i>	55
4.3.4.	<i>Modelo do Lote Fixo</i>	56
4.3.5.	<i>Modelo do Cálculo de Necessidades</i>	56
5	ESCOLHA DA AMOSTRA DE TRABALHO	60
5.1	AMOSTRA DE LOJAS	60
5.1.1.	<i>Critérios usados na definição da amostra de lojas</i>	60
5.1.2.	<i>Amostra de lojas escolhida</i>	63
5.2	AMOSTRA DE SKUs	63
5.2.1.	<i>Critérios usados na definição da amostra de SKUs</i>	63
5.2.2.	<i>Amostra de SKUs escolhida</i>	68
6	MÓDULO DE PREVISÃO DE DEMANDA	70
6.1	COLETA E TRATAMENTO DE DADOS.....	70
6.1.1.	<i>Coleta de dados</i>	70
6.1.2.	<i>Tratamento de dados</i>	71
6.2	ANÁLISE DOS DADOS E PROCURA DO PADRÃO DE DEMANDA	73
6.2.1.	<i>Análise gráfica</i>	73
6.2.2.	<i>Análise de autocorrelação</i>	74
6.2.3.	<i>Conclusão</i>	78
6.3	APLICAÇÃO DOS MODELOS.....	79
6.3.1.	<i>Divisão das séries históricas em fases</i>	79
6.3.2.	<i>Aplicação do modelo de Holt Winter's</i>	80
6.3.3.	<i>Aplicação do modelo de Decomposição Clássica</i>	81
6.3.4.	<i>Análise comparada do desempenho dos modelos</i>	82
6.3.5.	<i>Escolha do modelo</i>	84
6.3.6.	<i>Reflexão sobre os erros de previsão</i>	84
7	ELABORAÇÃO DO MODELO DE DECISÃO	86
7.1	HIPÓTESES DE ELABORAÇÃO DO MODELO DE DECISÃO.....	86
7.1.1.	<i>Componentes do sistema de gestão de estoques</i>	86
7.1.2.	<i>Restrições de "lote" de compra</i>	87
7.1.3.	<i>A falta como perda de vendas</i>	88
7.2	OBJETIVO DO MODELO DE DECISÃO	88
7.2.1.	<i>Definição dos indicadores de desempenho</i>	89
7.2.2.	<i>Objetivo quantitativo e parametrização do modelo</i>	90
7.3	TESTE DE VALIDAÇÃO: DESEMPENHO COMPARADO COM O SISTEMA EXISTENTE	91
7.3.1.	<i>Hipóteses de comparação</i>	91
7.3.2.	<i>Comparação dos dois modelos</i>	94
7.4	DISCUSSÃO SOBRE O DESEMPENHO DO MODELO DE DECISÃO	97
7.4.1.	<i>Meta de Instock</i>	97
7.4.2.	<i>Meta de CobEstMed</i>	97
8	CONCLUSÃO	100
8.1	SÍNTESE.....	100
8.2	RESULTADOS.....	101
8.3	PROPOSTA DE IMPLEMENTAÇÃO.....	101
8.4	ANÁLISE CRÍTICA	102
8.5	DESCOBRIAMENTOS	102
	REFERÊNCIAS BIBLIOGRÁFICAS	104

APÊNDICE A - RESULTADOS DA PREVISÃO DE DEMANDA	106
APÊNDICE B – INDICADORES DE GESTÃO DE ESTOQUE	108

1 Apresentação da empresa

1.1 O Grupo Danone

O Grupo Danone é uma empresa multinacional, que nasceu na França em 1973 da junção de duas companhias: Gervais Danone e BNS. Presente em mais de 120 países, a multinacional que conta com mais de 100 mil colaboradores, é o terceiro maior grupo alimentício da Europa e o sétimo maior fabricante de alimentos do mundo, sendo o primeiro em países como a França, Espanha e Itália.

Atualmente, a Danone tem quatro grandes linhas de produtos:

- *Fresh Dairy Products* (Produtos Lácteos Frescos): Core do Grupo que, com 20% do market share global (35% em alguns países), lidera o segmento.
- *Waters* (Águas): A Danone é a segunda maior produtora de água engarrafada no mundo.
- *Baby Nutrition* (Nutrição Infantil): A Danone é vice-líder no mercado, tanto no segmento de fórmula infantil quanto no segmento de comida sólida.
- *Medical Nutrition* (Nutrição Médica): O Grupo Danone entrou nesse novo mercado em 2007 com a aquisição da Numico e já virou vice-líder mundial.

1.2 A missão do Grupo

Hoje em dia, a Danone não somente reivindica o status de reconhecida empresa alimentar, mas também e, sobretudo, de único grupo alimentício a focalizar totalmente a saúde.

Ela define sua missão global da seguinte maneira: “Bringing Health to as Many People as Possible”, que em uma tradução livre seria “Trazendo saúde para o maior número de pessoas possível”. Esta frase mostra muito do que a Danone pretende como empresa e também contém o conceito de acessibilidade. Ela mostra uma real “lógica de serviço”, considerando, como o Zarifian (2001) explicita, que “a idéia principal é que o serviço não é somente o ponto de chegada da produção. É o ponto de partida, o que justifica sua existência e permite avaliar a performance de uma empresa.”

Para a Danone, os alimentos desempenham um papel essencial na saúde e no bem-estar das pessoas. Por isso ela luta continuamente para melhorar a qualidade nutritiva de seus produtos, investe em pesquisas e desenvolve programas educacionais destinados a ressaltar as virtudes da atividade física e da alimentação saudável.

1.3 A Danone no Brasil

A Danone chegou ao Brasil em 1970, através de uma parceria com a Laticínios Poços de Caldas. Nesse ano, a marca francesa lançou aqui um produto inédito e bem saboroso: o iogurte com polpa de frutas. O ingresso do iogurte no mercado revolucionou os hábitos de consumo dos brasileiros e teve sucesso imediato, tanto pelas características dos produtos – gostosos, saudáveis e nutritivos - como também pela inovação das suas embalagens - os potinhos, no modelo estriado. Alguns anos depois, a Danone diversificou a sua proposta no mercado brasileiro com produtos como o petit suisse Danoninho, o iogurte para beber Dan'up, a sobremesa láctea cremosa Danette ou ainda o iogurte light Corpus. Em dezembro de 2000, a Danone adquiriu a marca Paulista, que estava presente no Brasil desde 1933, quando iniciou a sua trajetória de sucesso com a distribuição porta a porta de leite em garrafas de vidro. A aquisição da Paulista permitiu ao Grupo consolidar a sua posição no mercado de produtos lácteos frescos e fez da marca a maior do Brasil nesse segmento.

Em 2008 foi lançado no Brasil à marca de água Bonafont, que veio completar a proposta da Danone. Todavia, o posicionamento da empresa nesse novo segmento no Brasil ainda não está completamente definido. O portfólio da Danone se diversificou também através da entrada de produtos de alimentação infantil, com a compra da marca Suporte no ano passado.

A empresa opera através da sua fábrica de produtos lácteos frescos, localizada em Poços de Caldas (MG) e da sua fábrica de água, localizada em Jacutinga (MG). A fábrica de alimentação infantil está localizada na Argentina. A matriz está situada em São Paulo, na Avenida Paulista e a empresa possui vários escritórios de venda, além de quatorze centros de distribuição espalhados pelo Brasil inteiro, conforme mostrado na figura 1-1.



Figura 1-1: Malha logística da Danone no Brasil

1.4 O Mercado de produtos lácteos frescos no Brasil

Esse trabalho se focará no segmento de produtos lácteos frescos, por ser de longe o maior departamento da Danone Brasil e também aquele no qual o grupo possui uma maior experiência.

A Danone é líder do mercado brasileiro de produtos lácteos frescos. A figura 1-2 ilustra a participação (*Market Share*) em faturamento referente ao ano 2008 das empresas atuando no segmento, e a figura 1-3 em volume.

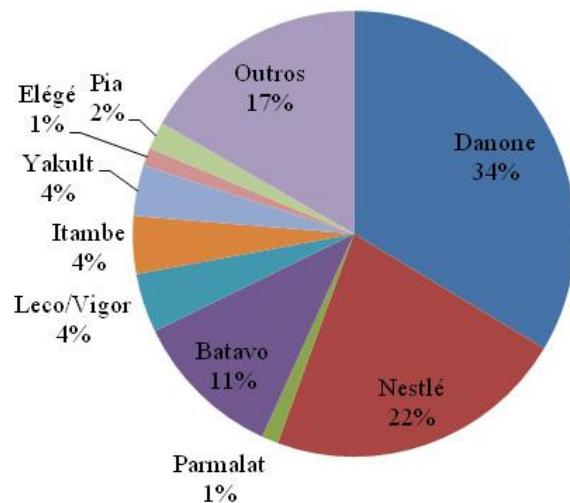


Figura 1-2: Market Share (em valor) do segmento de produtos lácteos frescos
(elaborada a partir de dados do instituto ACNielsen, 2008)

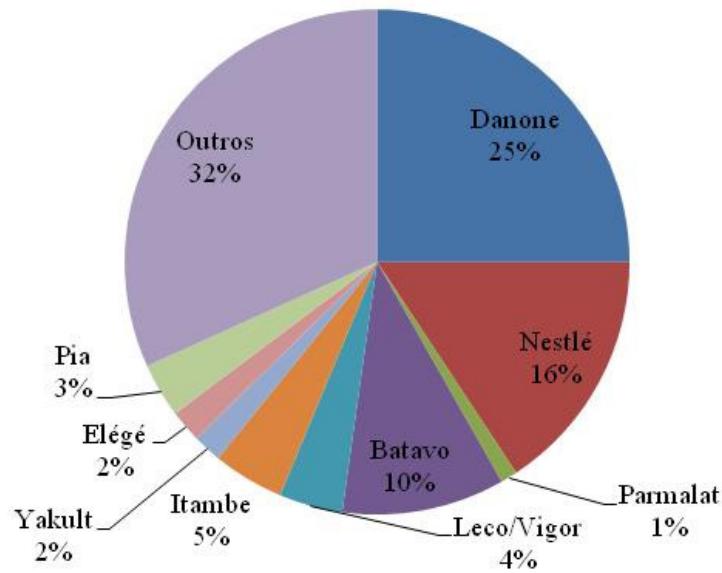


Figura 1-3: Market Share (em volume) do segmento de produtos lácteos frescos
(elaborada a partir de dados do instituto ACNielsen, 2008)

Observa-se que o Share Valor da empresa é muito superior ao Share Volume. Isto é consequência do posicionamento do grupo que produz produtos lácteos frescos com valor agregado superior à média do segmento, e destinado principalmente para consumidores das classes A e B como ilustrado na figura 1-4.

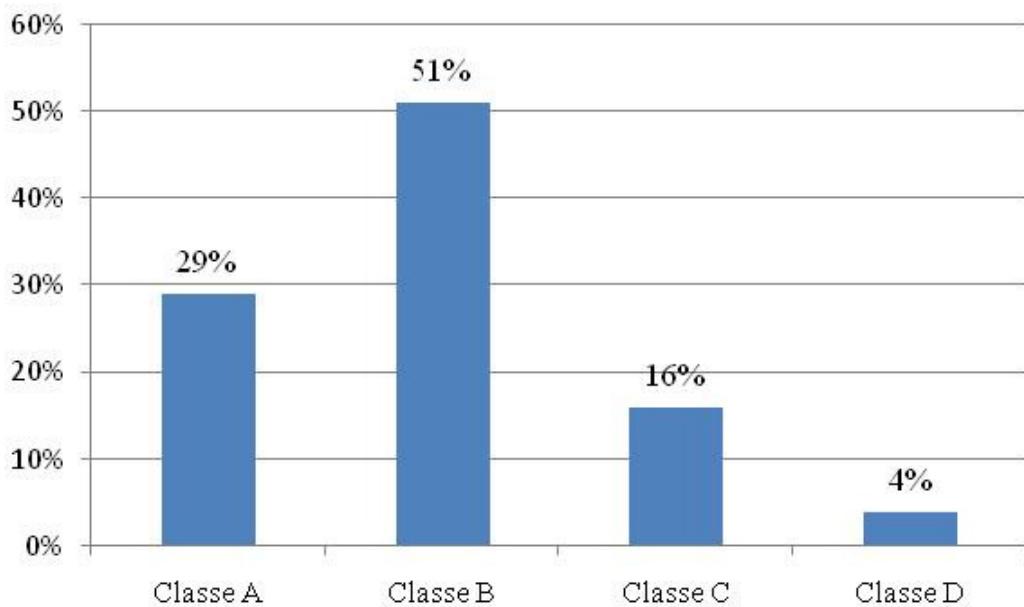


Figura 1-4: Perfil econômico do comprador de produtos lácteos frescos (% em vendas)
(Danone – Guia de Categorias 2008)

Como líder de mercado, a empresa busca aproveitar novas oportunidades e contribuir na expansão do mercado de produtos lácteos frescos no Brasil que ainda não atingiu plenamente sua maturidade: enquanto um francês consome em média quase 18 kg por ano, um brasileiro consome 5,5 kg por ano.

1.5 O Estágio

O estágio foi desenvolvido na área de Customer Service. O objetivo global da área é entender os serviços diferenciados que os clientes necessitam e preparar a empresa para oferecer estes serviços a um custo aceitável. Conforme apresentado na figura 1-5, o Customer Service está dentro da área de Supply Chain, sendo dividido em vários setores que cuidam desde a captação do pedido até a entrega deste na loja.

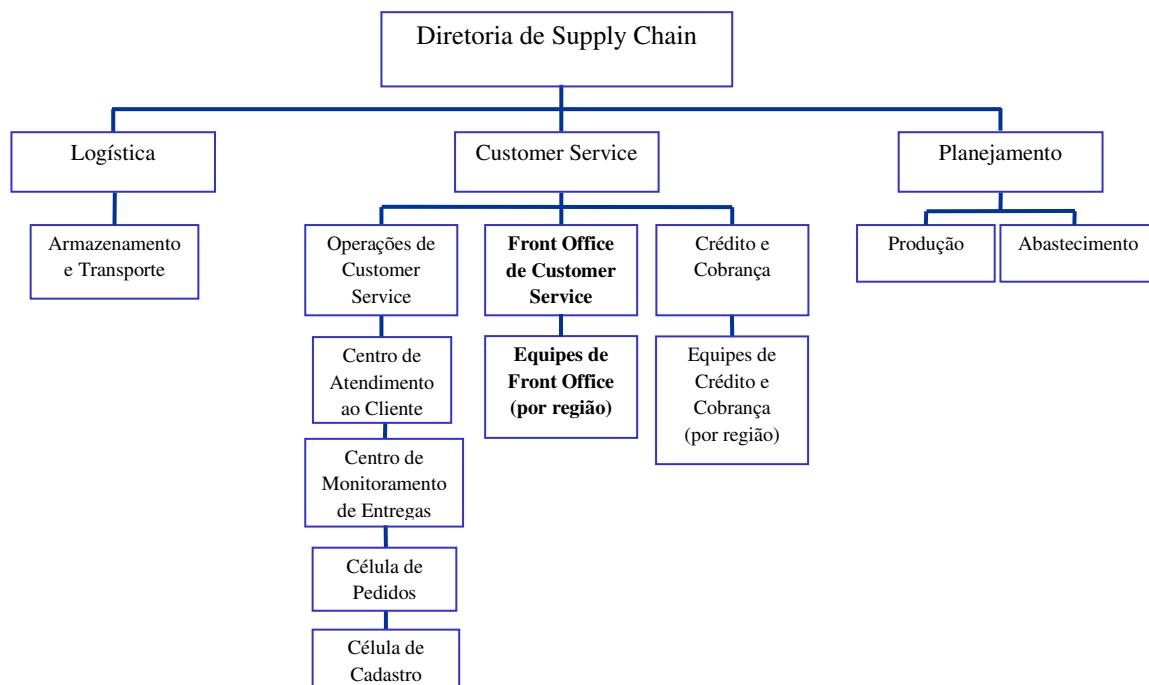


Figura 1-5: Organograma do departamento de Supply Chain

O setor Front Office dentro do Customer Service funciona como interface entre áreas internas da empresa e seus parceiros comerciais. Ele centraliza informações de diversas partes da empresa sendo o principal negociador para assuntos operacionais entre a área comercial, operações e clientes. Faz parte de sua função a antecipação de problemas na operação, a instauração de medidas para evitar a ampliação dos problemas existentes, além da discriminação de procedimentos e políticas de Supply Chain para distribuidores e outras áreas da empresa.

O meu papel dentro do Front Office era cuidar do atendimento dos Key Accounts, ou seja, das grandes redes como Wal Mart, Carrefour e Grupo Pão de Açúcar. Uma das principais responsabilidades era o monitoramento de indicadores operacionais e comerciais e o desenvolvimento de projetos para melhorar-los.

É nesse setor e mais particularmente em um grupo de lojas localizadas no Sul do Brasil que o presente trabalho está sendo feito. A escolha do varejo foi motivada pelo grau de colaboração e pela integração logística existentes entre as duas empresas. Essa colaboração é fundamental para se ter acesso a informações (especialmente dados diários de estoque e de venda dos nossos produtos nas lojas) e espaço para a realização e a aplicação de projetos de melhoria.

2 Descrição do problema

2.1 A busca da “Ruptura Zero”

2.1.1.A Disponibilidade de Produtos como dimensão de serviço mais valorizada pelos varejistas

O Instituto de Logística e Supply Chain (ILOS) publicou em 2009 os resultados de uma pesquisa chamada “Customer Service: Avaliação do Serviço de Distribuição das Indústrias de Produtos Perecíveis”, que conta com a opinião de 111 supermercadistas atuantes no Brasil inteiro. Esse estudo apresenta a avaliação do serviço logístico de várias empresas de bens de consumo perecíveis segundo oito dimensões chaves, a fim de identificar pontos que merecem maior ênfase e que gerem oportunidades de melhoria. As dimensões analisadas são as seguintes: a Disponibilidade de Produtos, o Tempo de Ciclo do Pedido, a Consistência do Prazo de Entrega, a Freqüência de Entrega, a Flexibilidade do Sistema de Distribuição, o Sistema de Informação de Apoio, o Sistema de Remediação de Falhas e o Apoio na Entrega Física.

Os supermercadistas avaliaram a importância relativa desses critérios usando uma escala de 1 a 5, onde 1 significa nenhuma importância e 5 muita importância. A figura 2-1 apresenta o resultado obtido. Todas as dimensões foram reconhecidas importantes para o serviço de distribuição. Vale destacar a Disponibilidade de Produtos e a Consistência do Prazo de Entrega que foram consideradas as mais relevantes de todas, com notas médias respectivas de 4,75 e 4,74. Olhando no Sul do Brasil, região de foco desse estudo, a avaliação apresenta o mesmo perfil, com destaque ainda maior da Disponibilidade de Produtos (nota 4,74) em relação à Consistência do Prazo de Entrega (nota 4,70). A figura 2-2 ilustra essa importância relativa.



Figura 2-1: Importância das dimensões de serviço segundo os varejistas do Brasil inteiro (ILOS, 2009)



Figura 2-2: Importância das dimensões segundo os varejistas do Sul do Brasil (ILOS, 2009)

2.1.2. Danone: um líder com uma tendência desfavorável

Na pesquisa do ILOS citada acima, os varejistas tiveram que citar os melhores fornecedores em relação ao critério de Disponibilidade de Produtos. A figura 2-3 apresenta a evolução da percentagem de citações dos seis fornecedores mais citados, entre os quais aparece a empresa Danone na terceira posição em 2008. O fato de figurar entre os quatro melhores fornecedores nessa dimensão há mais de dez anos é um sinal claro de excelência na gestão de ruptura.

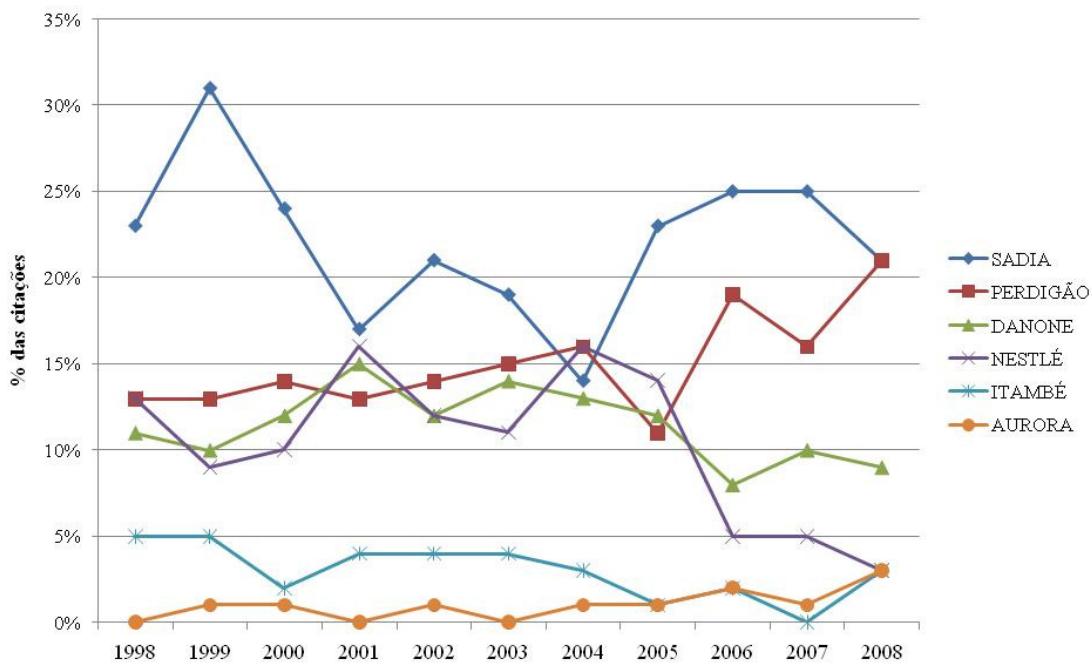


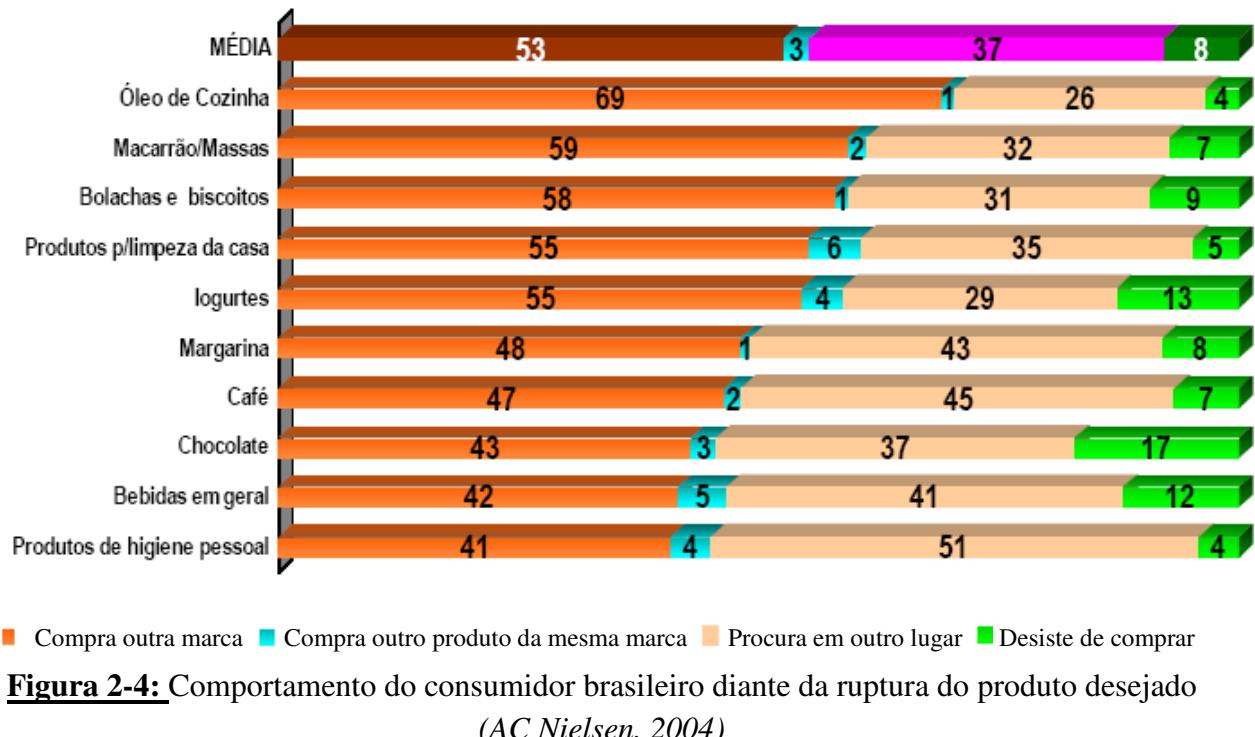
Figura 2-3: Melhores fornecedores em Disponibilidade de Produtos segundo os varejistas
(ILOS, 2009)

Todavia, desde 2006, a Danone obteve menos de 10% das citações, o que pode mostrar certo recuo em termo de desempenho, de criatividade ou de inovação nesses últimos anos. Esse recuo poderia impactar o nível de serviço global da Danone, uma vez que a Disponibilidade é um critério chave de avaliação, como visto no parágrafo anterior. Parece então essencial para a Danone buscar melhorias em gestão de Disponibilidade de Produtos, a fim de estabilizar sua posição de “fornecedor benchmark” nessa dimensão.

2.1.3. Impacto da ruptura de estoque

A Danone considera que uma ruptura ocorre quando um produto cadastrado em um ponto de venda não se encontra disponível na gôndola para os consumidores. Sendo assim, a ausência de um determinado produto na gôndola, mesmo havendo produtos no estoque do estabelecimento, é considerada ruptura.

Uma pesquisa desenvolvida no Brasil em 2004 pela ACNielsen com apoio do ECR (Efficient Consumer Response) Brasil e da ABRAS (Associação Brasileira de Supermercados) analisou o comportamento dos consumidores perante a ruptura do produto procurado. Alguns dos resultados obtidos são mostrados na figura 2-4.



Dessa maneira, diante da ruptura na gôndola de um produto lácteo fresco (categoria “Iogurtes” na figura 2-4), as possibilidades do cliente comprar outra marca ou não comprar o produto são 55% e 13% respectivamente, o que represente 68% de chance de perder a venda para a Danone. Sabendo que a percentagem média de ruptura na gôndola é estimada em 8% no Sul do Brasil, segundo o estudo do ILOS, podemos estimar que o ganho incremental das vendas seria de 5,4% caso não houvesse rupturas de estoque. Do ponto de vista do varejista, a situação é critica também, pois em 42% dos casos o cliente procura em outro lugar ou desiste de comprar.

Podemos identificar outros impactos da ruptura de estoque, além da perda de vendas potenciais, tais como a deterioração da imagem da marca e a queda de fidelidade do consumidor, que aumentam ainda o aspecto critico da Disponibilidade de Produtos.

2.1.4. A Perecibilidade: uma dificuldade a mais

Nos parágrafos anteriores, mostramos a importância da Disponibilidade de Produtos no serviço prestado pela Danone aos varejistas e o impacto negativo das rupturas tanto nos resultados financeiros, quanto no relacionamento com o varejista e o cliente final.

No caso dos produtos lácteos frescos da Danone, outra característica complica o problema: a perecibilidade. Os produtos têm uma validade de 30 a 45 dias, dependendo da forma de comercialização e do sabor do produto. É tradicionalmente considerado que um produto chega à gôndola aproximadamente uma semana após sua fabricação, o que reduz ainda mais o tempo real máximo de permanência na loja. Essa característica tende a criar rupturas, uma vez que os produtos vencem naturalmente na gôndola. Além disso, todo produto não consumido antes da data de vencimento vai para o lixo, gerando assim perdas para a empresa. Soma-se ao claro impacto financeiro o questionamento sobre a sustentabilidade da cadeia, uma problemática crescente dentro do Grupo Danone nessa última década.

2.2 As causas raízes de ruptura nas lojas estudadas

2.2.1. O ciclo do pedido

O entendimento da cadeia logística, bem como o de suas variabilidades, é fundamental para a compreensão do problema e para a determinação das possíveis causas de ruptura. Por essa razão, um fluxograma do ciclo do pedido, descrito nas figuras 2-5 e 2-6, foi elaborado. Ele permite entender as etapas sucessivas, da elaboração do pedido até a entrega final da mercadoria.

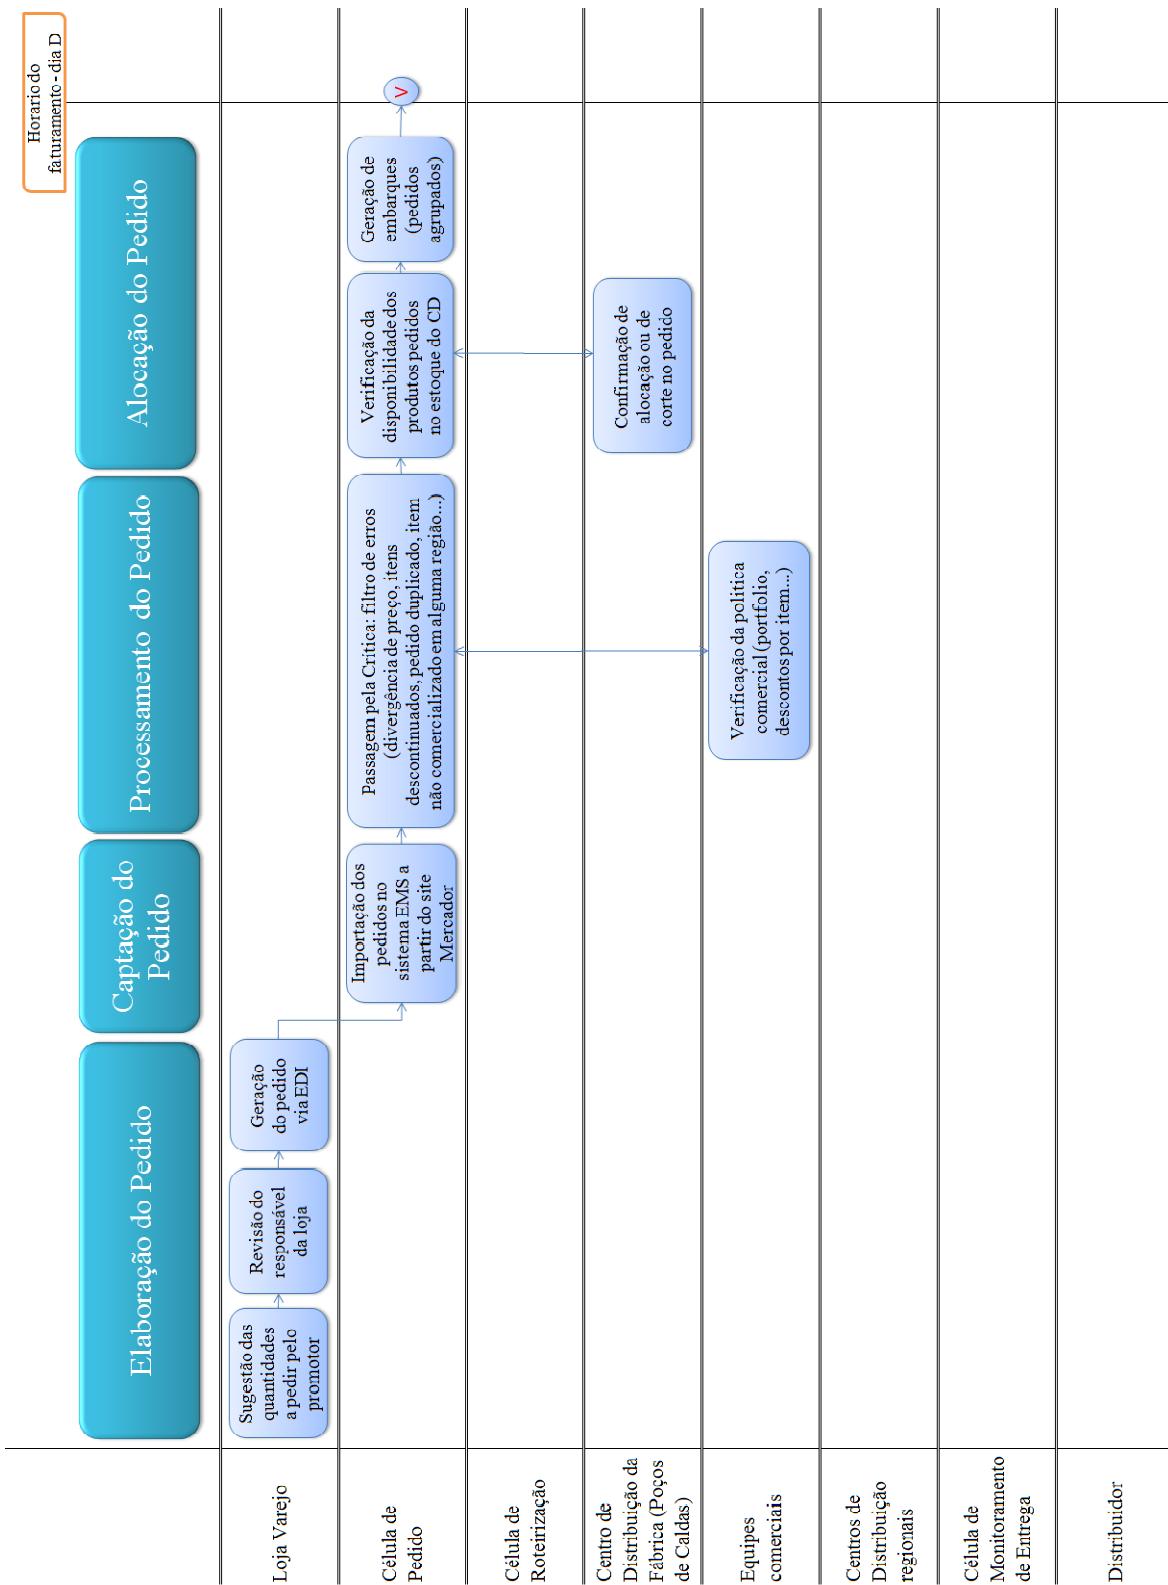


Figura 2-5: Fluxograma do ciclo do pedido, da elaboração à alocação

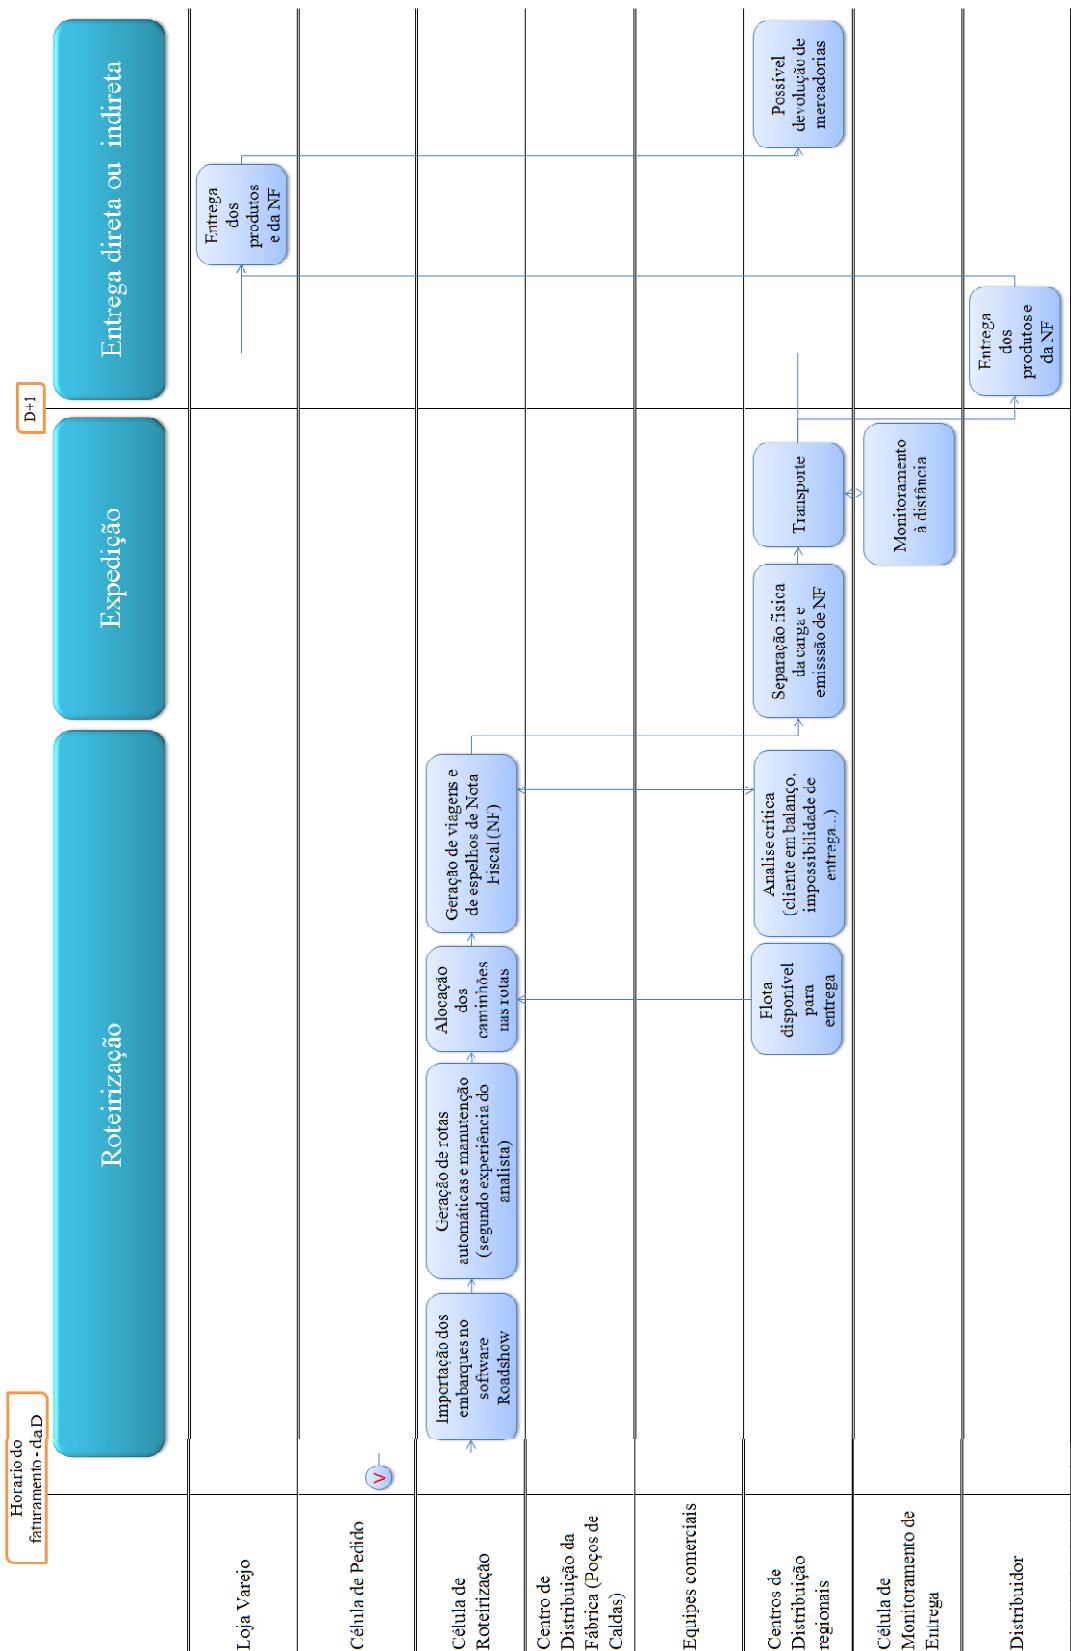


Figura 2-6: Fluxograma do ciclo do pedido, da roteirização à entrega

2.2.2. As possíveis causas de ruptura

Foram listadas as possíveis causas de ruptura na gôndola, a partir de discussões com os diferentes atores do ciclo do pedido (promotores nas lojas, faturistas, funcionários da Célula de Monitoramento de Entrega, de Customer Service...). Não foi buscada exaustividade, uma vez que essa listagem só teve o objetivo de destacar as causas raízes mais relevantes. A tabela 2-1 apresenta possíveis causas de ruptura ligadas com as etapas do ciclo do pedido, bem como o efeito e a freqüência de cada uma, segundo as estimativas qualitativas dos entrevistados. A tabela 2-2 lista possíveis causas de ruptura operacionais, uma vez que a mercadoria tenha chegado à loja.

Etapa do ciclo	Possíveis causas de ruptura	Efeito	Freqüência de ocorrência
Elaboração do pedido	<u>Não respeito do plano de campo:</u> O promotor passou um pedido no dia errado, ou no dia certo mas depois do horário de faturamento.	O pedido só será faturado no dia previsto. A loja fica sem receber até essa data.	média
	<u>Previsão da demanda:</u> O promotor digitou quantidades abaixo ou acima da demanda real ou não pediu.	<u>Pediu abaixo da demanda ou não pediu:</u> terá ruptura de estoque dos itens em questão. <u>Pediu acima da demanda:</u> o produto vencerá na gôndola, induzindo perdas.	alta
Captação do pedido	<u>Erro de transmissão:</u> O pedido não foi trafegado, e por consequência não foi processado.	A loja tem que esperar até o próximo dia de pedido. A loja fica sem receber até essa data.	baixíssima
Processamento do pedido	<u>Divergência de preço:</u> O preço de um item no cliente está abaixo do preço definido pela Danone.	O item não será faturado até alinhamento dos preços, gerando ruptura do mesmo.	média
Alocação do pedido	<u>Planejamento da produção:</u> Um item está em ruptura de estoque no CD da Danone ou bloqueado por razão qualquer (qualidade...).	Terá corte do item nos pedidos, até produção do mesmo.	alta
Expedição	<u>Manuseio:</u> Produtos ficam danificados no caminho.	Esses produtos não serão recebidos pela loja, o que gerará ruptura.	baixa
	<u>Entrega atrasada:</u> A expedição ocorre com atraso (especialmente no caso da entrega via distribuidor).	O pedido demora para chegar (até 3 dias de atraso), o que gera ruptura alta até o recebimento.	média a alta (entrega via distribuidor)
Entrega	<u>Erro na separação da carga:</u> Existem divergências entre o que é entregue e o que foi pedido (quantidades erradas...).	Essas divergências geram devolução parcial ou até total do pedido, gerando ruptura na loja.	baixa
	<u>Divergência administrativa:</u> Há divergência na nota fiscal.	O pedido inteiro é devolvido.	baixa

Tabela 2-1: Possíveis causas de ruptura ligadas ao ciclo de pedido

Possíveis causas de ruptura operacionais	Efeito	Freqüência de ocorrência
<i>Roubo:</i> Mercadoria foi roubada dentro do backroom ou na gôndola.	Abaixa a quantidade disponível a venda, o que pode gerir ruptura.	baixíssima
<i>Reabastecimento das gôndolas:</i> As gôndolas não estão reabastecidas pelo promotor. A mercadoria é disponível, mas fica no backroom.	Gera ruptura na gôndola, pelo cliente final.	baixa

Tabela 2-2: Possíveis causas de ruptura operacionais

2.2.3. Hierarquização das causas de ruptura

As tabelas anteriores introduziram possíveis causas de ruptura, com estimativas qualitativas de ocorrência. A fim de hierarquizar de maneira mais precisa essas causas, uma análise quantitativa foi realizada a partir dos dados acumulados de estoque, venda e queda relativos aos meses de abril e maio de sete lojas escolhidas entre as lojas do estudo. Esses dados foram disponibilizados pelo varejo. O método usado para definir a amostra de lojas será detalhado na parte 5.1. Foram considerados no estudo todos os SKUs da Danone vendidos nestas lojas. A sigla “SKU”, acrônimo de Stock Keeping Unit é normalmente usada para designar o código de cada variante dos artigos mantidos em armazém. Na Danone, a sigla é usada em todos os departamentos (não somente no setor de armazenamento) e designa uma variante de um produto, conforme a sua forma, tamanho, sabor... A sigla será reutilizada de forma recorrente nos próximos tópicos.

As lojas do varejo, foco do estudo, estimam que um SKU encontra-se em ruptura no dia D se o seu estoque atual (D) é inferior à venda média diária daquele produto (ou seja, um dia de cobertura). Essa convenção será discutida mais para frente, no entanto para respeitar o contexto de realização do trabalho ela foi considerada como válida para essa etapa de diagnóstico. Cada ruptura foi investigada e chegamos aos resultados apresentados na figura 2-7.



Figura 2-7: Causas raízes das rupturas identificadas

A análise quantitativa permitiu destacar o problema dos erros de previsão de demanda dos produtos lácteos frescos, responsáveis por 66% das rupturas identificadas na amostra escolhida. Conforme definido na tabela 2-1, isso é ligado às quantidades pedidas pelos promotores que não são coerentes com a demanda real dos produtos. Esse tema será o foco do estudo.

2.3 O problema

Como visto anteriormente, a Disponibilidade de Produto é uma dimensão chave do serviço prestado pela Danone aos varejistas. Um estudo qualitativo permitiu identificar algumas causas possíveis de ruptura, entre os quais os erros de previsão de demanda se destacaram.

Atualmente, não há ferramenta de previsão quantitativa no grupo de lojas estudado: as quantidades a pedir são sugeridas pelo promotor de vendas da Danone ao responsável de loja do varejista, segundo o conhecimento e o contato que o primeiro tem com o mercado.

A sugestão do promotor é baseada em previsão, mas não é apoiada em nenhum cálculo. Ela é manual e empírica, o que é uma lacuna clara do sistema atual. Além disso, existe um verdadeiro conflito de escolha (*trade-off*): deve ser pedido o suficiente para atender a demanda, mas sem excesso para não deixar vencer produto na gôndola.

Existem também riscos importantes associados ao fator erro humano e à concentração de informações chaves em uma única pessoa.

A sugestão do promotor é revista pelo responsável de loja do varejista, que também se encontra em situação de conflito de escolha (*trade-off*): ele busca abastecer a loja em quantidade suficiente para não criar ruptura, mas é pressionado para reduzir o nível de estoques numa perspectiva de redução de custo imposta pela matriz do varejo.

Essa situação é resumida na figura 2-8 a seguir.



Figura 2-8: Trade-offs na decisão das quantidades a pedir

2.4 O objetivo do trabalho

O objetivo desse trabalho é criar um modelo de apoio à decisão a ser usado pelos promotores na elaboração dos pedidos de produtos lácteos frescos. Esse modelo se baseará no estoque atual e nos resultados de uma previsão de demanda quantitativa, a fim de melhorar o abastecimento das lojas do varejo estudado. O modelo deverá auxiliar os tomadores de decisão a resolver o conflito de escolha ao qual eles são submetidos, conforme descrito no parágrafo anterior.

O modelo de apoio à decisão será composto de um módulo de previsão de demanda que abastecerá um módulo de reposição de estoque.

Esse trabalho se iniciará com uma análise da demanda dos produtos lácteos frescos e proporá um modelo de previsão que deverá funcionar respeitando a restrição de dados disponíveis, uma vez que o sistema que fornece informações sobre o estado das lojas contém um conjunto limitado de variáveis. Na medida do possível, o modelo deverá usar uma única técnica de previsão a fim de simplificar a utilização prática.

No que diz respeito ao modelo de decisão de reposição de estoque, ele deverá respeitar a freqüência de visitas às lojas negociada entre a Danone e o varejista.

2.5 Relevância para a empresa

O presente trabalho tem relevância em vários níveis para a Danone. Em primeiro lugar, ele fornece uma ferramenta de gestão de estoques que hoje em dia não existe. Essa ferramenta permitirá resolver o problema do conflito de escolha e da subjetividade na elaboração dos pedidos, além de melhorar a disponibilidade dos produtos, critério chave do serviço prestado pela Danone ao varejista.

O modelo reforçará ainda a colaboração e a integração logística existente entre a Danone e o varejo, o que deve aumentar a eficiência da cadeia como um todo.

Por fim, o modelo de previsão de demanda baseia-se em uma análise do perfil da demanda de produtos lácteos frescos, o que pode ser de grande ajuda para entender melhor o comportamento dos produtos no mercado e identificar oportunidades de crescimento e de revisão de portfólio.

2.6 Roteiro do trabalho

No capítulo 1, foram apresentados a empresa e o mercado de produtos lácteos frescos no Brasil. Foi descrita a área de atuação na qual esse trabalho se focará.

O capítulo 2 teve o objetivo de identificar o problema a ser abordado (a gestão da ruptura na gôndola), bem como as causas raízes do problema. Essas causas foram hierarquizadas para chegar à causa a ser tratada no presente trabalho: a previsão da demanda.

Os capítulos 3 e 4 trazem uma revisão bibliográficas dos assuntos mais relevantes para a solução dos problemas identificados, ou seja, da previsão de demanda e da gestão de estoques.

O capítulo 5 detalha a amostra escolhida para o presente trabalho.

O capítulo 6 propõe a elaboração do módulo de previsão de demanda, com coleta de dados históricos, tratamento, análise e finalmente procura do padrão de comportamento.

No capítulo 7 é apresentada a elaboração do modelo de apoio à decisão, bem como uma comparação do seu desempenho em relação ao método atual.

Por fim, o capítulo 8 apresenta uma síntese do trabalho e dos resultados obtidos, uma análise crítica do modelo, assim como possíveis desdobramentos futuros do trabalho.

3 Revisão Bibliográfica – Previsão de demanda

A demanda de um item pode ser definida como a vontade de consumo deste. Ela pode variar na quantidade e ao longo do tempo. Como podem acontecer rupturas no atendimento dela, ela se distingue claramente da vontade de oferta e não deve ser confundida com dados de vendas.

Segundo Hanke e Reitsch (1998), os tipos de previsão disponíveis para as organizações podem ser classificados de diversas maneiras, dependendo do critério usado. Eles podem ser de curto ou de longo prazo, quando se considera o horizonte de planejamento como característica chave, podem ser micro ou macro dependendo da abrangência do universo (uma fábrica ou um país) e do nível de detalhamento necessário, ou agrupados como qualitativos ou quantitativos, segundo o grau de julgamento humano ou tratamento de dados numéricos utilizado. Esta última classificação é especialmente relevante, porque isola modelos cujas premissas são bem diferentes.

Segundo Makridakis e Wheelwright (1978), uma previsão quantitativa pode ser aplicada quando três condições são reunidas:

- Existe informação disponível sobre o passado,
- Essa informação é quantificável em dados numéricos,
- Admite-se uma hipótese de continuidade: algum padrão do passado se perpetuará no futuro.

Já, os modelos qualitativos não precisam de histórico e não guardam relação clara com o passado. Eles baseiam-se no julgamento de especialistas, em pesquisas e intuição. Sipper e Bulfin (1997) mostraram que métodos como a pesquisa de mercado fornecem resultados interessantes, mas o tempo necessário para desenvolvê-los impede qualquer utilização em previsões de curto prazo. Portanto, esses modelos não serão detalhados no presente trabalho.

3.1 Modelos de previsão quantitativos

Como mostram Makridakis e Wheelwright (1978), uma previsão quantitativa baseia-se na concepção seguinte:

$$\text{Dados de demanda} = \text{Componente sistemático} + \text{Componente aleatório}$$

A previsão está intimamente ligada ao componente sistemático, que representa o padrão do passado. Na literatura, os métodos qualitativos são geralmente divididos em dois grupos:

- os métodos de séries temporais ou de projeção, que admitem como premissa que o futuro será uma projeção do passado e que utilizam modelos matemáticos e estatísticos sobre os dados históricos da demanda para executar a previsão. Nesse caso, o componente sistemático é função apenas do tempo e da hipótese de comportamento adotada.
- os métodos causais ou explicativos, que buscam relações de causa – efeito entre a variável de estudo e outras consideradas influentes nestas. Neste caso, o componente sistemático é função destas outras variáveis e da evolução delas no tempo.

Os métodos causais demonstram uma real preocupação com o conhecimento das causas da demanda. A compreensão dessas relações ajuda a empresa a entender o mercado no qual ela atua, o que pode trazer muitos benefícios, além dos ligados à previsão de demanda. Porém, devido à necessidade de análises de várias variáveis, eles possuem um custo elevado e são mais recomendados para previsões de médio e longo prazo.

O objetivo do presente trabalho é de criar um modelo de decisão a ser usado pelos promotores na elaboração dos pedidos de mais de 8000 itens/lojas. Os modelos de séries temporais parecem ser os modelos mais adequados ao caso a ser tratado, pela facilidade de uso e pela adequação à previsão de curto prazo. Por essa razão, somente eles serão tratados daqui em diante.

3.2 Análise de séries temporais

3.2.1. Decomposição Clássica

Como visto anteriormente, os modelos de previsão quantitativos vêem o futuro como reprodução do passado. Eles fazem a hipótese que um padrão de comportamento identificado na demanda passada se repetirá nas vendas futuras. Segundo Hanke e Reitsch (1998), para evitar desperdício de energia na busca desse padrão, uma abordagem sistemática para analisar uma série temporal é necessária. Ele chama de “Decomposição Clássica” a abordagem que decompõem os dados nos seguintes componentes:

- Tendência, o componente que representa o crescimento ou declínio de uma série temporal em um longo período de tempo. Hanke e Reitsch (1998) destacam alguns fatores que ajudam a explicar a tendência de uma série: o crescimento da população, a inflação, as mudanças tecnológicas ou ainda um aumento de produtividade.

- Ciclicidade, o componente que explica a ondulação, a flutuação cíclica em torno da tendência da série temporal. Ele é geralmente de longo prazo (vários anos) e ligado as evoluções macroeconômicas.

- Sazonalidade, o componente que explica o padrão de variação que se repete a intervalos de tempo constantes. Pode tratar-se de variações que se repetem anualmente, mensalmente ou também semanalmente.

- Aleatório, o componente que mede a variabilidade residual da série temporal após a remoção dos efeitos dos componentes anteriores.

3.2.2. Análise de autocorrelação

Uma das abordagens possíveis para identificar as características de uma série temporal é chamada de análise de autocorrelação. Esse método é usado para descrever a correlação entre dois valores da mesma série temporal, em diferentes períodos de tempo. Como notação, utilizaremos Y_t para designar uma variável dependente no instante t e n o número de valores da série temporal Y_t .

O coeficiente de autocorrelação r_1 mede a correlação entre dois valores adjacentes na série, ou seja, entre Y_t e Y_{t-1} . A autocorrelação, neste caso, é dita de defasagem (ou lag) 1.

De maneira genérica, o coeficiente de autocorrelação r_k de defasagem k , mede a correlação entre Y_t e Y_{t-k} e é calculado da seguinte forma:

$$r_k = \frac{\sum_{t=k+1}^n (Y_t - \bar{Y})(Y_{t-k} - \bar{Y})}{\sum_{t=1}^n (Y_t - \bar{Y})^2}$$

com \bar{Y} é a média dos valores da série temporal estudada

Como mostram Hanke e Reitsch (1998), se os valores da série são aleatórios, os coeficientes de autocorrelação serão próximos de zero. Se a série temporal apresenta uma tendência, os coeficientes serão significantemente diferentes de zero para as primeiras defasagens e cairão rapidamente até zero à medida que a defasagem aumenta. Já, se a série apresenta sazonalidade de período x , o coeficiente r_x terá também um valor significativamente alto.

Na literatura achamos critérios para definir valores limites a partir dos quais um coeficiente pode ser considerado como “significativamente diferente de zero”. Quenouille (1949) mostrou que os coeficientes de autocorrelação de uma série de valores aleatórios têm uma distribuição que se aproxima de uma curva normal de média μ igual a zero e de desvio padrão σ igual a $1/\sqrt{n}$. Segundo Hanke e Reitsch (1998), “sabendo isso, o analista pode comparar a distribuição discreta dos coeficientes de autocorrelação com a distribuição teórica e determinar se eles provêm de dados de média zero para uma dada defasagem”. Dessa maneira, Makridakis e Wheelwright (1978) propõem um teste para determinar se uma série temporal pode ser considerada aleatória ou não. Usando uma percentagem de confiança de 95%, e uma população de n observações, a série pode ser considerada aleatória se:

$$-V_{\text{lim}} \leq r_k \leq +V_{\text{lim}}$$

$$\text{com } V_{\text{lim}} = \mu + 1,96 * \sigma, \text{ ou seja, } V_{\text{lim}} = 1,96 / \sqrt{n}$$

Quando uma série temporal apresenta tendência, uma remoção da não-estacionaridade é desejada. Um dos métodos descritos por Makridakis e Wheelwright (1978) é chamado de diferenciação e consiste em criar uma nova série Y' a partir das diferenças entre períodos sucessivos, conforme equação seguinte:

$$Y'_t = Y_t - Y_{t-1}$$

Essa nova série é composta de $n-1$ valores e será estacionária se a série original apresenta tendência linear. Se não for o caso, as diferenças entre os resultados obtidos poderá ser calculada de novo, em busca da estacionariedade. A literatura indica que na maioria dos casos práticos, a estacionariedade é obtida num máximo de dois passos.

Uma análise metódica para identificar o comportamento de uma série temporal é proposta por Makridakis e Wheelwright (1978). O processo analítico é ilustrado na figura 3-1.

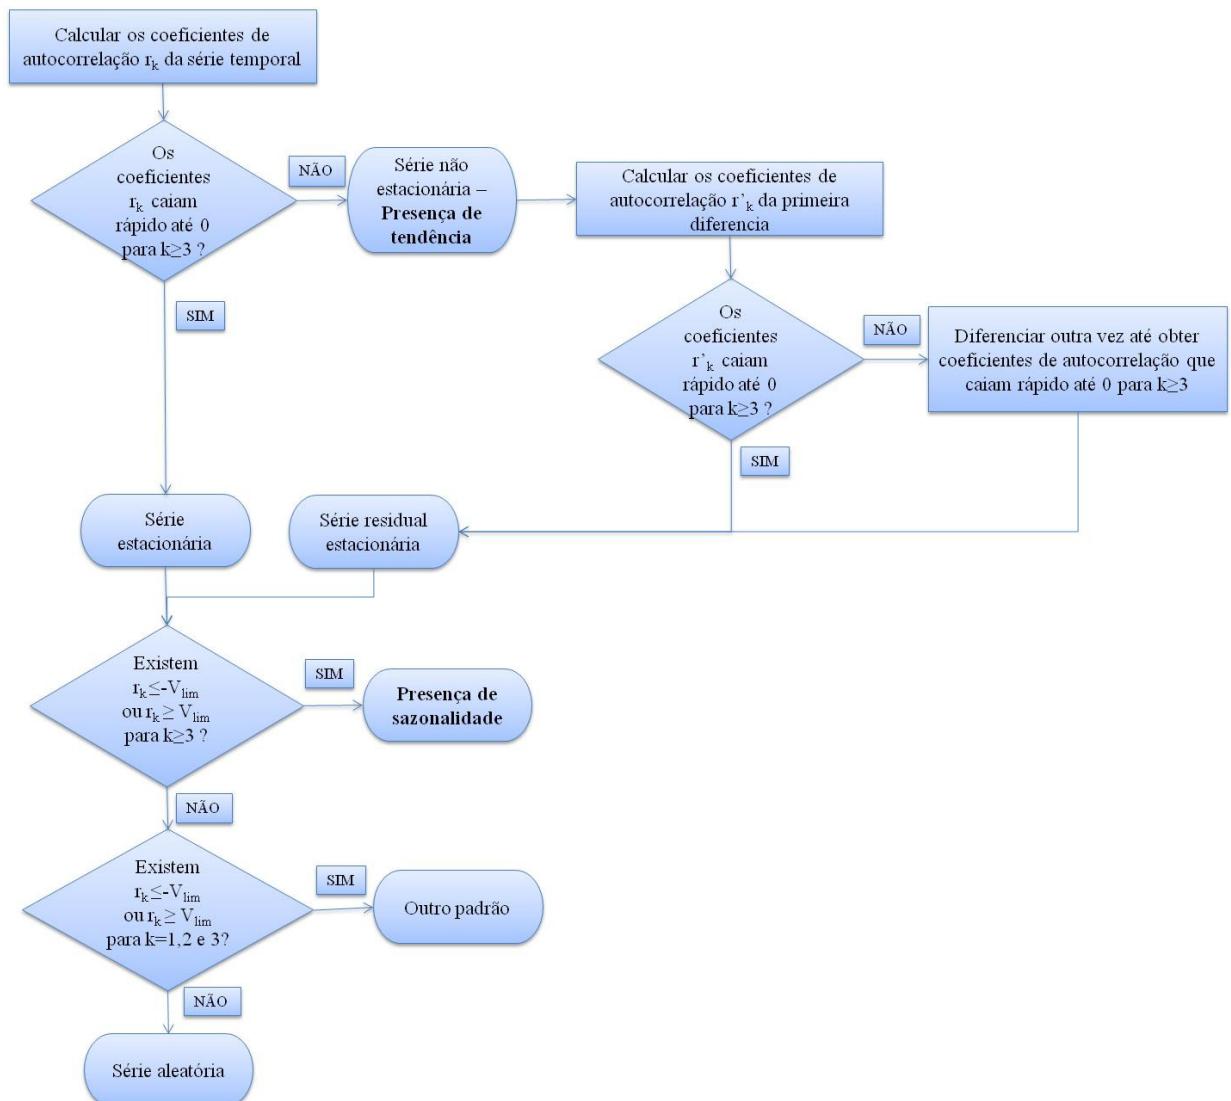


Figura 3-1: Fluxograma do método de análise do comportamento de uma série temporal
(adaptado de Makridakis e Wheelwright, 1978)

A representação gráfica que compila os coeficientes de autocorrelação r_k de uma série temporal em suas diferentes defasagens (ou lags) é denominada autocorrelograma. Ela permite visualizar num único gráfico as diferentes autocorrelações, o que facilita a identificação do padrão de comportamento da série.

3.3 Modelos de previsão quantitativos de séries temporais

Na literatura, encontram-se dezenas de modelos de previsão quantitativos de séries temporais. Todavia, Hogarth e Makridakis (1981) mostraram que o aumento da complexidade nos métodos de previsão não aumenta a acurácia dos resultados. Portanto, serão apresentados em seguida: o método do último dado, dois modelos de média (média simples e média móvel), três modelos de suavização exponencial (suavização exponencial simples, modelo de Holt e modelo de Holt Winter's) e o modelo de previsão baseado na Decomposição Clássica.

Utilizaremos nos próximos parágrafos as seguintes notações (inspiradas de Hanke e Reitsch (1998)):

Y_t = Valor observado da série no período t

\hat{Y}_{t+p} = Previsão em t do período t+p

n = Número de observações usadas na previsão

Notações próprias a cada modelo serão explicitadas na descrição do mesmo.

3.3.1. Modelo do último dado

Neste modelo, a previsão para o período subsequente é igual ao último valor observado, ou seja:

$$\hat{Y}_{t+1} = Y_t$$

Este modelo é muito simples e fácil de implementar, já que requer a estocagem de um único dado. Como ele tem como pressuposto de que o último valor é o melhor para prever o futuro, ele costuma apresentar um desempenho ruim quando a demanda apresenta variações freqüentes.

3.3.2. Modelo da média simples

Neste modelo, todos os dados históricos da série temporal são utilizados no cálculo da previsão, que é a média destes valores, conforme a fórmula seguinte:

$$\hat{Y}_{n+1} = \frac{\sum_{t=1}^n Y_t}{n}$$

Este método já é menos sensível às variações do componente aleatório da demanda. Em contraparte, ele demora em reagir às mudanças ocorridas no componente sistemático. Segundo Makridakis e Wheelwright (1978), este modelo é recomendado quando duas condições são reunidas: uma demanda estacionária e distribuída de maneira aleatória.

O método requer que se estoque o histórico inteiro da série, o que já foi visto como um fator crítico, mas que atualmente, com o aumento da capacidade computacional, raramente é um problema.

3.3.3. Modelo da média móvel

Neste método, só as últimas N observações passadas são consideradas no cálculo da média, conforme a fórmula:

$$\hat{Y}_{T+1} = \frac{\sum_{t=T-N+1}^T Y_t}{N}$$

O número de valores considerados não aumenta, como no caso do método da média simples. Cada nova previsão pode ser vista como um ajuste da previsão anterior com o descarte da observação mais antiga (Y_{T-N}) e a inclusão da última observação agora disponível (Y_T), conforme fórmula seguinte. Essa mudança dos valores de referência à medida que novas observações se tornam disponíveis dá o nome ao método.

$$\hat{Y}_{T+1} = \frac{Y_T}{N} - \frac{Y_{T-N}}{N} + \hat{Y}_T$$

A principal dificuldade do método está na escolha do valor de N , que depende do nível de reatividade às mudanças desejada. Quanto maior o valor de N , maior será a suavização na previsão e menor a adaptabilidade do modelo às mudanças da demanda. Mas se a determinação do valor ótimo de N requer várias simulações numéricas, essa particularidade faz também a riqueza do método, pois traz muita flexibilidade, especialmente comparando com os outros métodos de previsão baseados em médias.

O modelo da média móvel dá uma importância maior para os dados mais recentes, uma vez que ele só considera as N últimas observações, mas ele dá o mesmo peso para todas os valores consideradas no cálculo. Isso pode representar uma limitação, uma vez que, conforme explicitado por Makridakis e Wheelwright (1978), “em vários casos, as observações mais recentes contêm mais informação sobre o que vai acontecer no futuro que as mais antigas”.

3.3.4. Modelo de suavização exponencial simples

Os métodos de suavização exponencial são bastante similares ao método da média móvel, tendo como premissa que os dados mais recentes são mais confiáveis e refletem melhor o que irá acontecer no futuro. Porém, eles apresentam duas diferenças fundamentais: eles usam todas as observações disponíveis e ponderam os dados exponencialmente de acordo com o seu período, dando pesos maiores aos dados mais recentes. A fórmula usada é a seguinte:

$$\hat{Y}_{T+1} = \alpha Y_T + (1-\alpha)^2 Y_{T-1} + (1-\alpha)^3 Y_{T-2} + \dots + (1-\alpha)^T Y_1$$

Simplificando a equação, a previsão pode ser expressa como a soma de porcentagens da última previsão e da última observação feitas, calculada como sendo:

$$\hat{Y}_{T+1} = \alpha Y_T + (1-\alpha) \hat{Y}_T$$

A constante α utilizada para a ponderação dos dados históricos é chamada: constante de suavização. O valor dela deve se enquadrar no intervalo $[0;1]$, mas a literatura recomenda o uso da constante entre 0,01 e 0,3. Quanto maior seu valor, maior é o peso dado ao valor atual e quanto menor seu valor, maior importância é dada à previsão anterior. Dessa maneira, ela permite tornar a previsão mais ou menor sensível às variações da demanda. Geralmente, ela é

determinada através de simulação, mas existem também abordagens sistemáticas (como a abordagem chamada de adaptativa).

Esse método é principalmente recomendado para demandas estacionárias, mas devido à sua grande adaptabilidade, fornece bons resultados também com outros tipos de curva.

3.3.5. Modelo de suavização exponencial com tendência (modelo de Holt)

Quando a demanda apresenta tendência, o modelo de suavização exponencial simples reage com atraso ao crescimento ou declínio das vendas, o que tende a subestimar ou superestimar constantemente a demanda. O modelo de Brown soluciona esse problema, considerando a demanda como a soma de dois componentes: um constante (C_T) e um representando a tendência (T_T). Assim:

$$\hat{Y}_{T+1} = C_{T+1} + T_{T+1}$$

O componente constante prevê o nível da demanda e é determinado com o método da suavização exponencial simples e a constante de suavização de nível α , conforme fórmula:

$$C_{T+1} = \alpha Y_T + (1 - \alpha)(C_T + T_T)$$

O componente de tendência prevê o crescimento ou declínio da demanda, e é determinado utilizando uma lógica semelhante. A suavização é feita através da constante de suavização para a tendência β . Quanto maior o crescimento ou declínio observado, maior deverá ser o valor de β . Na equação, o fator β multiplica o crescimento observado da demanda no último período considerado, enquanto o fator $1 - \beta$ cuida da média exponencialmente ponderada do crescimento, ou seja:

$$T_{T+1} = \beta(C_{T+1} - C_T) + (1 - \beta)T_T$$

Os comentários feitos anteriormente sobre a determinação da constante α nesse método também são válidos para β .

3.3.6. Modelo de suavização exponencial com tendência e sazonalidade (modelo de Holt Winter's)

Quando a demanda apresenta flutuações sazonais além da tendência, o método de Holt Winter's é mais adequado que os modelos precedentes. Ele considera a demanda como a soma de três componentes: um constante (C_T), um representando a tendência (T_T) e um fator multiplicativo ligado à sazonalidade (S_T), como explicitado na equação seguinte:

$$Y_T = (C_T + T_T)S_T$$

A lógica por trás do método é semelhante ao modelo de Holt, havendo apenas o acréscimo do fator de sazonalidade nas equações. Desta forma, a previsão é calculada como sendo:

$$\hat{Y}_{T+1} = (C_{T+1} + T_{T+1})S_{T-L+1}$$

onde L é o tamanho do período de sazonalidade

Os componentes constante e de tendência são determinado como no método de Holt, com a diferença de que as equações consideram a demanda desazonalizada, ou seja:

$$C_{T+1} = \alpha \frac{Y_T}{S_{T-L}} + (1 - \alpha)(C_T + T_T)$$

$$T_{T+1} = \beta(C_{T+1} - C_T) + (1 - \beta)T_T$$

O componente de sazonalidade (C_T) também é calculado através de suavização exponencial, conforme equação seguinte:

$$S_T = \gamma \times \frac{Y_T}{C_T} + (1 - \gamma) \times S_{T-L}$$

Esse método é poderoso. Porém, Ballou (2006) recomenda “agir com muita cautela na escolha do modelo” e indica duas condições a serem cumpridas antes da aplicação do método: “1 - Os picos e vales no padrão da demanda precisam ter um motivo conhecido, e devem ocorrer na mesma época todos os anos.

2 – A variação sazonal deve ser maior do que as variações aleatórias ou ruídos.”

3.3.7. Modelo baseado na Decomposição Clássica

Os métodos de decomposição estão, segundo Makridakis e Wheelwright (1978), “entre as abordagens mais antigas”, pois suas bases foram estabelecidas nos anos 1920. Existem várias técnicas, como a Análise Espectral, a Decomposição Clássica e a Análise de Séries de Fourier. Em seguida, será apresentada unicamente a Decomposição Clássica, pois este método possui um tratamento matemático mais simples e, segundo Ballou (2006), “nenhum método mais sofisticado conseguiu oferecer precisão superior à dela”.

Como explicado no parágrafo 3.2.1, a representação matemática geral para esses modelos é:

$$Y_T = f(T_T, S_T, C_T, E_T)$$

Com T_T é o componente de tendência, S_T o de sazonalidade, C_T o de ciclicidade e E_T o erro ou componente randômico.

A equação acima pode ser escrita de duas maneiras diferentes, dependendo da forma em que os componentes interagem entre si. A decomposição pode ser aditiva (equação 1) ou multiplicativa (equação 2).

$$Y_T = T_T + S_T + C_T + E_T \quad (1)$$

$$Y_T = T_T \times S_T \times C_T \times E_T \quad (2)$$

A primeira equação é usada quando a sazonalidade não depende do nível da série, enquanto no segundo caso, a sazonalidade tem um efeito relativo à demanda (ela aumenta conforme o nível da série aumenta).

As séries temporais estudadas no presente trabalho se aproximam do segundo caso. Por causa disso, será descrito a seguir um modelo baseado na decomposição multiplicativa, chamado Razão de Médias Móveis (*ratio-to-moving-average method* in inglês), cujo princípio foi explicitado por Makridakis e Wheelwright (1978), entre outros.

A decomposição consiste nos seguintes passos:

1) Determinação dos índices de sazonalidade

A primeira etapa é o cálculo de uma média móvel M_T , cujo número de termos é igual ao período da sazonalidade. Se os dados apresentam uma sazonalidade diária dentro da semana, e as medições são realizadas diariamente, usaremos então uma média móvel de 7 termos. Isso permite remover tanto o componente randômico, pelo fato de calcular uma média, quanto o efeito sazonal, pelo fato de considerar no cálculo um número de termos igual ao período da sazonalidade. Assim obtemos uma primeira separação:

$$M_T = T_T \times C_T$$

$$\frac{Y_T}{M_T} = S_T \times E_T$$

O segundo passo consiste em isolar o componente sazonal do componente randômico. Para isso, é necessário calcular as razões Y_T/M_T para todos os dados disponíveis e calcular a média delas para cada dia da semana. No final, para obter os índices de sazonalidade será preciso ajustar essas médias, multiplicando-as por um fator de correção para que a soma dos 7 índices seja igual a 7.

2) Determinação da equação de tendência

O cálculo das médias móveis permite separar os componentes de tendência e ciclicidade dos outros. A determinação da equação de tendência é feita usando o Método dos Mínimos Quadrados. Para uma tendência linear (único caso tratado aqui), temos:

$$T_T = a + bT$$

$$b = \frac{n \sum t M_t - \sum t \sum M_t}{n \sum t^2 - (\sum t)^2}$$

$$a = \frac{\sum M_t}{n} - b \frac{\sum t}{n}$$

3) Determinação da ciclicidade

O componente de ciclicidade é obtido pela razão M_T/T_T .

A previsão da demanda é obtida em seguida com os seguintes passos:

- 1) Projeção do componente de tendência, segundo a equação determinada,
- 2) Multiplicação do componente de tendência pelo índice de sazonalidade (índice do dia da semana se se trata de sazonalidade diária dentro da semana),
- 3) Multiplicação do número obtido pelo índice de ciclicidade (cuja projeção requer uma estimativa de especialistas).

3.4 Medidas de erros de previsão e escolha do melhor método de previsão

Conhecer os erros de previsão é de altíssima importância, pois são eles que indicam o quão próximo as previsões estão da demanda real. Eles servem de critério na escolha do melhor método de previsão, avaliam a confiabilidade do modelo escolhido e auxiliam na melhoria do processo de previsão.

Corrêa; Gianesi e Caon (2007) destacam que dois fatores devem ser considerados no monitoramento dos erros: a amplitude e o grau de viés. A amplitude serve para avaliar a confiabilidade das previsões e estimar os riscos que elas incorrem. Por sua vez, a análise do viés permite ver se os erros são distribuídos simetricamente a menos e a mais, ou seja, verificar se a previsão não resulta em valores sistematicamente otimistas ou pessimistas. Caso não haja simetria, a previsão é dita viesada e o erro deve ser imediatamente corrigido.

Existem vários indicadores para medir o erro de previsão. A maioria deles toma como base o erro individual de cada período, também chamado na literatura de residual. Ele é freqüentemente notado e_T e expressado da seguinte maneira:

$$e_T = Y_T - \hat{Y}_T$$

Serão apresentados a seguir alguns modelos básicos de medição. Para todos, quanto menor for o valor do indicador, melhor é a qualidade da previsão. Os quatro primeiros modelos são usados no monitoramento da amplitude do erro, enquanto o último é útil na análise do viés da previsão.

3.4.1. Desvio Absoluto Médio (MAD)

O MAD (*Mean Absolute Deviation*) é a média dos erros absolutos de cada período. Seu cálculo é feito através da fórmula:

$$MAD = \frac{\sum_{t=1}^n |e_t|}{n}$$

Segundo Hanke e Reitsch (1998), esse método é especialmente útil quando o analista procura calcular o erro na mesma unidade que os dados iniciais.

3.4.2. Desvio Quadrático Médio (MSD)

O método do MSD (*Mean Squared Deviation*) usa o quadrado dos erros, visando a penalização das previsões gerando erros de grande amplitude.

$$MSD = \frac{\sum_{t=1}^n (e_T)^2}{n}$$

Esse critério deve ser usado quando se deseja um modelo de previsão apresentando sempre erros moderados, ao invés de modelos produzindo erros pequenos e ocasionalmente erros bem maiores.

3.4.3. Desvio Absoluto Percentual Médio (MAPE)

O método do MAPE (*Mean Absolute Percentage Error*) visa a comparação entre a magnitude dos erros da previsão e a magnitude dos valores reais da demanda. Seu cálculo é feito através da fórmula:

$$MAPE = \frac{\sum_{t=1}^n \frac{|e_T|}{Y_T}}{n}$$

O método é prático, porque ele apresenta os erros em termo de percentagem, o que permite comparar, por exemplo, a acurácia de um modelo em duas séries temporais diferentes.

Porém, ele não pode ser aplicado a itens que possuam esporadicamente demanda nula. Da mesma maneira, os valores de erro para produtos de demanda pequena perdem completamente o sentido.

3.4.4. Desvio Absoluto Percentual Médio Ponderado (WMAPE)

O WMAPE (*Weighted Mean Absolute Percentage Error*) também visa a comparação entre a magnitude dos erros e a magnitude dos valores reais da demanda, mas ele busca solucionar as limitações do MAPE com itens de demanda pequena ou nula. Seu cálculo é feito através da fórmula:

$$WMAPE = \frac{\sum_{t=1}^n |e_t|}{\sum_{t=1}^n Y_t}$$

3.4.5. Desvio Relativo Percentual Médio (MPE)

O método do MPE (*Mean Percentage Error*) apresenta também os erros em termo percentual, mas visa a análise do viés da previsão. Quanto mais próximo de zero, menos viesada é a previsão, conforme fórmula:

$$MPE = \frac{\sum_{t=1}^n \frac{e_t}{Y_t}}{n}$$

Esse indicador é de extrema importância na detecção de erros sistemáticos e deve ser usado no processo de melhoria do método de previsão.

3.4.6. Escolha do modelo

Na literatura, é possível encontrar muitos métodos para auxiliar na escolha da técnica de previsão adaptada a uma determinada série temporal. Dado que a previsão da demanda só representa uma parte do presente trabalho, uma revisão detalhada desses métodos não será feita. Uma apresentação sucinta da guia elaborada por Hanke e Reitsch (1998) é suficiente para o objetivo do trabalho.

Hanke e Reitsch (1998) consideram que os seguintes critérios devem ser considerados na escolha do método de previsão:

- 1) o padrão da demanda (série estacionária ou não, presença de tendência, sazonalidade, ciclicidade),
- 2) o horizonte de planejamento (curto, médio ou longo prazo),
- 3) a aplicabilidade do método (rapidez de execução, aceitação pela gerência...),
- 4) a facilidade de compreensão e interpretação dos resultados,
- 5) o custo do método, critério que, segundo o autor, não fará (se já não é o caso) muito sentido em breve, com os progressos computacionais,
- 6) o desempenho do método, a acurácia dele em comparação aos outros métodos aplicáveis.

Como o presente trabalho se foca nas previsões em curto prazo, somente métodos relacionados foram apresentados. O segundo critério é então considerado como uma hipótese de trabalho. A tabela 3-1 relaciona os modelos apresentados nesta seção com o padrão da demanda, ou seja, com o primeiro critério:

Método	Padrão dos dados
Último dado	Estacionário
Média simples	Estacionário
Média móvel	Estacionário
Suavização exponencial simples	Estacionário
Modelo de Holt	Tendência
Modelo de Holt Winter's	Tendência e Sazonalidade
Decomposição clássica	Tendência, Sazonalidade e Ciclicidade

Tabela 3-1: Resumo dos métodos apresentados e suas aplicações

Os outros critérios serão também examinados na escolha do melhor método, a exceção do quinto, considerado como obsoleto.

4 Revisão Bibliográfica – Gestão de estoques

A gestão de estoques é uma área que continua a suscitar muitos debates nas empresas inseridas no contexto atual onde a competitividade não para de aumentar. Segundo Slack; Chambers e Johnston (2008), “os gerentes de produção usualmente têm uma atitude ambivalente em relação a estoques. Por um lado, eles são custosos, e algumas vezes empalam considerável quantidade de capital. [...] Por outro lado, proporcionam certo nível de segurança em ambientes complexos e incertos.”

4.1 Definição e funções de um estoque

Dentre as várias definições de estoque disponíveis na literatura, é adotada aqui a definição de Love (1979): “Estoque é uma quantidade de bens ou materiais, sob controle da empresa, em um estado relativamente ocioso, esperando por seu uso ou venda.”

O estoque permite compensar o desequilíbrio que existe com freqüência entre etapas de suprimento e de demanda, o que proporciona independência entre as fases. Conforme explicitado por Corrêa; GIANESI e Caon (2007), os estoques costumam ser classificados em três categorias de acordo com o posicionamento no decorrer do processo de manufatura:

- os estoques de matérias-primas, que regulam a diferença entre as taxas de abastecimento pelo fornecedor e de utilização pelo processo de produção,
- os estoques de material semi-acabado, utilizados para compensar diferenças de ritmo entre dois equipamentos subsequentes,
- os estoques de produtos acabados, que regulam as diferenças entre as taxas de produção do processo de manufatura e de demanda do mercado.

Corrêa; GIANESI e Caon (2007) destacam quatro razões principais para a manutenção de estoques:

- Falta de coordenação: em muitos casos, pode ser impossível ou inviável coordenar as fases de um processo de transformação para garantir que o suprimento e o consumo sejam iguais. Dentre os motivos disso, podemos citar os problemas de capacidade (não se consegue adequar a capacidade produtiva

à demanda, como no caso de produtos cuja demanda é sazonal). A “obediência à limitação técnica e/ou econômica de tamanho dos lotes”, proposta por Santoro (2009) também pode constituir um motivo de falta de coordenação.

- Incerteza: nem sempre é possível prever perfeitamente as futuras taxas de demanda, tanto dentro do processo produtivo, quanto por parte dos consumidores finais. Isso justifica a geração de estoques intermediários, bem como de estoques de produtos acabados para se proteger contra faltas. Incertezas de abastecimento de matérias-primas por parte de fornecedores que podem atrasar ou entregar parcialmente implicam também na manutenção de estoques de matérias-primas ou de material semi-acabado.
- Especulação: a criação de estoques pode ser uma decisão puramente estratégica. Prevendo um futuro aumento dos preços de suas matérias-primas, uma organização pode comprar uma grande quantidade antes da escassez, a fim de minimizar seus custos de aquisição.
- Disponibilidade no canal de distribuição: freqüentemente, os centros produtores não se encontram próximos dos mercadores consumidores e existe um tempo necessário para transportar a mercadoria no canal. Para permitir que as mercadorias fluam de maneira continua dentro dos canais de distribuição, é necessária a criação de estoques em vários pontos da cadeia de suprimento.

Ballou (2006) propõe uma classificação levemente diferente, que se aproxima bastante das definições usadas dentro da Danone. Ele considera cinco categorias de estoque distintas:

- o estoque em trânsito, que representa a mercadoria que se encontra no canal de distribuição, seja entre a fábrica e o cliente final, seja entre diferentes operações de produção,
- o estoque mantido por fins de especulação, conforme explicado no parágrafo anterior,
- o estoque regular, cuja função é de satisfazer a demanda entre dois reabastecimentos sucessivos,
- o estoque de segurança, que visa compensar a variabilidade da demanda e dos prazos de reposição,
- o estoque obsoleto (chamado de estoque virtual na Danone), que representa as quantidades de mercadoria deteriorada, vencida, ultrapassada ou roubada.

4.2 Objetivos da modelagem de estoques

Ballou (2006) propõe três classes gerais de custos relativos aos estoques. Estas classes estão “permanentemente em conflito, ou em compensação entre si”:

- os custos de aquisição, que incluem os custos dos itens comprados, os custos de preparação, processamento e transmissão dos pedidos e os custos de transporte e de manuseio dos materiais,
- os custos de manutenção do estoque, que incluem os custos do espaço de armazenamento, os custos de capital ligados ao montante investido em estoque (custos de oportunidade), os seguros e impostos, bem como os custos de riscos de estocagem provenientes de deterioração, quebra, obsolescência e furto.
- os custos de falta de estoques, que se desdobram em custos de perda de vendas quando a falta é sinônimo de não atendimento, e em custos de pedidos atrasados, quando o cliente está disposto a esperar o atendimento do pedido.

Segundo Santoro (2009), a modelagem de estoques tem normalmente o objetivo de minimizar o custo global, diretamente ou indiretamente. Na prática, esse objetivo macro pode se traduzir de várias maneiras em função do peso relativo das três classes de custo descritas anteriormente e do foco da gerência. Podemos citar como objetivos individuais a minimização dos estoques do sistema global, do custo dos materiais comprados ou ainda das faltas, como será o foco nesse trabalho.

4.3 Modelos de estoques

Na literatura, acham-se vários modelos de reposição de estoque. Todos auxiliam na determinação das variáveis de decisão que são: decisão de variedade (o que pedir?), decisão de tempo (quando pedir?) e decisão de quantidade (quanto pedir?). Eles diferem na forma de determinação das variáveis.

4.3.1. Classificação dos modelos

Santoro (2006) sugere uma classificação completa segundo vários critérios. Dentre eles, podemos citar o uso de previsões de demanda na tomada de decisão, o que distingue os modelos reativos, para os quais a determinação das variáveis de decisão não requer previsão de demanda, dos modelos ativos que a utilizam. Outro critério de classificação é a freqüência de revisão (decisão de tempo): existem modelos de revisão periódica e modelos de revisão contínua. A variabilidade da quantidade pedida (decisão de quantidade) também varia dependendo do método usado; os modelos podem trabalhar com quantidade fixa de reposição, com quantidade variável em função do nível máximo e atual ou ainda com quantidade variável em função da previsão de demanda. Enfim, podemos citar o atendimento da demanda, que pode permitir ou não as faltas.

Serão usadas as notações seguintes, inspiradas de Santoro (2006) e ilustradas na figura 4-1:

PerRev = período de revisão

TEsp = tempo de espera ou lead-time (é a antecedência normal para se tomar ou alterar decisões de abastecimento)

TRes = tempo de resposta ou tempo de reação (é o tempo decorrido entre uma tomada de decisão de abastecimento e a próxima data onde se pode influenciar fisicamente o estoque)

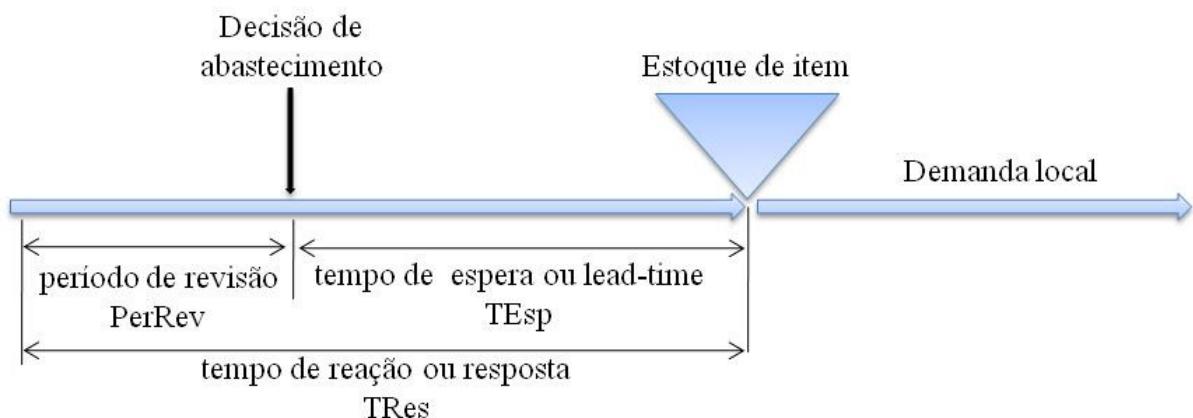


Figura 4-1: Componentes de um sistema de gestão de estoques
(adaptado de Santoro, 2006)

Para modelos periódicos, temos: $TRes = TEsp + PerRev$

Para modelos contínuos, temos: $TRes = TEsp$

Um modelo contínuo pode ser visto como um modelo periódico cujo período de revisão é muito pequeno. Na maioria dos casos práticos, um modelo contínuo é um modelo de revisão diária. Por causa disso, só a versão periódica dos modelos será explicitada a seguir. Serão apresentados quatro modelos, três reativos e um ativo.

Utilizaremos nos próximos parágrafos as notações seguintes (inspiradas de Santoro (2006)):

PerRev = Período de revisão

EstFis = Estoque físico

EstARec = Estoque a receber no tempo de espera

EstDisCP = Estoque disponível a curto prazo ($\text{EstDisCP} = \text{EstFis} + \text{EstARec}$)

EstMax = Estoque máximo

EstSeg = Estoque de segurança

OCompra = Quantidade a comprar calculada no instante de decisão de abastecimento

Notações próprias a cada modelo serão explicitadas na descrição do mesmo.

4.3.2. Modelo de Reposição do Máximo

Este modelo reativo funciona da seguinte maneira: o estoque a curto prazo é verificado a cada instante de decisão de abastecimento (seja a cada momento de revisão nos modelos periódicos, seja depois de cada retirada nos modelos contínuos). Se seu nível for inferior a um limite preestabelecido, chamado de “ponto de pedido”, encomenda-se uma quantidade que iguale o estoque ao máximo. Caso contrário, nada é comprado. A regra de decisão pode ser modelada da seguinte forma:

$$\text{OCompra} = \begin{cases} (\text{EstMax} - \text{EstDisCP}) & \text{se } \text{EstDisCP} < \text{PtoPed} \\ 0 & \text{se } \text{EstDisCP} \geq \text{PtoPed} \end{cases}$$

com PtoPed = Ponto de pedido (parâmetro de quantidade em estoque que determina a decisão de compra)

O ponto de pedido costuma ser determinado a partir da demanda considerada máxima (DemMax) e do tempo de reação (TRe), conforme a equação:

$$\text{PtoPed} = \text{DemMax} \times \text{TRe}$$

Isso pode ser escrito em função da demanda média (DemMed) e do estoque de segurança (EstSeg) da seguinte maneira, conforme mostrado na figura 4-2:

$$\text{PtoPed} = \text{DemMed} \times \text{TRe} + \text{EstSeg}$$

$$\text{com } \text{EstSeg} = (\text{DemMax} - \text{DemMed}) \times \text{TRe}$$

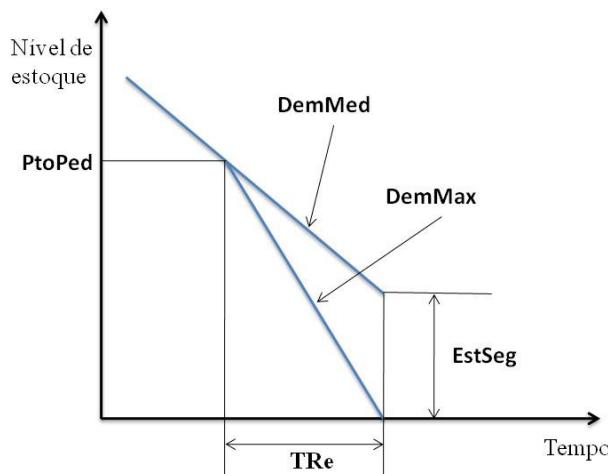


Figura 4-2: Determinação do ponto de pedido

4.3.3. Modelo de Reposição da Base

Nesse modelo reativo, a cada instante de decisão de abastecimento, o estoque a curto prazo é analisado. Se ele for menor que o estoque máximo, é comprada a quantidade necessária para que o estoque atinja o estoque máximo, conforme equação seguinte:

$$\text{OCompra} = (\text{EstMax} - \text{EstDisCP})$$

Este modelo pode ser visto como um caso particular do precedente, quando o ponto de pedido é igual ao estoque máximo. Essa característica do modelo faz com que a freqüência de emissão de pedidos tenda a ser alta. Sendo assim, o modelo não é recomendado quando os custos de aquisição são altos. Além disso, uma reposição da base é de difícil aplicação para produtos altamente perecíveis, especialmente quando a demanda tem uma previsibilidade baixa, como é o caso de alguns SKU/loja estudados.

4.3.4. Modelo do Lote Fixo

No modelo reativo de decisão do lote fixo, a quantidade adquirida é sempre um múltiplo de uma quantidade chamada “lote fixo”. A cada instante de decisão de abastecimento, o estoque a curto prazo é analisado. Caso seja inferior ao “ponto de pedido”, encomenda-se a menor quantidade múltipla do lote fixo que garanta que o estoque a curto prazo supere o ponto de pedido. Isso pode ser modelado da seguinte forma:

$$OCompra = \begin{cases} n \times LotFix & \text{se } EstDisCP < PtoPed \\ 0 & \text{se } EstDisCP \geq PtoPed \end{cases}$$

com $LotFix =$ Lote fixo (quantidade' fixa de itens formando um lote fixo por algum motivo)
 $n =$ menor inteiro que garanta após a compra a condição: $EstDisCP \geq PtoPed$

O lote fixo pode ser determinado com vários critérios. Quando ele é calculado otimizando-se uma determinada função de custo, ele é chamado de “lote econômico”.

4.3.5. Modelo do Cálculo de Necessidades

O Cálculo de Necessidades é um modelo proposto por Santoro (2006), com base no sistema Material Requirements Planning (MRP). É um modelo ativo: ele requer a disponibilização de previsões de demanda. O principal parâmetro dele é o EstSeg (estoque de segurança), cujo papel é de cobrir os desvios de previsão (e não de compensar as variações de demanda, como nos modelos reativos). O EstSeg será função do nível de atendimento desejado.

Para entender o funcionamento do modelo será apresentado o exemplo dado por Santoro (2006). Serão usadas as notações específicas seguintes:

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

$NLiq_{t,p}$ = necessidade líquida em t a ser entregue no final de p períodos adiante

$OCompra_{t,p}$ = quantidade a comprar decidida em t a ser entregue no final de p períodos

Além das informações disponíveis na figura 4-3, consideremos os valores numéricos:
 $TEsp = 3$, $PerRev = 1$ e $EstSeg = 10$.

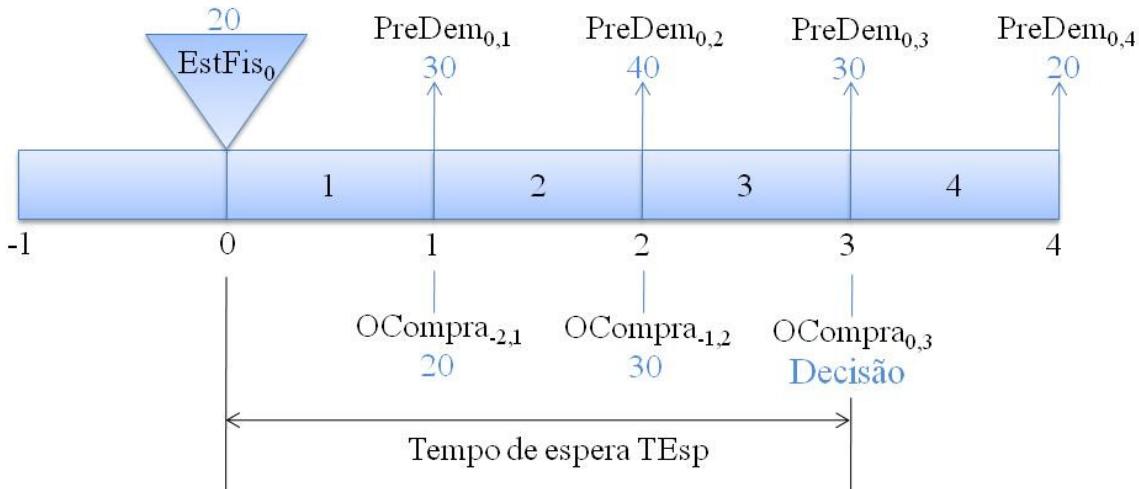


Figura 4-3: Esquema de decisão do Modelo de Cálculo de Necessidades
(extraído de Santoro, 2006)

Para determinar $OCompra_{0,3}$, precisamos calcular a Necessidade Líquida no instante zero, de forma que as demandas previstas sejam atendidas e tenha-se o estoque de segurança no estoque físico ao final do período 4. Isso resulta em:

$$NLIq_{0,3} = \sum_{i=1}^4 \text{PreDem}_{0,i} - \sum_{i=1}^2 OCompra_{t-i} - EstFis_0 + EstSeg_{i-3,i}$$

$$NLIq_{0,3} = (30+40+30+20)-(20+30)-20+10=60$$

A equação geral do procedimento de decisão no final dos períodos é:

$$NLIq_{t,t+TEsp} = \sum_{i=1}^{T_{Res}} \text{PreDem}_{t,t+i} - \sum_{i=1}^{TEsp-1} OCompra_{t+i-Tesp,t+i} - EstFis_t + EstSeg$$

A decisão de compra pode ser calculada segundo a regra:

$$OCompra_{0,3} = \begin{cases} NLIq_{0,3} & \text{se } NLIq_{0,3} > 0 \\ 0 & \text{se } NLIq_{0,3} \leq 0 \end{cases}$$

Assim, no exemplo, serão encomendadas 60 unidades no instante inicial, com previsão de chegada para $t=3$. Se não têm desvios de previsão, o período 4 encerrará com 10 unidades de mercadoria, ou seja, com o estoque de segurança.

Esse modelo procura comprar o estritamente necessário, conforme filosofia do Just In Time. Isso é particularmente interessante para o presente trabalho, que busca gerenciar os estoques no varejo, com o objetivo de reduzir a cobertura média dos produtos sem deixar o índice de ruptura subir.

Freire (2007) efetuou uma análise comparativa do desempenho dos modelos de estoques apresentados anteriormente, submetendo-os a uma grande diversidade de situações de demanda e custos. Ele concluiu que “os resultados mostraram um desempenho superior do modelo de Cálculo de Necessidades, em quase todos os ambientes testados”, o que reforça a escolha do modelo ativo para o presente estudo.

5 Escolha da amostra de trabalho

5.1 Amostra de lojas

5.1.1. Critérios usados na definição da amostra de lojas

Para selecionar uma amostra representativa, os critérios seguintes foram usados:

a. Localização geográfica

A filial do varejo internacional estudado é composta de 124 lojas, localizadas no Sul do Brasil e divididas da seguinte maneira:

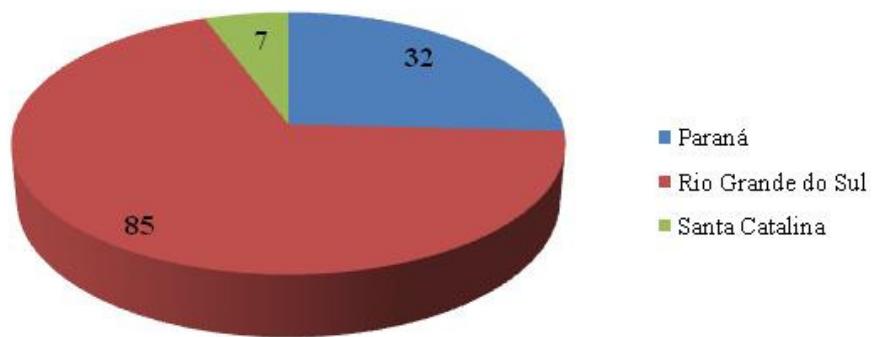


Figura 5-1: Divisão geográfica das lojas

b. Distribuição

Na maioria dos casos, a distribuição é direta e a loja recebe a mercadoria no dia seguinte ao faturamento do pedido (exceto mercadoria faturada na sexta-feira que pode ser recebida no sábado ou na segunda, dependendo da política de recebimento da loja). No entanto, algumas lojas muito isoladas situadas no interior dos estados do Paraná e do Rio Grande do Sul são atendidas via distribuidores terceirizados. Nesse caso, a mercadoria chega ao centro de distribuição do distribuidor no dia seguinte do faturamento e o distribuidor pode demorar até três dias para entregar os pedidos na loja do cliente, dependendo de sua acessibilidade.

O gráfico a seguir ilustra a divisão das lojas segundo esse critério.

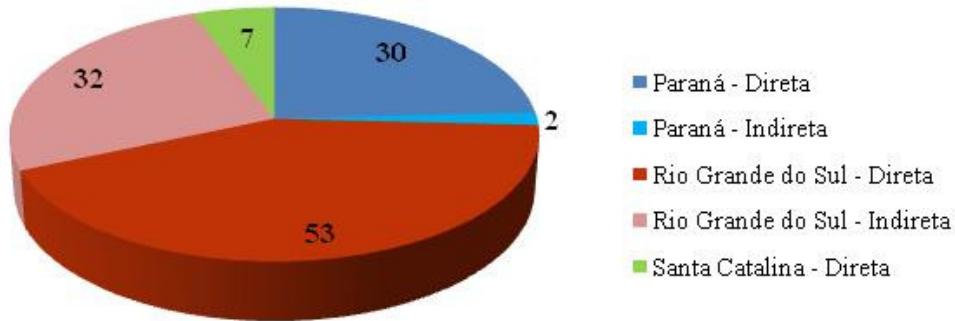


Figura 5-2: Divisão das lojas por tipo de distribuição

c. Bandeira

As lojas analisadas são de três bandeiras diferentes. A fim de não infringir a confidencialidade, essas bandeiras serão nomeadas: B1, B2 e B3. Elas diferem pelo público alvo e o portfólio proposto, porém as operações de abastecimento e de logística são as mesmas. A divisão das lojas por bandeira é a seguinte:

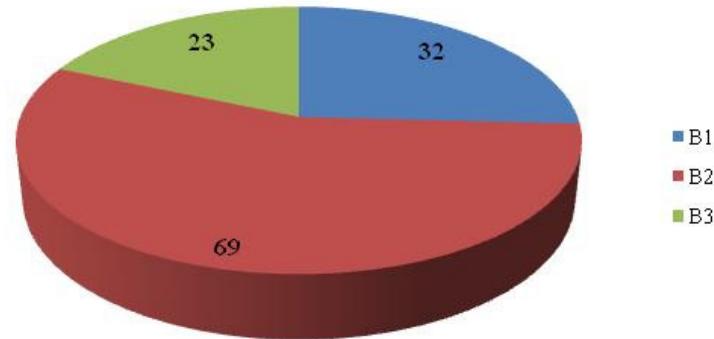


Figura 5-3: Divisão das lojas por bandeira

d. Volume de venda médio

A partir da análise dos dados de venda semanal média desde o inicio do ano de 2009, foi possível identificar as lojas com volume alto, médio e baixo. A seguinte classificação foi usada:

- Volume alto → volume semanal > 1.000 kg
- Volume médio → 400 kg < volume semanal ≤ 1.000 kg
- Volume baixo → volume semanal ≤ 400 kg

O gráfico a seguir foi construído a partir dessa convenção.

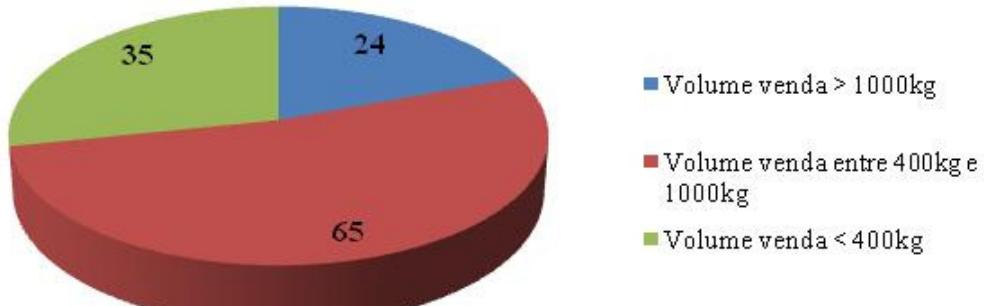


Figura 5-4: Divisão das lojas por volume de venda

e. Ruptura média

A percentagem média de produtos em ruptura em cada loja desde o inicio do ano de 2009 é um indicador importante da maturidade do processo de abastecimento. Para determinar essa percentagem, foram usados dados diários de estoque atual e de venda média diária para cada SKU em cada loja. Segundo definição das lojas do estudo, um item é considerado em ruptura se o estoque atual do SKU é inferior à venda média diária daquele produto (ou seja, um dia de cobertura). Como a meta de ruptura máxima de 2009 é de 2% e a meta do ano de 2008 era de 5%, foi usada a seguinte classificação:

- Ruptura baixa → Índice de ruptura < 2%
- Ruptura média → 2% < Índice de ruptura ≤ 5%
- Ruptura alta → Índice de ruptura > 5%

Com essa definição, obtém-se a divisão ilustrada no gráfico a seguir:

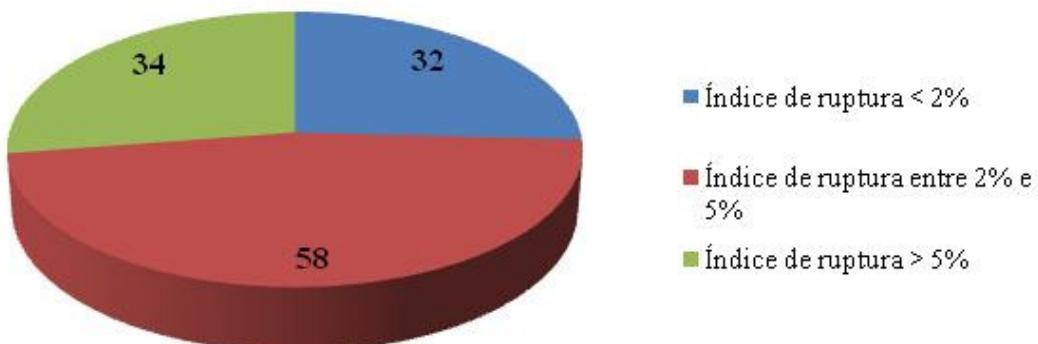


Figura 5-5: Divisão das lojas por nível de índice de ruptura

f. Freqüência de pedido

Tanto a freqüência quanto os dias de pedido e recebimento são pré-estabelecidos em um documento chamado “plano de campo das lojas”, que foi revisto e atualizado no ano passado. Segundo esse plano, a freqüência mínima de visita às lojas é de uma vez por semana e a freqüência máxima é de três vezes por semana.

5.1.2. Amostra de lojas escolhida

A partir desses seis critérios, sete lojas foram escolhidas. Isso representa quase 6% das lojas monitoradas. A tabela a seguir apresenta essa seleção e as características de cada loja em relação aos critérios.

Número Loja	Bandeira	Estado	Cidade	Distribuição	Lead Time teórico	Volume Venda	Índice Ruptura	Dias Pedido	Dias Recebimento
L1	B3	PR	Curitiba	direta	1 dia	médio	alto	2a, 4a, 6a	3a, 5a, sab
L2	B3	PR	Curitiba	direta	1 dia	baixo	médio	3a, 6a	4a, sab
L3	B2	RS	Guaíba	direta	1 dia	médio	baixo	2a, 5a	3a, 6a
L4	B1	RS	Porto Alegre	direta	1 dia	alto	baixo	2a, 4a, 6a	3a, 5a, sab
L5	B1	RS	Uruguaiana	indireta	2 dias	alto	médio	6a	2a
L6	B2	RS	Xangri-Lá	indireta	1 dia	baixo	alto	3a, 6a	4a, 2a
L7	B1	SC	Florianopolis	direta	1 dia	alto	médio	2a, 5a	3a, 6a

Tabela 5-1: Características das lojas selecionadas

5.2 Amostra de SKUs

5.2.1. Critérios usados na definição da amostra de SKUs

Para selecionar uma amostra representativa, foram usados os seguintes critérios:

a. A família e a marca

Na Danone, os produtos lácteos são convencionalmente divididos em quatro grandes famílias, com diferentes desempenhos no mercado e público alvo.

A família Activia

Activia, na verdade não é um produto e sim uma linha de produtos que tem por objetivo regular o intestino de seus consumidores. Esta linha é composta por iogurtes naturais, iogurtes com frutas e leite fermentado.



Figura 5-6: Produtos da marca Activia

Os produtos Activia ajudam a regular o trânsito intestinal em pessoas com o trânsito lento, graças à ação do exclusivo bacilo DanRegularis que é fruto do centro de pesquisas para a saúde da Danone.

A família Danoninho

Danoninho é uma marca de nutrição infantil. Os produtos da linha são enriquecidos com Cálcio, Ferro, Zinco, Fósforo e Vitaminas para complementar a alimentação das crianças de idade pré-escolares.



Figura 5-7: Produtos da marca Danoninho

Este produto foi reelaborado após um grande estudo das necessidades alimentares das crianças no Brasil. Oferecendo produtos variados na linha Danoninho, a Danone busca superar os padrões de qualidade dos produtos concorrentes, focando na melhora do crescimento mental e físico dos bebês e crianças assim como no fortalecimento do sistema imunológico dos mesmos.

A família Corpus

Corpus é o Iogurte Light da Danone, com 0% de gordura e sem adição de açúcares. Corpus ainda possui VitaCal que, em uma porção de 100g supre 22% das necessidades diárias de cálcio e de vitaminas A e D de um adulto. Corpus Light oferece nutrientes que devem fazer parte de uma dieta balanceada, sendo uma opção para quem se preocupa com a alimentação, o bem-estar e a qualidade de vida.



Figura 5-8: Produtos da família Corpus

A família Actimel

Essa família é a última nascida da Danone no Brasil. Actimel é uma bebida probiótica que contém um fermento especial, o L. Casei Imunitass, que ajuda a reforçar as defesas naturais do organismo. Como essa família só foi lançada em 2009, não disporemos de dados históricos suficientes para poder incluir um dos SKUs dessa família em nossa amostra.



Figura 5-9: Produtos da família Actimel

A família Base Business

Essa família reúne todos os outros produtos lácteos frescos da Danone. Não julgamos pertinente criar outras categorias especiais, porque as outras marcas não têm um desempenho excepcional, nem um reconhecimento diferenciado no mercado. Essa família contém várias subfamílias, como, por exemplo:

- *Danette*, que é uma linha de sobremesas lácteas,



Figura 5-10: Produtos da marca Danette

- *Danito*, que é a marca de produtos lácteos caçula da Danone no Brasil voltada para crianças e pré-adolescentes. A linha possui a polpa de frutas com cereais coloridos e cereais de chocolate, o Leite Fermentado e o flan de chocolate, além da bandeja de polpa com seis potes.



Figura 5-11: Produtos da marca Danito

- *Dan'up*, que é a linha de bebidas lácteas da Danone, especialmente formulada para jovens que se preocupam com a saúde.



Figura 5-12: Produtos da marca Dan'up

b. A forma

Um mesmo produto pode ser comercializado sob formas e embalagens diferentes, que não têm o mesmo público alvo. O produto Activia Morango, por exemplo, é disponível em iogurte de polpa ou em forma de iogurte líquido para beber. O iogurte de polpa é comercializado em embalagens de quatro ou oito potinhos de 100g, que obviamente não são destinados a famílias do mesmo tamanho. Também é possível encontrar potinhos vendidos unitariamente. Da mesma maneira, o Activia líquido é vendido em garrafinha de 180g ou garrafão de 900g. O critério da forma de comercialização é pertinente, porque os diferentes SKUs do mesmo produto bruto podem ter comportamentos muito diferentes nas gôndolas.

c. A validade

Os produtos lácteos frescos da Danone têm uma validade de 30 a 45 dias, dependendo da forma de comercialização e do sabor do produto. É tradicionalmente considerado que um produto chega à gôndola aproximadamente uma semana após sua fabricação, o que reduz o tempo real máximo de permanência na loja. Como a validade terá impacto sobre a freqüência de pedidos, parece importante escolher produtos com diferentes períodos de validade.

d. A posição no ciclo de vida

O ciclo de vida de um produto pode ser representado na seguinte figura:

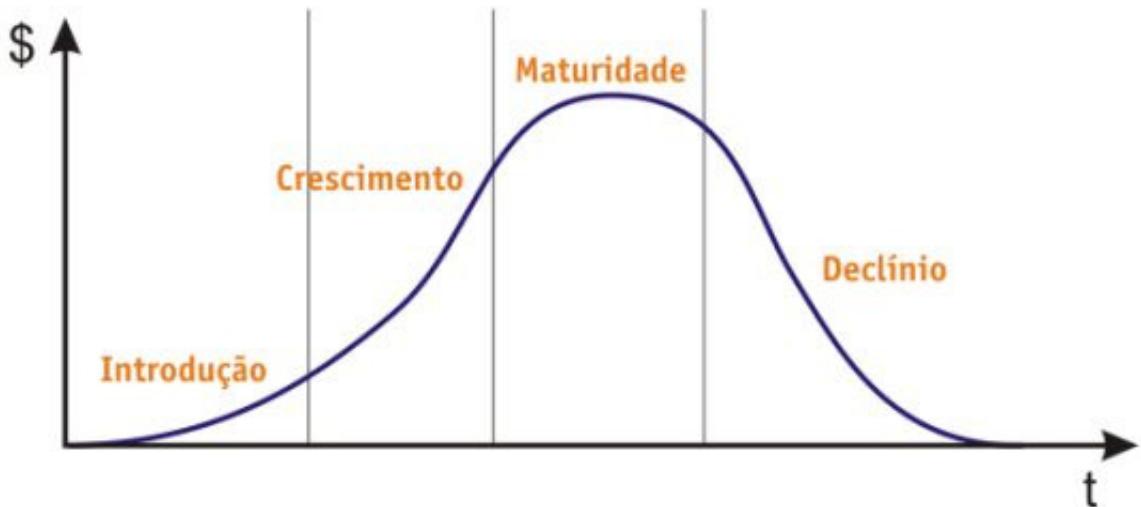


Figura 5-13: Ciclo de vida do produto
(adaptado de Slack; Chambers e Johnston, 2008)

Na amostra dessa primeira etapa do trabalho, pode ser interessante escolher SKUs em fases diferentes, porque o tratamento para a previsão de demanda, por exemplo, obedecerá com certeza a problemáticas diferentes.

e. O giro

O giro de um SKU é um parâmetro importantíssimo para a etapa de previsão de demanda, mas não é um indicador fácil de calcular. Nessa primeira etapa de seleção, não foram levantados dados quantitativos. Foi considerado que uma análise qualitativa é suficiente.

5.2.2. Amostra de SKUs escolhida

A partir dos cinco critérios de escolha apresentados anteriormente, seis SKUs foram escolhidos para a primeira fase do trabalho. Isso representa 10% dos itens monitorados. A tabela a seguir apresenta essa seleção e as características de cada SKU em relação aos critérios:

Código SKU	Família	Subfamília	Forma	Validade	Posição Ciclo Vida	Giro	Quantidade de unidades por caixa
A	Activia	Activia	garrafinha	40 dias	crescimento	médio	42
B	Activia	Activia	garrafão	45 dias	crescimento	alto	15
C	Base Business	Danone	6 potinhos de 100g	45 dias	maturidade	alto	10
D	Base Business	Danito	potinho unitário de 130g	45 dias	declínio	baixo	18
E	Corpus	Corpus	6 potinhos de 90g	40 dias	maturidade	médio	10
F	Danoninho	Danoninho	8 potinhos de 45g	40 dias	maturidade	alto	18

Tabela 5-2: Características dos SKUs escolhidos

6 Módulo de previsão de demanda

Como explicado no parágrafo 2.4, o objetivo desse trabalho é criar um modelo de decisão a ser usado na elaboração dos pedidos pelos promotores das lojas do varejista estudadas. Esse modelo de decisão será composto de um módulo de previsão de demanda que abastecerá o módulo de gestão de estoque propriamente dito. Esta parte se focará no primeiro módulo, ou seja, na previsão de demanda.

6.1 Coleta e tratamento de dados

6.1.1. Coleta de dados

O levantamento de dados constitui o primeiro passo do processo de previsão de demanda. Segundo Hanke e Reitsch (1998), essa etapa é com freqüência a parte mais desafiadora do processo inteiro e problemas na coleta e no controle de qualidade dos dados são comuns.

Os dados históricos das lojas estudadas são fornecidos pelo próprio varejo, que disponibiliza alguns relatórios via Internet. Como já foi explicado anteriormente, o nome do varejo não pode ser revelado no presente trabalho por razão de confidencialidade. Por causa disso, o endereço do site também não será divulgado.

Para o nível de detalhamento temporal dos dados, precisamos coletar a demanda diária, pois a freqüência de emissão de pedido varia entre uma vez e três vezes por semana, dependendo do plano de campo das lojas. O site do varejo é atualizado diariamente e não estoca os dados passados, se bem que é necessário baixar as informações todos os dias para não perder o histórico dos valores. Foi possível ter acesso a informações sobre o histórico de vendas diárias no nível SKU/loja desde setembro de 2008. Antes dessa data, só estão disponíveis os valores consolidados por loja ou por item, o que tem pouca utilidade para a nossa previsão, já que o nosso objetivo é auxiliar na elaboração dos pedidos de cada SKU em cada loja. A coleta de dados teve, portanto como horizonte de tempo o período de setembro de 2008 até outubro de 2009. Como os dados foram coletados diariamente, obtivemos 391 valores históricos para cada SKU/loja.

Modelos quantitativos necessitam de uma base de dados referente a um período de tempo relativamente longo, especialmente para montar análises de sazonalidade. Como só temos acesso a informações de um ano, não poderemos analisar evoluções sazonais anuais. Isso não constitui um problema tão grande, uma vez que, segundo analistas que já têm vários anos de experiência dentro da Danone, os nossos produtos não costumam apresentar sazonalidade mensal dentro do ano relevante.

6.1.2. Tratamento de dados

O sistema de informação do varejo permite obter as vendas diárias de cada SKU/loja bem como o nível do estoque dos itens no inicio do dia. Uma primeira correção importante a fazer é a detecção e o ajuste dos dias “excepcionais”, tais como feriados, dias de inventário... Normalmente, as lojas do estudo ficam abertas de domingo a domingo. Portanto, para localizar os dias excepcionais, basta filtrar os dias com venda total zerada (todos os SKUs do estudo confundidos). Em seguida, é necessário investigar o motivo da queda de venda e reajustar a demanda usando a venda média daquele dia da semana. Esse método permitiu detectar e corrigir um total de 40 “dias excepcionais” na nossa amostra.

Outro problema é o fato de que as vendas diárias não refletem exatamente a vontade de consumo, uma vez que pode faltar mercadoria nas gôndolas. Para resolver esse primeiro problema, é necessário corrigir as quantidades vendidas com a avaliação de faltas. Como as lojas do estudo não contabilizam o não-atendimento, foi montada uma regra prática para estimar o que faltou.

Calculamos a venda média diária e a venda média por dia da semana para cada SKU/loja. Tentamos primeiramente identificar “situações de perigo de ruptura”, ou seja, dias nos quais é provável ter faltado mercadoria usando a seguinte regra. Um dia D foi considerado “situação de perigo de ruptura” para um determinado SKU/loja se tinha menos de um dia de cobertura no estoque da loja à noite, conforme explicado na figura 6-1. Essa margem de segurança de um dia se justifica pelo fato que, às vezes, a quantidade que aparece no sistema não representa exatamente o que tem na gôndola, por causas diversas (quebra de produto ainda não registrada no sistema, mercadoria presente na câmara fria, mas ainda não colocada na gôndola...). Para essas “situações de perigo”, foi verificado se a venda do dia foi inferior à venda média para aquele dia da semana (ver figura 6-1). Em caso positivo,

consideramos que pode ter faltado produto e a venda foi reajustada para atingir essa média. A figura 6-1 resume o raciocínio.

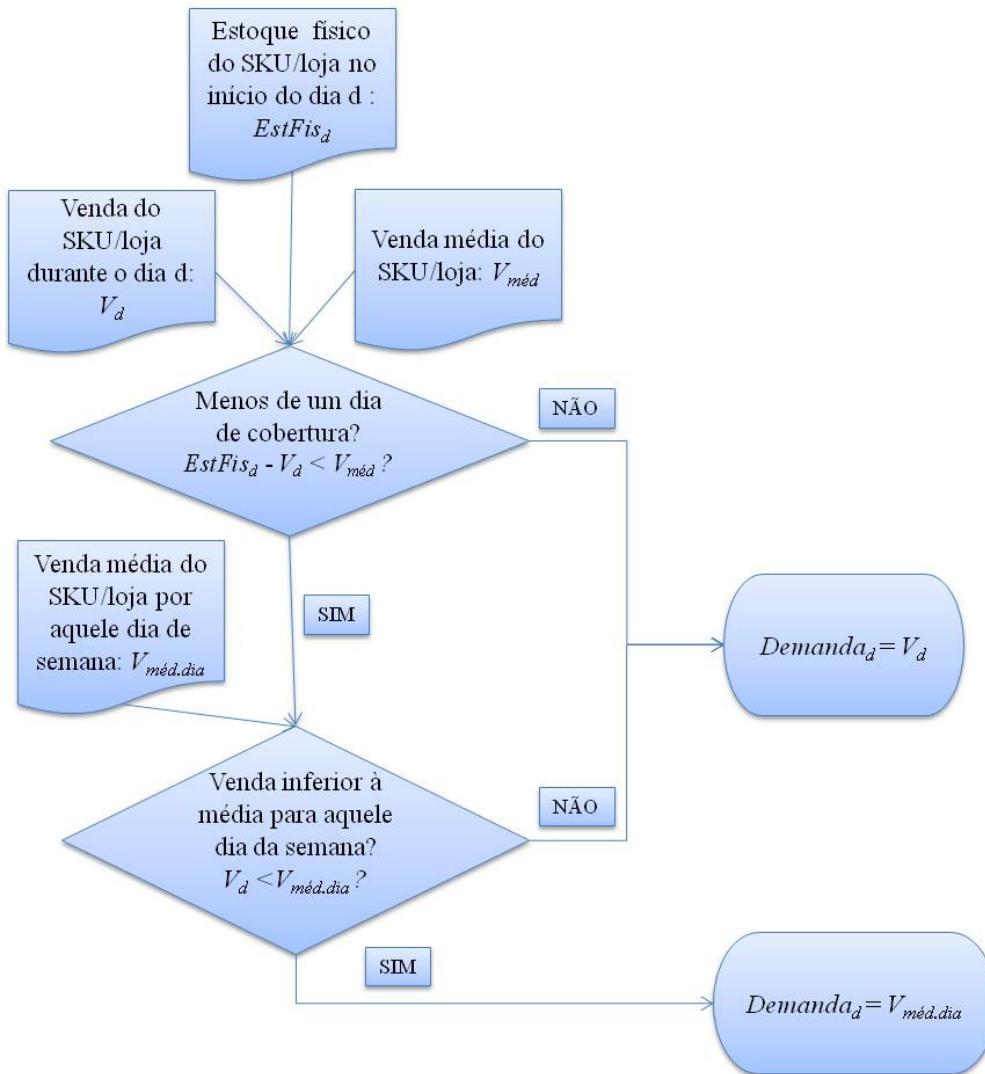


Figura 6-1: Regra de correção das vendas com a avaliação de faltas

Com esse método foram reajustados 4,0% dos dados, o que parece coerente com a ruptura média dos SKU/loja estudados, que é da ordem de 5,0%.

Segundo Santoro (2009), para melhorar ainda a qualidade dos dados de entrada, precisaria corrigir os efeitos dos descontos, campanhas promocionais e propagandas, bem como das políticas de preços e propagandas dos concorrentes que podem gerar alterações, antecipações ou postergações de demanda. Infelizmente, não temos informações sobre esses fatores. Acreditamos que essa falta prejudica o conhecimento sobre os eventos que influenciam a demanda, mas que ela não invalida a previsão a seguir.

6.2 Análise dos dados e procura do padrão de demanda

A análise dos dados foi realizada em julho de 2009: foram usados dados históricos do período de setembro de 2008 até julho de 2009.

6.2.1. Análise gráfica

A observação gráfica dos dados históricos é geralmente o primeiro passo para analisar o comportamento da demanda e tentar identificar a existência de sazonalidades e tendências. Como precisamos trabalhar com dados diários, obtemos uma série de mais de 300 valores para cada SKU/loja. Segue um exemplo da evolução da demanda, para o SKU B na loja L7. Por razão de confidencialidade, a escala não será colocada.

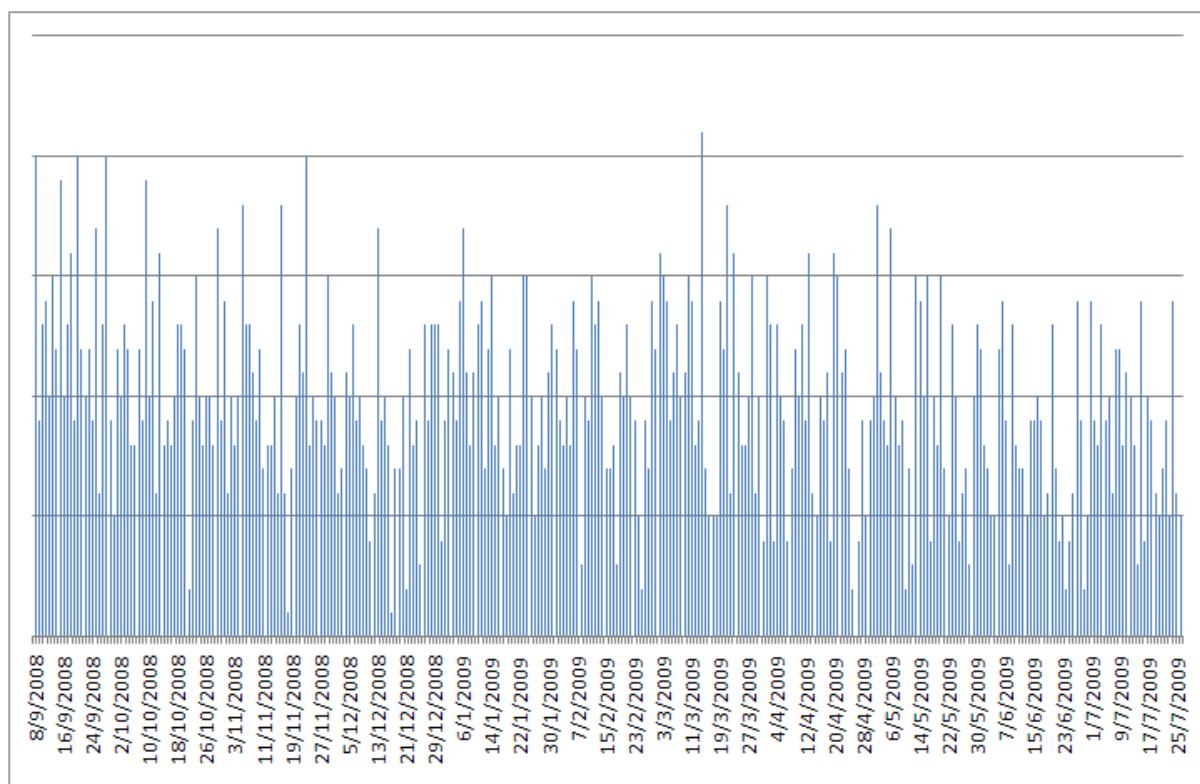


Figura 6-2: Demanda do SKU B na loja L7

Uma análise detalhada desse gráfico e de vários outros (para outros SKU/loja) parece indicar uma sazonalidade diária dentro da semana, com aumento das vendas no final da semana, o que é bastante comum para os bens de consumo.

Dá para sentir o grau alto de dificuldade para analisar visualmente a demanda em um nível tão detalhado (SKU/loja/dia), e isso para todos os SKUs e todas as lojas da amostra! Por causa disso, pode ser mais metódico e conveniente usar uma ferramenta sistemática, como a análise de autocorrelação.

6.2.2. Análise de autocorrelação

A análise de autocorrelação e a construção dos autocorrelogramas (representações gráficas que compilam os coeficientes de autocorrelação r_k de uma série temporal em suas diferentes defasagens) foram desenvolvidas no software Microsoft Excel®.

a. Identificação de sazonalidade diária na semana

Consideramos na nossa amostra 7 lojas e 6 SKUs, totalizando 42 combinações de SKU/loja a testar. Cada série temporal contém 322 valores com medições diárias (do dia 08/09/2008 até o dia 26/07/2009), o que corresponde a 46 semanas de dados. Os coeficientes de autocorrelação foram calculados até a defasagem (ou *lag*) 21. Como explicitado no parágrafo 3.2.2, usando uma percentagem de confiança de 95%, podemos calcular o valor V_{lim} a partir do qual os coeficientes serão considerados relevantes com a seguinte fórmula:

$$V_{lim} = 1,96/\sqrt{n}$$

Ou seja, $V_{lim} = 0,109227$ com $n = 322$ valores

Usamos o método descrito no fluxograma da figura 3-1 para identificar o comportamento das séries temporais. Segue na figura 6-3 o autocorrelograma montado para o SKU B na loja L7 (exemplo do parágrafo precedente). Nesse exemplo, a conclusão é direta: a demanda apresenta sazonalidade diária na semana (defasagem 7), o que confirma a análise visual realizada anteriormente.

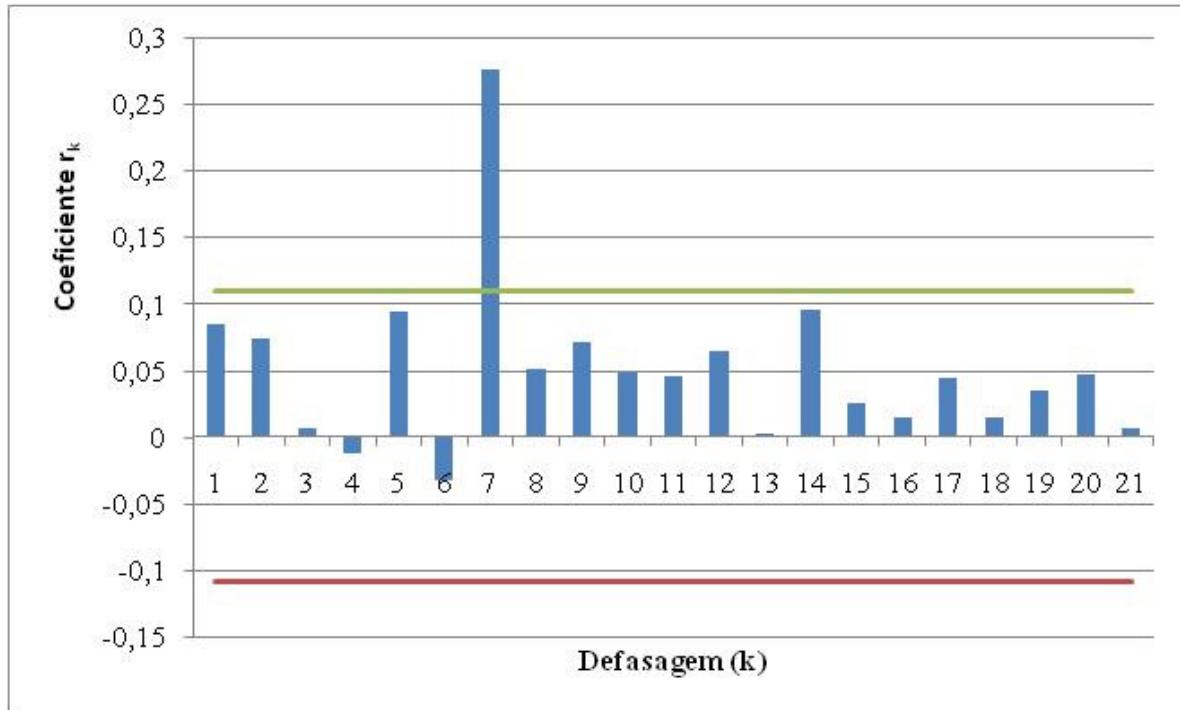


Figura 6-3: Autocorrelograma do SKU B na loja L7

Fizemos a análise para as 42 combinações e obtemos 55% de séries temporais sazonais, conforme mostrado na tabela 6-1.

Comportamento	Percentagem de ocorrência
Sazonalidade semanal com Tendência	31%
Sazonalidade semanal sem Tendência	24%
Aleatoriedade	45%

Tabela 6-1: Percentagens de ocorrência dos comportamentos das 42 combinações

Procuramos entender melhor o perfil das combinações que resultaram em aleatoriedade. Verificamos que, na maioria dos casos, tratam-se dos SKUs e das lojas com venda média baixa, pois para estes SKU/loja, uma unidade vendida a mais ou a menos já pode possuir um impacto grande! Segue nas figuras 6-4 e 6-5 o exemplo do SKU D na loja L2, cuja demanda é muito baixa. Nenhum coeficiente de correlação (fora do de defasagem 1) mostrou-se relevante.

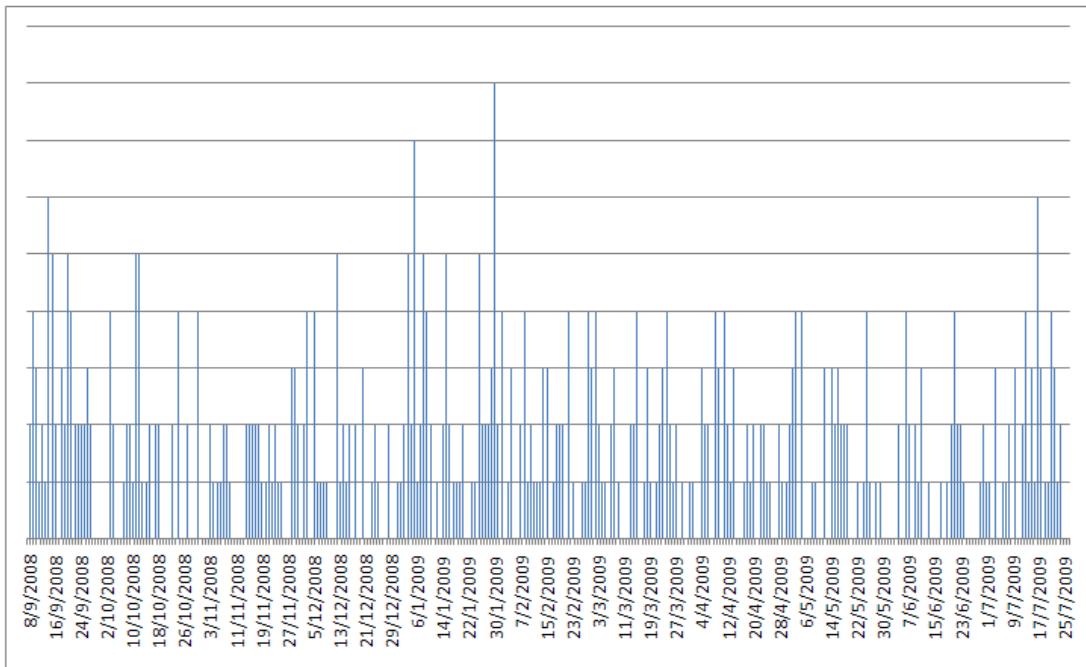


Figura 6-4: Demanda do SKU D na loja L2

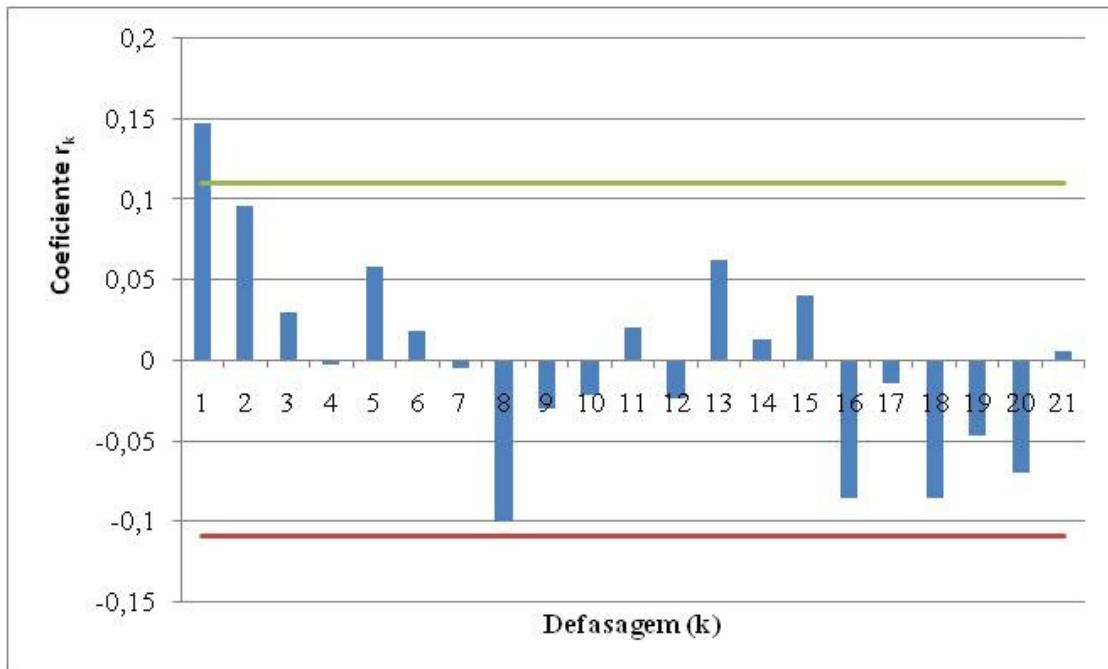


Figura 6-5: Autocorrelogramma do SKU D na loja L2

Tirando os dois SKUs cujo giro é baixo (os SKUs A e D), assim que as duas menores lojas (L2 e L6), 70% das combinações apresentam sazonalidade diária na semana, como mostra a tabela 6-2.

Comportamento	Percentagem de ocorrência
Sazonalidade semanal com Tendência	40%
Sazonalidade semanal sem Tendência	30%
Aleatoriedade	30%

Tabela 6-2: Percentagens de ocorrência dos comportamentos tirando os SKUs e as lojas de baixo giro

Para entender o comportamento dos SKUs e lojas de baixo giro, decidimos repetir a análise num nível de agrupamento maior, ou seja, somando as demandas de todas as lojas para os SKUs A e D e as demandas de todos os SKUs para as lojas L2 e L6, a fim de se livrar do problema de escala. Os perfis das lojas continuaram aleatórios, mas os dos SKUs A e D indicaram sazonalidade diária na semana.

b. A procura de sazonalidade semanal ou dezenal no mês

Os bens de consumo costumam ter uma demanda variável dentro do mês, devido aos dias de pagamento da população. Por conta disso, podemos imaginar que na primeira semana ou dezena do mês, a procura é maior. Para validar ou recusar essa hipótese, foi realizada uma análise de autocorrelação no nível de agrupamento das lojas. Olhamos, loja a loja, se a demanda total semanal ou dezenal dos SKUs da amostra apresentava sazonalidade dentro do mês. Os testes foram negativos. Segue nas figuras 6-6 e 6-7 o exemplo da loja L5:

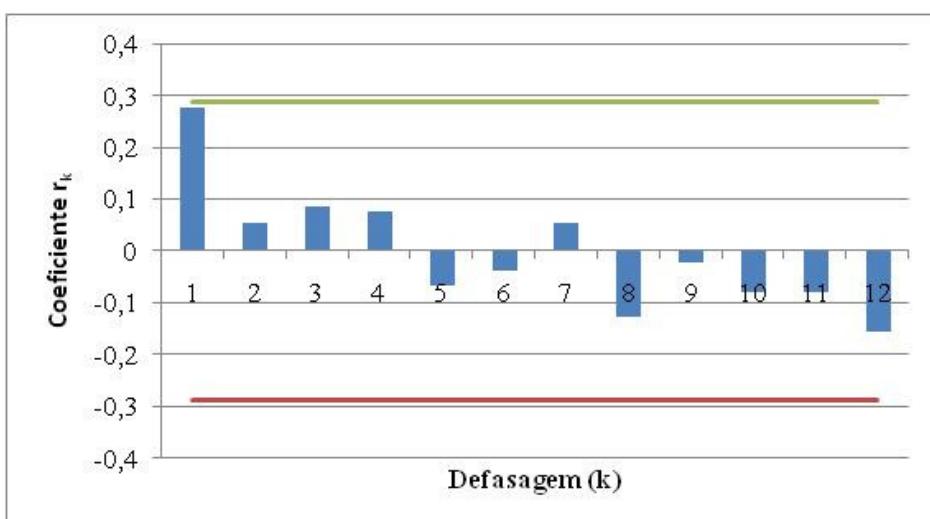


Figura 6-6: Autocorrelograma da demanda semanal da loja L5

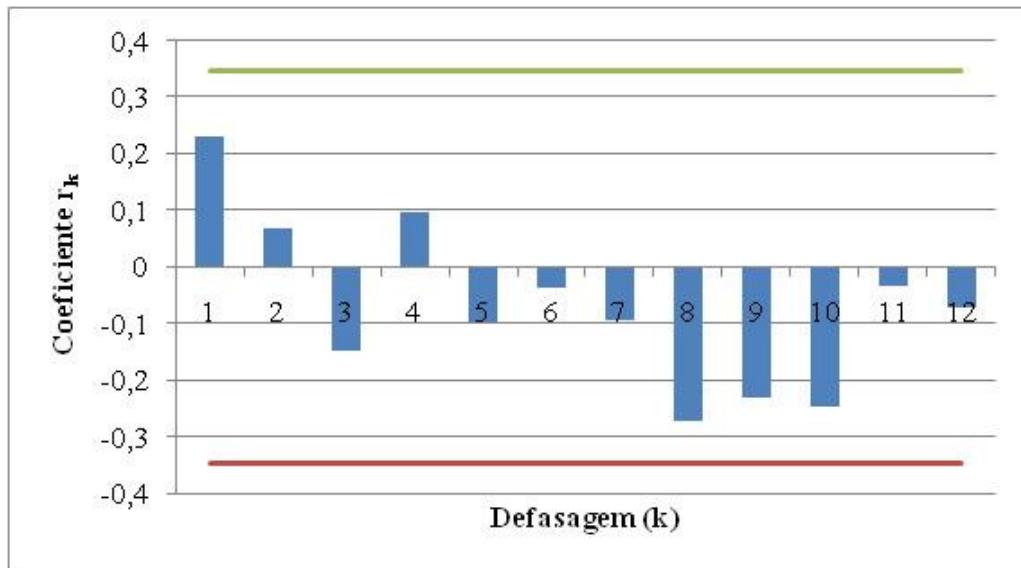


Figura 6-7: Autocorrelograma da demanda dezenal da loja L5

Vários fatores podem explicar a ausência de sazonalidade semanal ou dezenal dentro do mês. Primeiramente, iogurtes são alimentos perecíveis, o que reduz a possibilidade de antecipação ou postergação das compras. Segundamente, a Danone produz produtos lácteos frescos com valor agregado superior à média do segmento, como explicado no parágrafo 1.4. Eles se destinam assim a um público alvo para o qual o iogurte é um bem de consumo básico, cuja compra não depende da data de recebimento.

6.2.3. Conclusão

As análises de autocorrelação realizadas em conjunto com análises gráficas da evolução da demanda dos SKU/loja estudados permitiram identificar a presença de sazonalidade diária dentro da semana para 55% das 42 combinações SKU/loja disponíveis. 57% destas combinações sazonais apresentaram também tendência.

Dentro dos 45% das combinações que apresentaram um comportamento dito “aleatório”, identificamos que a grande maioria é ligada aos SKU/loja de demanda média muito baixa, para os quais uma variação unitária da quantidade vendida já pode impactar significativamente os resultados. Esses SKUs apresentam um comportamento sazonal quando agrupamos as vendas de várias lojas. Não foi identificada sazonalidade semanal ou dezenal dentro do mês para nenhum SKU/loja.

Como foi explicado no objetivo do trabalho, tentaremos, na medida do possível, usar uma única técnica de previsão para todos os SKUs. Dado que identificamos componentes de tendência e sazonalidade na maioria das demandas analisadas, foram pré-selecionados dois modelos de previsão de demanda de acordo com a tabela 3-1 (que relaciona técnicas de previsão com o padrão dos dados): o modelo de Holt Winter's e o modelo de Decomposição Clássica. Essa pré-seleção dos modelos a partir do padrão da demanda corresponde ao primeiro critério a levar em conta na escolha do método de previsão, segundo Hanke e Reitsch (1998) (ver parágrafo 3.4.6). Os critérios da aplicabilidade do método, da facilidade de compreensão e do desempenho do método serão analisados nos próximos parágrafos.

6.3 Aplicação dos modelos

Nos parágrafos a seguir serão apresentados os testes realizados com os dois modelos de previsão de demanda considerados, bem como uma análise comparativa do desempenho deles para a seleção do melhor modelo.

6.3.1. Divisão das séries históricas em fases

A etapa de previsão de demanda foi realizada em julho de 2009: dispomos então de dados históricos do período de setembro de 2008 até julho de 2009, o que representa medições relativas a 322 dias para cada SKU/loja. Segundo Santoro (2006), as séries históricas devem ser divididas em três períodos: inicialização, validação e previsão, para realizar o ajuste dos modelos. Cada fase tem um objetivo específico. Vamos considerar o exemplo do modelo de Holt Winter's. São definidos na fase de inicialização os componentes de nível (C_T), de tendência (T_T) e de sazonalidade (S_T), geralmente pelo método de otimização. Os três parâmetros são otimizados para minimizar o erro (conforme recomendado na literatura, usaremos o erro absoluto médio, ou MAD). A partir dos valores dos componentes C_T , T_T e S_T obtidos ao final da etapa de inicialização são determinados na fase de validação os coeficientes de suavização α , β e γ , também pelo método de otimização.

Para o presente trabalho, decidimos prever as demandas para um período que vai do final do mês de julho até o início de outubro, necessitando assim a previsão de 70 valores diários para cada SKU/loja.

Devido à disponibilidade de poucos dados históricos, foi necessária a priorização da etapa de inicialização (com os primeiros 273 dados), com relação à de validação para garantir uma boa adaptação do modelo. A divisão é apresentada na figura 6-8.

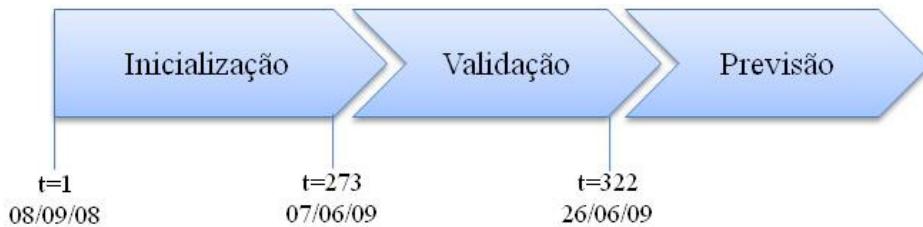


Figura 6-8: Divisão das séries históricas em três fases

Em uma melhoria futura do processo, quando mais dados serão disponíveis, seria interessante reforçar o período de validação para equilibrar as duas fases. Porém a situação atual não invalida a presente análise, uma vez que a duração da primeira fase permite uma inicialização adequada.

6.3.2. Aplicação do modelo de Holt Winter's

O método de Holt Winter's foi aplicado aos 42 SKU/loja da amostra. Pela facilidade de uso foi escolhido o software MiniTab® (versão 15) para a realização dos testes. O programa fornece somente três medidas de erro (o desvio absoluto médio (MAD), o desvio absoluto percentual médio (MAPE) e o desvio quadrático médio (MSD)), mas isso foi julgado suficiente para a etapa de aplicação e de otimização do modelo.

O MiniTab® não calibra os valores das constantes de suavização α , β e γ de maneira automática. Simulações manuais foram realizadas com o objetivo de minimizar o erro absoluto médio (MAD). Sabendo que a literatura recomenda geralmente valores inferiores a 0,5 optou-se por restringir a faixa de variação das constantes entre 0,05 e 0,40 e testar só valores múltiplos de 0,05 para reduzir o número de combinações possíveis.

Segue na figura 6-9 o exemplo do SKU C na loja L5, para o qual os valores otimizados das constantes (os que minimizam o MAD) foram $\alpha = 0,30$, $\beta = 0,05$ e $\gamma = 0,05$. Por razão de confidencialidade, as escalas foram deletadas.

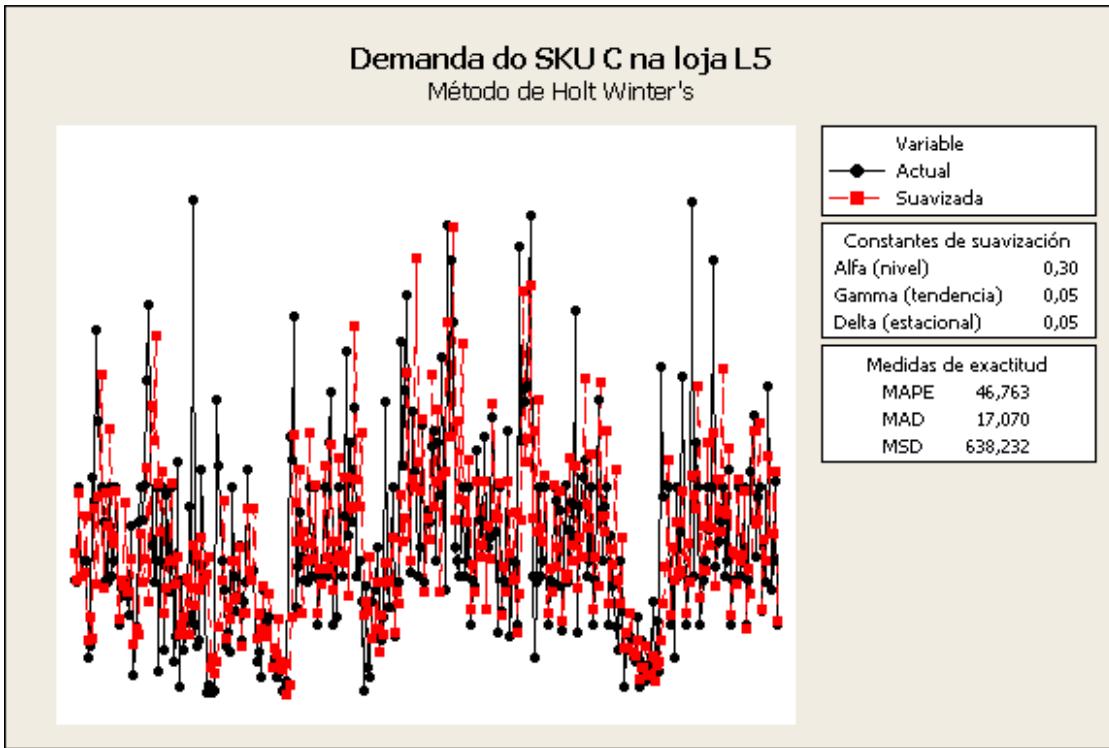


Figura 6-9: Demanda e previsão do SKU C na loja L5 – Método de Holt Winter's
(realizado no MiniTab®)

6.3.3. Aplicação do modelo de Decomposição Clássica

O método de Decomposição Clássica foi também aplicado aos 42 SKU/loja da amostra. O modelo usado foi o modelo chamado Razão de Médias Móveis cujo princípio é descrito no parágrafo 3.3.7, na revisão bibliográfica. Como a simulação é de fácil implementação (as equações são relativamente básicas), ela foi realizada no software Microsoft Excel®.

Para cada SKU/loja, a equação de tendência (linear) foi calculada, bem como os índices de sazonalidade.

Segue na figura 6-10 o exemplo do SKU C na loja L5. Por razão de confidencialidade, as escalas foram deletadas. Os índices de sazonalidade diária são disponíveis na tabela 6-3.

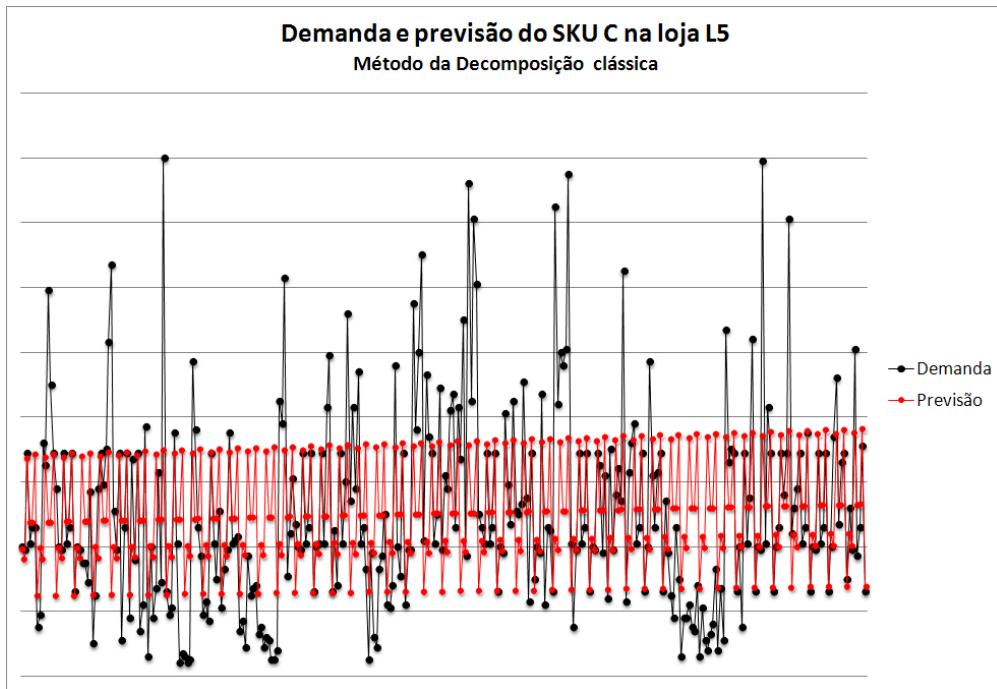


Figura 6-10: Demanda e previsão do SKU C na loja L5 – Método de Decomposição Clássica (realizado no Microsoft Excel®)

Dia da semana	Índice de sazonalidade
Segunda	83%
Terça	76%
Quarta	142%
Quinta	100%
Sexta	100%
Sábado	145%
Domingo	52%

Tabela 6-3: Índices de sazonalidade para o SKU C na loja L5

6.3.4. Análise comparada do desempenho dos modelos

Conforme mencionado, os dois modelos foram aplicados aos 42 SKU/loja do estudo. Como os indicadores de erro calculados pelo software MiniTab® não desconsideram o intervalo de inicialização dos dados e que nem todas as medidas de erros são fornecidas pelo programa, as previsões obtidas pelo método de Holt Winter's foram exportadas para o software Microsoft Excel® e uma análise comparativa dos dois modelos, baseada nas medidas de erro foi montada para cada SKU/loja.

Observando-se as curvas apresentadas nas figuras 6-9 e 6-10, dá para perceber que enquanto o modelo de Decomposição Clássica tem um comportamento bastante “rígido” e muito regular com parâmetros fixos, o modelo de Holt Winter's tem a possibilidade de adaptar o valor dos seus parâmetros de acordo com os dados reais da série. Dependendo do perfil da demanda, essas características se revelam pontos positivos ou negativos.

Para escolha do modelo, foi usado o critério do menor desvio absoluto médio (MAD), porque ele é amplamente recomendado pela literatura nessa situação (comparação de dois métodos de previsão aplicados a mesma série temporal). No caso do exemplo usado nos parágrafos anteriores (SKU C na loja L5), obtemos os resultados da tabela 6-4.

	Decomposição Clássica	Holt Winter's
MAD	11,65	25,94

Tabela 6-4: Comparação de MAD no caso do SKU C na loja L5

Os resultados completos da comparação são disponíveis no apêndice A. Depois de análises mais profundas, verificamos que, para alguns casos, a diferença entre os modelos era baixa (inferior a 10%). Nesses casos, achamos que era difícil escolher entre os modelos, especialmente sabendo que os testes foram efetuadas com uma restrição de dados históricos disponíveis e consideramos os modelos equivalentes. Obtemos as estatísticas apresentadas na tabela 6-5.

Comparação dos modelos	Percentagem de ocorrência
Modelo de Decomposição Clássica melhor	53%
Modelos equivalentes	26%
Modelo de Holt Winter's melhor	21%

Tabela 6-5: Resultados das simulações de previsão de demanda

O método de Decomposição Clássica mostrou o melhor desempenho em 53% dos casos. Somando com os casos de indecisão, podemos considerar que ele apresenta acurácia elevada em 79% dos casos. O modelo de Holt Winter's, pela propriedade de ser mais reativo não se adequou tão bem. De fato, as séries estudadas apresentam na maioria dos casos muita variação. O modelo de Decomposição Clássica se adapta a média dos valores, o que tende a minimizar o erro, enquanto o modelo de Holt Winter's que tenta seguir as mudanças reage com certo atraso às variações, tornando-se bastante instável e aumentando o erro médio.

Foram realizadas diversas análises cruzando o melhor modelo com o giro das lojas, o giro dos SKUs, ou ainda o comportamento da demanda (identificado na análise de autocorrelação). Não foi achada nenhuma ligação direta.

6.3.5. Escolha do modelo

Conforme visto na revisão bibliográfica, no parágrafo 3.4.6, devem ser considerados vários critérios na escolha do método. O critério de horizonte de planejamento foi considerado como uma hipótese de trabalho, já que nos focamos só em previsões a curto prazo. O padrão da demanda, que constitui o primeiro critério segundo Hanke e Reitsch (1998) permitiu pré-selecionar o modelo de Holt Winter's e o modelo de Decomposição Clássica.

Análises comparativas do desempenho dos dois modelos permitiram destacar o modelo de Decomposição Clássica como o modelo de maior acurácia na maioria dos casos.

No que diz respeito aos critérios de aplicabilidade dos métodos (rapidez de execução, aceitação pela gerência...) e de facilidade de compreensão, os modelos foram considerados equivalentes, com uma leve preferência para o modelo de Decomposição Clássica, reconhecido como sendo o mais intuitivo pelo Gerente de Customer Service entrevistado.

Um dos requisitos desse estudo em relação ao modelo de previsão de demanda a ser usado é que ele seja simples e, na medida do possível, que seja usada uma única técnica para todos os SKUs, mesmo se esta não se mostra ótima para todas as famílias. Isso se justifica, pois a previsão de demanda constitui neste trabalho só uma parte do modelo de decisão a elaborar e o uso de vários métodos de previsão poderia inviabilizar a utilização prática do modelo. Por isso, e segundo a avaliação dos dois modelos feita anteriormente, escolhemos o método da Decomposição Clássica.

6.3.6. Reflexão sobre os erros de previsão

Além do desvio absoluto médio (MAD) que usamos para definir o método de melhor desempenho, calculamos o erro absoluto percentual médio ponderado (WMAPE) para ter uma idéia do erro em termo percentual. Preferimos utilizar esse indicador ao invés do erro absoluto médio (MAPE), por permitir o uso com itens de demanda pequena ou nula.

De maneira geral, o WMAPE calculado é bastante elevado: para os itens de giro médio a alto ele é em média 60% (para o modelo de Decomposição Clássica) e para os itens de baixo giro ele ultrapassa em média 100%. Isso ilustra a complexidade de previsão de demanda do mercado de produtos lácteos frescos, especialmente no nível de detalhamento SKU/loja/dia. Existem muitos fatores externos que influenciam a demanda (como promoção, política da concorrência, posicionamento do produto na gôndola e até meteorologia!), mas devido à falta de informações sobre esses variáveis, não foi possível realizar análises de correlação.

Todavia, o objetivo do nosso estudo é usar a previsão de demanda para melhorar o sistema de gestão de estoques atual: aqui a previsão não é um fim em si mesmo. Os desvios de previsão serão cobertos pelo estoque de segurança. Outro fator que permite também relativizar o nível alto do WMAPE é uma consideração do giro dos itens. O SKU D, por exemplo, tem um giro tão baixo em algumas lojas que 100% de erro de previsão pode na prática corresponder a uma unidade vendida a mais do que o previsto, o que terá pouca consequência nos indicadores de gestão de estoques.

7 Elaboração do modelo de decisão

Como explicado no parágrafo 2.4, o objetivo do trabalho é criar um modelo de decisão a ser usado na elaboração dos pedidos pelos promotores das lojas estudadas. Na última parte, foi elaborado um modelo de previsão de demanda. Nessa parte, será apresentado o modelo de decisão, cujo desempenho será comparado ao sistema atual de gestão de estoques.

7.1 Hipóteses de elaboração do modelo de decisão

Conforme explicado no parágrafo 4.3.5, o modelo de gestão de estoques que usaremos é o modelo de Cálculo de Necessidades, já que se trata de um modelo ativo, e que acreditamos que é possível obter melhores resultados ao modificar o sistema atual de reabastecimento para utilizar a previsão de demanda na tomada de decisão. Para poder ser implementado, o modelo deverá se adaptar a algumas restrições operacionais atuais, conforme descrito nos parágrafos a seguir.

7.1.1. Componentes do sistema de gestão de estoques

Conforme explicitado no parágrafo 5.1.1, a freqüência de visita às lojas, bem como os dias de pedido de cada loja são consignados em um documento chamado “plano de campo”. O lead-time teórico, que depende do tipo de distribuição (direta ou indireta), também é fixo. Esses dados definem o período de revisão e o tempo de resposta do sistema de gestão de estoques para cada loja.

Consideramos o exemplo da loja L6, cujo lead-time teórico é de um dia (distribuição direta). Na prática, a loja emite pedidos na terça-feira de manhã e recebe a mercadoria na quarta durante o dia. A mercadoria só estará disponível na gôndola na quinta de manhã, o que resulta em um tempo de espera real de dois dias. Da mesma maneira, o pedido efetuado na sexta-feira só será recebido na segunda-feira (porque essa loja não recebe no sábado), o que resulta em quatro dias de tempo de espera real. Por isso, o período de revisão é de três ou quatro dias, dependendo do dia de pedido considerado. Assim, o tempo de resposta do sistema é de seis ou sete dias, como ilustrado na figura 7-1, onde são usadas as abreviações definidas na revisão bibliográfica.

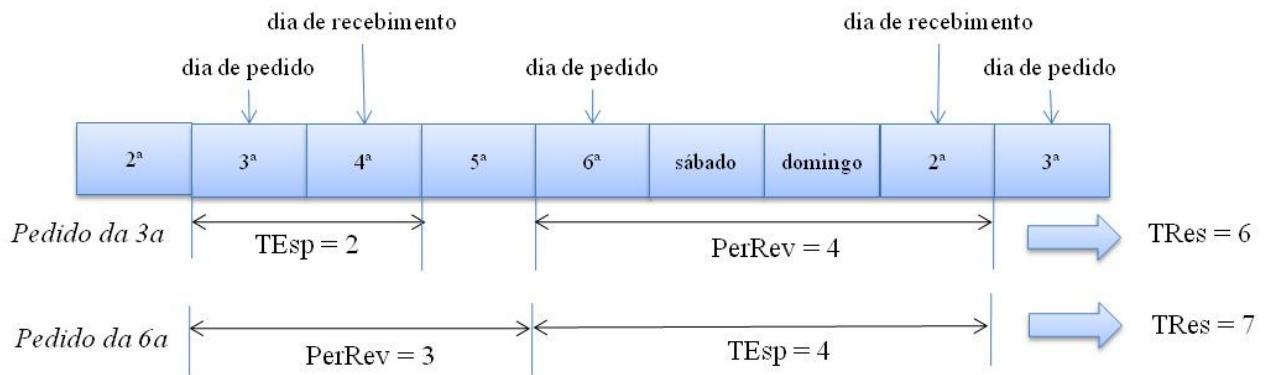


Figura 7-1: Determinação dos componentes do sistema de gestão de estoques para a loja L6

A obtenção dos componentes do sistema de gestão de estoques das outras lojas é similar. Os dados estão disponíveis na tabela 7-1.

Numero Loja	Dias Pedido	Dias Recebimento	Lead Time teórico	TEsp (Tempo de Espera)	PerRev (Período de Revisão)	TRes (Tempo de Resposta)
L1	2a, 4a, 6a	3a, 5a, sab	1 dia	2 dias	2 ou 3 dias	4 ou 5 dias
L2	3a, 6a	4a, sab	1 dia	2 dias	3 ou 4 dias	5 ou 6 dias
L3	2a, 5a	3a, 6a	1 dia	2 dias	3 ou 4 dias	5 ou 6 dias
L4	2a, 4a, 6a	3a, 5a, sab	1 dia	2 dias	2 ou 3 dias	4 ou 5 dias
L5	6a	2a	2 dias	4 dias	7 dias	11 dias
L6	3a, 6a	4a, 2a	1 dia	2 ou 4 dias	3 ou 4 dias	6 ou 7 dias
L7	2a, 5a	3a, 6a	1 dia	2 dias	3 ou 4 dias	5 ou 6 dias

Tabela 7-1: Componentes do sistema de gestão de estoques das lojas do estudo

7.1.2. Restrições de “lote” de compra

Os SKUs na Danone são vendidos ao varejista em caixas: não existe possibilidade de adquirir os produtos unitariamente. Por isso, não é possível usar o modelo de Cálculo de Necessidades na sua forma “original”: é necessário levar em consideração esse “lote de compra”, que é uma restrição operacional da Danone. Para funcionar de acordo com o princípio do modelo, a ordem de compra corresponderá à necessidade líquida arredondada para cima até um múltiplo da quantidade de unidades de itens por caixa.

A introdução desse parâmetro modifica a regra de decisão do modelo, como mostrado a seguir (usando as notações estabelecidas no parágrafo 4.3.5 da revisão bibliográfica).

$$OComprat,k = \begin{cases} n \times LotComp & \text{se } NLiq_{t,k} > 0 \\ 0 & \text{se } NLiq_{t,k} \leq 0 \end{cases}$$

com: $LotComp$ = o “lote” de compra, ou seja, a quantidade de unidades de itens por caixa

$$n = \text{menor inteiro tal que } NLiq_{t,k} \leq n \times LotComp$$

Essa restrição operacional introduz uma quantidade mínima de compra igual a $LotComp$, o que terá o efeito de diminuir a freqüência de pedido dos itens. Isso é uma vantagem quando os custos de pedido são altos, mas terá pouca importância em nosso estudo, já que a freqüência de visita às lojas foi negociada entre o varejista e a Danone em coerência com o giro de cada loja e que a Danone tem o compromisso de abastecer as lojas em acordo com o planejado. A quantidade $LotComp$ varia dependendo do SKU considerado e está disponível na tabela 5-2, na parte de descrição da amostra.

7.1.3. A falta como perda de vendas

Como mostrado na figura 2-4 da introdução, o consumidor brasileiro, diante da ruptura do iogurte desejado, não está disposto a esperar: em 59% dos casos ele compra outro produto na hora, em 29% dos casos procura em outro lugar ou simplesmente desiste de compra. A falta de produto passa a ser sinônimo de não atendimento, de perda de venda, o que é outra hipótese da elaboração do nosso modelo de gestão de estoques.

7.2 Objetivo do modelo de decisão

Como explicado na revisão bibliográfica (no parágrafo 4.2), a modelagem de estoques tem normalmente o objetivo de minimizar o custo global, o que pode ser traduzido de várias formas, dependendo do caso.

7.2.1. Definição dos indicadores de desempenho

O modelo deverá auxiliar os promotores a resolver o conflito de escolha descrito no parágrafo 2.3, que se refere à elaboração dos pedidos. Deve ser pedido o suficiente para atender a demanda, mas sem excesso para não deixar nem que o produto vença na gôndola (visão da Danone), nem que hajam altos níveis de estoque de mercadoria na loja (pressão de redução de custos de estocagem no varejo).

Devido a esse objetivo, não trabalharemos diretamente com uma função objetivo de minimização do custo total. No nosso caso, o custo do pedido não é relevante, já que a freqüência de visita às lojas do varejo é um dado de entrada do sistema (como explicado anteriormente). Sobre os custos de falta e de manutenção dos estoques, não temos dados monetários, mas indicadores de desempenho ligados: o Instock e o índice de cobertura média (notado CobEstMed).

Chamaremos de Instock o indicador complementar da ruptura (calculado como “1 – índice de ruptura”). A respeito do índice de ruptura, as lojas do varejo, foco do estudo, estimam que um SKU encontra-se em ruptura no dia D se o seu estoque atual (D) é inferior à venda média diária daquele produto (ou seja, um dia de cobertura). Para as lojas, o índice de ruptura é binário (o item encontra-se em ruptura ou não) e não considera as quantidades de unidades não atendidas. Essa definição não foi contestada na parte de diagnóstico e de tratamento de dados, nas quais só era necessário detectar situações de risco de ruptura, mas não é compatível com a nossa simulação de gestão de estoques, uma vez que queremos minimizar as vendas perdidas e não o número de dias de risco de ruptura. O sistema de informação do varejo permite obter as vendas diárias de cada SKU/loja bem como o nível do estoque dos itens no início do dia. Definimos o índice de Instock calculado para um SKU/loja da seguinte maneira:

$$InStock = 1 - \frac{\sum_{i=1}^n VenPer_i}{\sum_{i=1}^n Dem_i}$$

com Dem_i = demanda durante o dia i

n = número de dias considerados no cálculo do indicador

$VenPer_i$ = vendas perdidas no dia i, definido da seguinte maneira:

$$\text{VenPer}_i = \begin{cases} \text{Dem}_i - \text{EstFis}_i & \text{se } \text{EstFis}_i - \text{Dem}_i < 0 \\ 0 & \text{se } \text{EstFis}_i - \text{Dem}_i \geq 0 \end{cases}$$

com EstFis_i = estoque físico no início do dia i

O segundo indicador que usaremos é o índice de cobertura média (notado CobEstMed), indicador usado pelas lojas do varejo para medir os dias de cobertura do estoque de produtos guardados na loja (nas gôndolas e nas câmaras frias). Ele é calculado a partir do estoque médio e da demanda média, conforme a fórmula a seguir, que usa as notações definidas anteriormente:

$$\text{CobEstMed} = \frac{\frac{\sum_{i=1}^n \text{EstFis}_i}{n}}{\frac{\sum_{i=1}^n \text{Dem}_i}{n}}$$

7.2.2. Objetivo quantitativo e parametrização do modelo

O nosso objetivo é melhorar a disponibilidade dos produtos na gôndola, sem criar excessos de mercadoria estocada. As metas da Danone em relação ao abastecimento das lojas do varejo para o ano 2009 é obter um Instock médio de 98% e um índice de cobertura média de 12 dias, incluindo todos os SKUs de todas as lojas do varejo. Tratando-se de médias gerais, o excelente desempenho de alguns SKU/loja pode contrabalançar o mais fraco de outros, porém a idéia é buscar melhorar o abastecimento de todos os SKUs, especialmente em termo de Instock, dimensão chave do serviço prestado pela Danone.

O parâmetro do modelo de Cálculo de Necessidades é o estoque de segurança. Traduzimos o objetivo macro do sistema para o nosso modelo de decisão no nível SKU/loja da seguinte maneira: para todos os SKU/loja, procuramos o estoque de segurança que minimiza o índice CobEstMed, submetendo o modelo a uma restrição de desempenho para a qual o Instock deve ser, no mínimo, 98%. Isso permitirá atingir a meta global de Instock, o que é crucial, devido à importância do indicador. A respeito da meta de cobertura média (12 dias no máximo), o nosso modelo não assegura que ela será atingida, mas ele busca a minimização do indicador nas condições operacionais atuais.

7.3 Teste de validação: desempenho comparado com o sistema existente

Testes de validação foram realizados no software Microsoft Excel® com dados reais, entre o final do mês de julho e o início de outubro (7 semanas). Como o sistema existente é empírico e não pode ser modelado matematicamente, não foi possível comparar os modelos por via de simulações de desempenho, em diversas situações de demanda. Foi utilizada uma abordagem determinística, comparando o desempenho simulado do nosso modelo de decisão com os resultados reais do sistema atual de pedido.

7.3.1. Hipóteses de comparação

Um dos grandes desafios para realizar uma comparação real entre os dois sistemas consiste em submeter o nosso modelo às condições de funcionamento do sistema atual, levando em conta a variabilidade do processo. Por exemplo, o atraso de um dia na entrega de um pedido prejudica o sistema atual e tem um impacto direto nos indicadores de desempenho. A possibilidade de atraso tem que ser levada em conta também na nossa simulação para poder comparar os sistemas sob as mesmas hipóteses. Para levar em conta essa variabilidade, foram considerados vários fatores, explicitados a seguir.

a. Atraso

Como temos acesso aos dados diários de estoque das lojas, é fácil detectar a ocorrência de uma entrega no sistema empírico atual: o estoque sobe. Isso permite detectar em qual dia uma entrega foi realizada. Como as lojas têm dias fixos para emitir e receber os pedidos, essa análise permite verificar se a entrega foi feita no dia previsto ou com atraso. Dessa maneira, atrasos foram detectados no sistema atual e aplicados às entregas do nosso sistema, como ilustrado na figura 7-2.

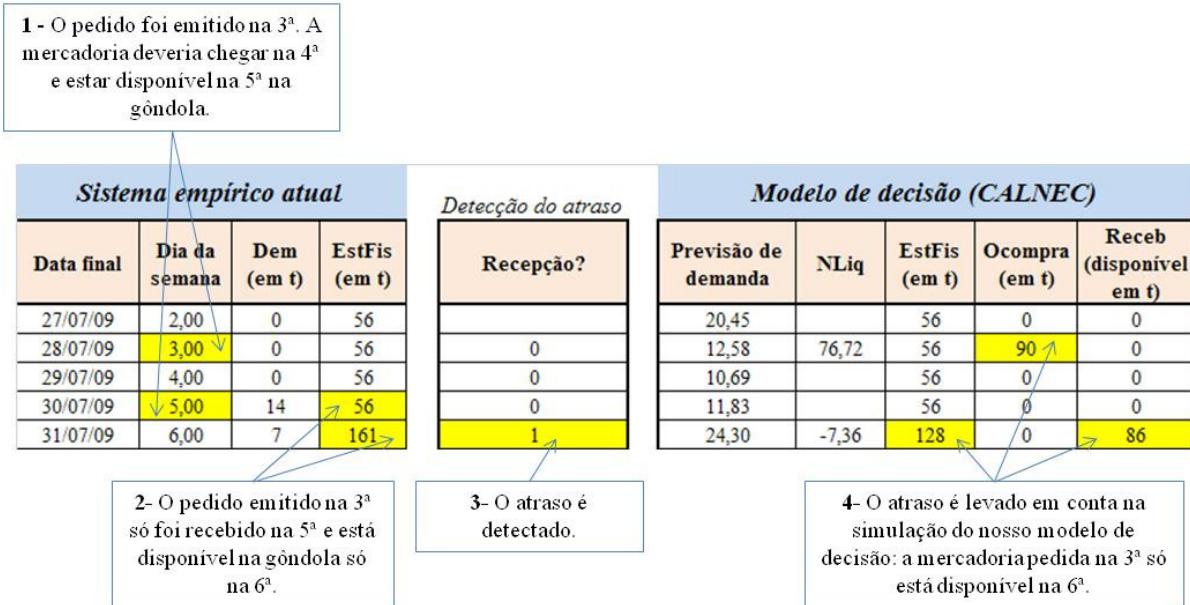


Figura 7-2: Ilustração da detecção e aplicação de atraso no nosso modelo de decisão (exemplo do SKU B na loja L6, os números foram modificados)

b. Corte

Como visto no parágrafo 2.2.2, o planejamento da produção na Danone não é perfeito. Pode acontecer de um produto pedido se encontrar em ruptura de estoque no Centro de Distribuição, resultando em corte parcial ou total das quantidades pedidas. Esse fato deve ser levado em conta para poder comparar os dois sistemas sob as mesmas condições de funcionamento. Como a informação dos cortes diários de produtos não é armazenada, é muito difícil aplicar o corte de maneira determinística, como fizemos para a ocorrência de atrasos. Conseguimos obter dados da percentagem de corte médio por SKU e por loja referente ao período de estudo. Essa percentagem foi aplicada às quantidades pedidas na simulação do desempenho do nosso sistema, como mostrado no exemplo da figura 7-3. O método poderia ser melhorado no futuro realizando uma simulação probabilística de ocorrência.

<i>Sistema empírico atual</i>				<i>Modelo de decisão (CALNEC)</i>						
<i>Data final</i>	<i>Dia da semana</i>	<i>Dem (em t)</i>	<i>EstFis (em t)</i>	<i>Detecção do atraso</i>		<i>Previsão de demanda</i>	<i>NLiq</i>	<i>EstFis (em t)</i>	<i>Ocompra (em t)</i>	<i>Receb (disponível em t)</i>
				<i>Recepção?</i>						
27/07/09	2,00	0	56			20,45		56	0	0
28/07/09	3,00	0	56	0		12,58	76,72	56	90	0
29/07/09	4,00	0	56	0		10,69		56	0	0
30/07/09	5,00	14	56	0		11,83		56	0	0
31/07/09	6,00	7	161	1		24,30	-7,36	128	0	86

Esse SKU/loja tive um corte médio de 5% no período considerado. Esse corte é considerado na simulação do nosso modelo de decisão.

Figura 7-3: Ilustração da aplicação de corte no nosso modelo de decisão
(exemplo do SKU B na loja L6, os números foram modificados)

c. Vencimento na gôndola

Um produto cuja data de vencimento está próxima é tirado da gôndola e o estoque é atualizado. Na nossa simulação, devemos poder rebaixar o estoque por esse motivo também. Consideramos que um produto chega à gôndola uma semana depois da sua fabricação, o que representa menos de um quarto da sua validade (que varia entre 30 e 45 dias). A Danone estima que um iogurte passe dois terços da sua validade na gôndola antes de ser retirado por data avançada. Em nossa simulação, verificamos se as quantidades recebidas foram vendidas nesse intervalo de tempo, usando a regra do “First In, First Out”. Caso contrário, damos rebaixa no estoque, como ilustrado na figura 7-4. Essa estimativa não é ótima, uma vez que nem sempre os produtos mais antigos são vendidos antes, mas permite detectar os casos mais prováveis de vencimento.

Sistema empírico atual				Detecção de vencimento	Modelo de decisão (CALNEC)				
Data final	Demanda (em t)	EstFis (em t)	Vencimento?		Previsão de demanda	NLiq	EstFis (em t)	Ocompra (em t)	Receb (disponível em t)
25/08/09	3,00	2	22	0	1,20	19,72	11	36	0
26/08/09	4,00	6	20	0	1,56		9	0	0
27/08/09	5,00	2	14	0	1,71		38	0	35
28/08/09	6,00	0	12	0	2,27	-7,04	36	0	0
29/08/09	7,00	4	12	0	1,93		36	0	0
30/08/09	1,00	0	8	0	0,83		32	0	0
31/08/09	2,00	2	8	0	1,22		32	0	0
01/09/09	3,00	1	21	0	1,18	0,50	30	18	0
02/09/09	4,00	0	20	0	1,53		29	0	0
03/09/09	5,00	0	20	0	1,67		47	0	18
04/09/09	6,00	0	20	0	2,22	-18,23	47	0	0
05/09/09	7,00	0	20	0	1,89		47	0	0
06/09/09	1,00	0	20	0	0,82		47	0	0
07/09/09	2,00	2	20	0	1,19		47	0	0
08/09/09	3,00	0	18	0	1,15	-14,72	45	0	0
09/09/09	4,00	3	18	0	1,50		45	0	0
10/09/09	5,00	1	15	0	1,64		42	0	0
11/09/09	6,00	0	14	0	2,17	-12,41	41	0	0
12/09/09	7,00	2	14	0	1,85		41	0	0
13/09/09	1,00	1	12	0	0,80		39	0	0
14/09/09	2,00	1	11	0	1,17		38	0	0
15/09/09	3,00	0	10	0	1,13	-6,94	37	0	0
16/09/09	4,00	0	10	0	1,47		37	0	0
17/09/09	5,00	1	10	0	1,60		37	0	0
18/09/09	6,00	0	9	0	2,13	-7,60	36	0	0
19/09/09	7,00	2	9	0	1,81		36	0	0
20/09/09	1,00	2	7	0	0,78		34	0	0
21/09/09	2,00	1	5	0	1,14		32	0	0
22/09/09	3,00	0	4	0	1,10	-1,16	31	0	0
23/09/09	4,00	1	4	0	1,43		31	0	0
24/09/09	5,00	2	3	0	1,57		30	0	0
25/09/09	6,00	2	1	1	2,08	7,22	21	18	0

2 – O SKU D tem uma validade de 45 dias. Consideraram os que permanece na gôndola 2/3 da sua vida, antes de ser retirado por data avançada (ou seja 30 dias). Nesse prazo, só 28 unidades foram vendidas: 7 unidades devem ser retiradas (usando a regra 'First In, First Out').

3 – O vencimento é detectado.

1 – 35 unidades do SKU D chegaram na loja, dia 27/08/09.

4 – O estoque é atualizado: 2 unidades foram vendidas no dia 24/09/09 e 7 unidades foram retiradas por data avançada.

Figura 7-4: Ilustração da detecção de vencimento de produto no nosso modelo de decisão (exemplo do SKU D na loja L6, os números foram modificados)

7.3.2. Comparação dos dois modelos

Para cada SKU/loja, foi calculado o estoque de segurança que permite minimizar a CobEstMed com a restrição de Instock mínimo de 98%. Por questão de confidencialidade, os números otimizados não podem ser revelados.

Comparamos depois os resultados do nosso modelo de decisão com os obtidos pela Danone no mesmo período com o sistema de pedido empírico atual. Foram assim comparados os indicadores de desempenho definidos, ou seja, o Instock e a CobEstMed para cada SKU/loja. Os resultados estão disponíveis no apêndice B.

Notaremos os indicadores do sistema atual empírico: $\text{Instock}_{\text{empírico}}$ e $\text{CobEstMed}_{\text{empírico}}$. Os indicadores do nosso modelo de decisão serão: $\text{Instock}_{\text{CALNEC}}$ e $\text{CobEstMed}_{\text{CALNEC}}$.

O $\text{Instock}_{\text{CALNEC}}$ é automaticamente superior a 98%, pois o modelo foi construído com essa restrição. Acima desse número, consideramos os modelos de desempenho similar em relação ao indicador, ou seja, atingir 100% de Instock não constitui uma vantagem competitiva, e é visto aqui como desnecessário. Classificamos os SKU/loja em três grupos, dependendo do número de indicadores que melhoraram com o novo sistema, conforme figura 7-5.

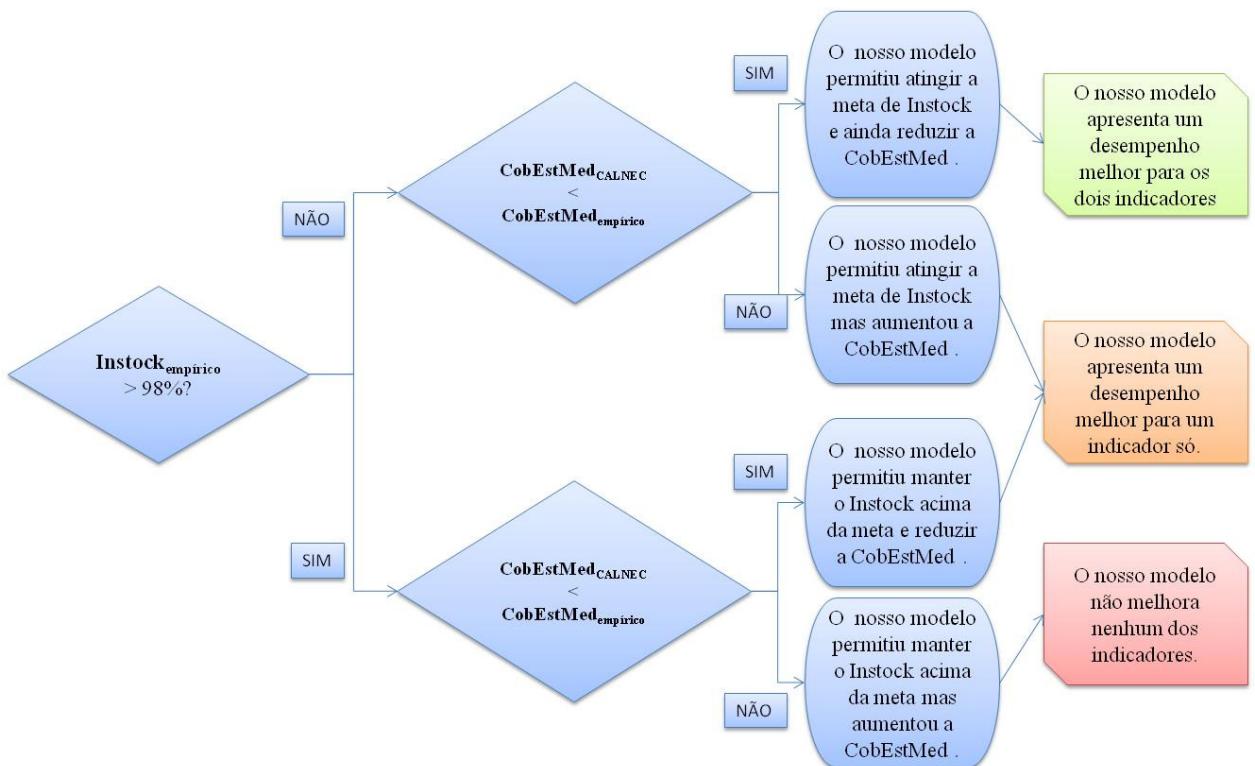


Figura 7-5: Regra de comparação do novo modelo de decisão com o sistema empírico atual

Obtemos as estatísticas apresentadas na figura 7-6. Em 98% dos casos, o nosso modelo de decisão baseado no Cálculo de Necessidades apresentou um desempenho melhor ao sistema empírico atual para, pelo menos, um dos dois indicadores, o que constitui um excelente resultado.

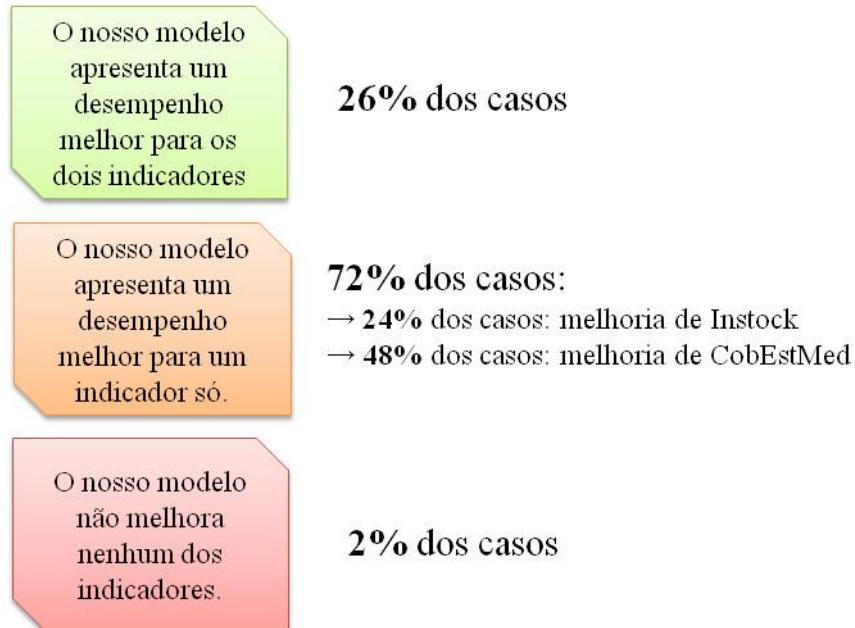


Figura 7-6: Comparação do desempenho dos dois modelos

O nosso modelo só não melhorou nenhum dos dois indicadores para um único SKU/loja da nossa amostra de 42 SKU/loja. Analisamos detalhadamente o caso junto com o promotor e verificamos que esse SKU/loja foi o objeto de uma campanha promocional pontual nessa loja na primeira semana de agosto. A campanha multiplicou por três a demanda média durante a semana considerada. O nosso sistema não foi informado de que este pico de demanda foi induzido, e o considerou como uma aleatoriedade intrínseca à demanda cotidiana o que induziu o aumento da CobMedEst do SKU/loja. Esse caso foi uma exceção e não questiona o desempenho do nosso modelo, no entanto, mostra a importância da revisão humana. O nosso modelo tem o objetivo de auxiliar o promotor na elaboração dos pedidos, sugerindo quantidades a encomendar em situações “clássicas” de abastecimento. Em casos pontuais de promoção e de degustação, cabe ao promotor aumentar as quantidades pedidas para o pico de demanda. A consideração das campanhas promocionais constitui claramente um desdobramento futuro desejável do modelo de decisão. Todavia, esse projeto de melhoria necessitará um conhecimento prévio da ocorrência das promoções, o que é difícil de se obter atualmente, já que essas informações não são centralizadas.

Olhando o valor médio e o desvio padrão dos indicadores para todos os SKU/loja da amostra, obtemos uma boa melhoria da média e uma diminuição da dispersão dos valores, como mostrado nas tabelas 7-2 e 7-3.

	Sistema atual empírico	Modelo de decisão (CALNEC)
Média Instock	95,4%	99,4%
Desvio Padrão Instock	6,4%	0,7%

Tabela 7-2: Comparação da média e do desvio padrão do Instock (%) da amostra

	Sistema atual empírico	Modelo de decisão (CALNEC)
Média CobEstMed	12,3	9,1
Desvio Padrão CobEstMed	8,5	5,7

Tabela 7-3: Comparação da média e do desvio padrão da CobEstMed (dias) da amostra

7.4 Discussão sobre o desempenho do modelo de decisão

Mostramos no parágrafo anterior que o nosso modelo de decisão apresenta um desempenho melhor ao sistema empírico atual em 98% dos casos testados. Vamos agora analisar o desempenho do nosso modelo em relação às metas de desempenho fixadas pela Danone e pelo varejo.

7.4.1. Meta de Instock

Como o modelo foi construído com uma restrição de Instock mínimo de 98%, a meta é automaticamente atingida no que se refere a esse indicador.

7.4.2. Meta de CobEstMed

O nosso modelo buscou minimizar a CobEstMed, submetido ao mesmo tempo, à restrição de Instock. Conforme foi explicado anteriormente, a meta de cobertura média da Danone é de 12 dias no máximo, todos os SKUs incluídos. A média do indicador para a nossa amostra é de 9,1 dias, com um desvio padrão de 5,7 dias, como mostrado na tabela 7-3. Como a amostra escolhida é representativa tanto do ponto de visto do portfólio quanto de lojas estudadas, podemos acreditar que a meta será atingida, especialmente porque os valores obtidos são 24% inferiores à meta, o que deixa certa margem de manobra.

Vamos analisar a CobEstMed no nível SKU/loja. Obtivemos uma redução do desvio padrão, mas a dispersão ainda é alta, com o SKU F na loja L1 que tem um índice de 3,2 dias e o SKU A na loja L4 cuja cobertura é de 29,7 dias. Todavia, verificamos que só 20% dos SKU/loja ultrapassam a meta de 12 dias. A lista desses SKU/loja é fornecida na tabela 7-4 a seguir:

Loja	SKU	CobEstMed
L4	A	29,7
L6	A	25,7
L3	A	17,9
L6	B	16,4
L6	E	15,5
L2	E	15,0
L3	E	14,9
L4	D	13,5
L6	D	12,3

Tabela 7-4: Lista dos SKU/loja cuja cobertura é superior a meta de 12 dias

Analisamos o perfil desses SKU/loja e chegamos a conclusão que alguns fatores, combinados ou não, podem ajudar a entender o nível alto de cobertura:

- a quantidade de unidades por caixa (que é de 42 para o SKU A por exemplo),
- o giro dos produtos e das lojas (os SKUs A e D têm um giro médio baixo e o SKU E médio),
- o tempo de resposta do sistema (para a loja L6, ele é de 6 a 7 dias por exemplo).

Alterações nesses fatores, tais como revisão de portfólio, diminuição da quantidade de unidades por caixa de itens de baixo giro ou ainda aumento da freqüência de visita às lojas poderiam ajudar a diminuir o indicador de CobEstMed.

8 Conclusão

8.1 Síntese

A Disponibilidade de Produto é uma dimensão chave do serviço prestado pela Danone aos varejistas. Uma análise quantitativa das possíveis causas de ruptura na gôndola destacou os erros de previsão de demanda. O presente trabalho teve seu foco na criação de um modelo de decisão de suprimento baseado na previsão de demanda, a ser usado pelos promotores da Danone na elaboração dos pedidos de produtos lácteos frescos em uma rede varejista. O objetivo é melhorar a disponibilidade dos produtos na gôndola, sem criar excessos de mercadoria estocada.

Escolhemos uma amostra representativa tanto no que diz respeito às lojas do varejo quanto aos SKUs da Danone. Foi considerada uma amostra de 7 lojas e de 6 SKUs, resultando em um total de 42 SKU/loja a estudar.

A partir de análises gráficas e de autocorrelação, identificamos a presença de sazonalidade diária dentro da semana e de tendência para a maioria dos SKU/loja do estudo. Por isso, pré-selecionamos dois métodos de previsão de demanda adequados: o modelo de Holt Winter's e o modelo de Decomposição Clássica. Análises comparativas de performance permitiram destacar o modelo de Decomposição Clássica como o modelo de maior acurácia na maioria dos casos.

Para a reposição dos estoques foi utilizado o modelo de Cálculo de Necessidades, já que se trata de um modelo ativo. Definimos dois indicadores de desempenho: o Instock, medindo a disponibilidade de produtos na gôndola e a CobEstMed, índice de cobertura média. Para todos os SKU/loja, buscamos o estoque de segurança que minimiza a cobertura média, respeitando uma restrição de Instock mínimo de 98%.

Em seguida, comparamos deterministicamente o desempenho simulado do nosso modelo de decisão com os resultados reais do sistema atual de pedido. Mostramos que o nosso modelo apresenta um desempenho superior ao sistema empírico atual em 98% dos casos testados, sendo os 2% restantes devido a uma alteração brutal na demanda de um único SKU/loja durante uma campanha promocional pontual.

8.2 Resultados

O modelo permitiu atingir as metas para os dois principais indicadores de nível de serviço. Instock (98%) e CobEstMed (12 dias), o que representa um enorme progresso já que com o sistema atual, nenhuma das duas é atingida. Foram também identificadas ações suplementares que permitiriam uma redução ainda maior da cobertura média.

Além dos ganhos obtidos nos dois principais indicadores de nível de serviço, o modelo trará outros benefícios para a Danone. A análise de autocorrelação realizada neste trabalho é uma ferramenta poderosa para entender melhor o comportamento dos produtos no mercado e já interessa o departamento de Customer Service. Um estudo generalizado (todos os SKU/loja do varejo) é previsto para o inicio de 2010.

Enfim, o modelo de decisão possibilita também a realização de simulações do impacto da mudança de parâmetros (tais como revisão da freqüência de pedido...) sobre os indicadores de abastecimento. Ele será usado em dezembro 2009 para quantificar o impacto de uma mudança de embalagem (ou seja, da quantidade de itens por caixa) de alguns SKUs com altas taxas de vencimento nas gôndolas.

8.3 Proposta de implementação

Foi decidido na Danone que, a título de experimentação, o modelo proposto será implementado para todos os SKUs de uma loja piloto no mês de dezembro 2009.

Para que o modelo funcione, somente será preciso imputar os dados de venda nas planilhas eletrônicas montadas no software Microsoft Excel®. Isso permitirá uma utilização rápida e fácil do modelo. Um analista de abastecimento realizará a simulação no período da manhã nos dias de pedido e comunicará as quantidades sugeridas para o promotor da loja. Este último revisará a sugestão e a transmitirá ao responsável da loja do varejo que emitirá o pedido a tarde. O intuito dessa fase de teste é avaliar os resultados obtidos com o modelo em situação de funcionamento real e detectar qualquer lacuna ou dificuldade prática. Depois dessa fase de teste, será decidido no inicio do ano 2010 se a iniciativa será generalizada ou não.

8.4 Análise crítica

O presente trabalho atingiu os objetivos fixados, porém algumas críticas podem e devem ser feitas no que diz respeito tanto à parte de previsão de demanda quanto à gestão de estoques.

Devido à restrição de dados armazenados disponíveis, trabalhamos na parte de análise do padrão da demanda e de previsão com onze meses de histórico, o que é pouco. Por isso, não foi possível, por exemplo, verificar a nossa hipótese de ausência de sazonalidade mensal no ano. Essa restrição também limitou a duração do período de validação.

Decidimos usar uma única técnica de previsão para todos os SKUs a fim de simplificar a utilização prática do modelo de decisão. Essa hipótese de trabalho pode ser questionada uma vez que uma única técnica pode não se mostrar ótima para todas as famílias e subestimar o desempenho do modelo. Permitir a escolha entre os dois modelos de previsão analisados para cada SKU/loja é definitivamente um eixo de melhoria a se considerar.

Em relação à análise comparativa do desempenho do nosso modelo e do sistema empírico atual, a abordagem escolhida foi determinística. A consideração da ocorrência de corte e de atraso na entrega poderia ter sido feita através de simulação probabilística. Por fim, outros fatores poderiam também ter sido tomados em conta na simulação de funcionamento do nosso sistema em condição real, tais como devolução de mercadoria na entrega por divergência administrativa na nota fiscal, erro na separação da carga...

8.5 Desdobramentos

Esse estudo foi montado para as lojas de uma rede varejista. Um primeiro desdobramento que poderia ser realizado seria a ampliação do projeto piloto para as demais redes varejistas com as quais a Danone trabalha.

Outro fator importante de desdobramento, como mencionado no tópico anterior, consistiria em melhorar a parte de previsão de demanda do modelo testando várias técnicas para escolher a de melhor desempenho, ao invés de usar uma única técnica para todos os SKUs.

Outro projeto de melhoria consistiria em utilizar também métodos causais para complementar os métodos de séries temporais utilizados, a fim de estudar e levar em conta o efeito das campanhas promocionais, feriados...

Além disso, conforme explicado no parágrafo 8.2, o modelo de decisão permite também realizar simulações do impacto da mudança de parâmetros (tais como revisão da freqüência de pedido...) sobre os indicadores de abastecimento. Dessa maneira, ele poderia ser usado freqüentemente pelos departamentos Comercial e de Operações, tanto para identificar oportunidades de melhoria quanto para estimar seu impacto nas gôndolas.

Enfim, o presente estudo foi realizado para o segmento de produtos lácteos frescos. A Danone atua também no mercado de águas engarrafadas e de alimentação infantil. Um próximo passo poderia consistir em desenvolver uma metodologia de gestão de estoques semelhante para estes segmentos.

Referências bibliográficas

AZEVEDO, C.; ARAÚJO, O. **Ruptura: Causas e impactos na cadeia de abastecimento e no comportamento do consumidor.** São Paulo: ACNiesen, 2004. Disponível em <http://www.amcham.com.br/download/informativo2004-10-20h_arquivo>. Acesso em: 03/05/2009.

BALLOU, R. H. **Gerenciamento da cadeia de suprimentos / Logística empresarial.** 5. ed. Porto Alegre: Bookman, 2006.

CORRÊA, H. L.; GIANESI, I. G. N.; CAON, M. **Planejamento, Programação e Controle da Produção.** 5. ed. São Paulo: Atlas, 2007.

DANONE. **Guia das Categorias.** São Paulo, 2008.

FREIRE, G. **Estudo comparativo de modelos de estoques num ambiente com previsibilidade variável de demanda.** 2007. 105p. Dissertação (Mestrado) – Escola Politécnica, Universidade de São Paulo, São Paulo, 2007.

HANKE, J. E.; REITSCH, A. G. **Business Forecasting.** New Jersey: Prentice Hall, 1998.

HOGARTH, R. M.; MAKRIDAKIS, S. **Forecasting and Planning: An Evaluation.** *Management Science*, Philadelphia, v. 27, n. 2, p. 115-138, fev. 1981.

INSTITUTO DE LOGÍSTICA E SUPPLY CHAIN. **Customer Service: Avaliação do Serviço de Distribuição das Indústrias de Produtos Perecíveis.** 2009.

LOVE, S. F. **Inventory Control.** New York: McGraw-Hill, 1979.

MAKRIDAKIS, S.; WHEELWRIGHT, S. C. **Forecasting - Methods and Applications.** New York: Wiley, 1978.

QUENOUILLE, M. H. **The Joint Distribution of Serial Correlation Coefficients**, Annals of Mathematical Statistics, v. 20, p. 561-571, 1949.

SANTORO, M. C. **Gestão Demanda e Estoques**. São Paulo: Epusp, 2009. Apostila para disciplina de graduação do Departamento de Engenharia de Produção, PRO-2412 – Modelagem Probabilística e Simulação de Sistemas de Produção.

SANTORO, M. C. **Sistema de gestão de estoques de múltiplos itens em local único**. 2006. 109p. Tese (Livre Docência) – Escola Politécnica, Universidade de São Paulo, São Paulo, 2006.

SIPPER, D.; BULFIN, R. L. **Production Planning, Control and Integration**. Singapore: McGraw-Hill, 1997.

SLACK, N.; CHAMBERS, S.; JOHNSTON, R. **Administração da Produção**. 2. ed. São Paulo: Atlas, 2008.

ZARIFIAN, P. Mutação dos Sistemas Produtivos e Competências Profissionais: a produção industrial do serviço. In: SALERNO, M. S. **Relação de Serviço: produção e avaliação**. São Paulo: Senac, 2001.

APÊNDICE A - Resultados da previsão de demanda

Nesse apêndice são apresentados os resultados da comparação dos modelos de Decomposição Clássica e de Holt Winter's, para cada SKU/loja.

Caso 1: SKU/loja pelos quais o modelo de Decomposição Clássica apresenta um desempenho melhor

Loja	SKU	MAD - Decomposição Clássica	MAD - Holt Winter's
L1	D	1,66	3,01
L1	E	1,51	2,47
L1	F	1,91	2,49
L2	A	2,65	4,19
L2	B	1,67	2,08
L2	D	1,10	1,29
L2	E	2,52	3,31
L3	B	2,66	3,14
L3	D	23,00	39,11
L3	E	1,29	7,44
L3	F	5,02	6,67
L4	C	38,50	42,88
L4	F	8,40	10,19
L5	B	1,99	4,07
L5	C	11,65	25,94
L5	D	2,84	3,42
L5	E	1,69	4,82
L6	B	2,75	3,46
L6	E	0,54	0,72
L7	A	3,68	4,89
L7	C	8,69	35,29
L7	F	5,97	8,93

Caso 2: SKU/loja pelos quais os modelos são considerados equivalentes (diferença de MAD inferior a 10%).

Loja	SKU	MAD - Decomposição Clássica	MAD - Holt Winter's
L1	A	5,01	5,28
L1	B	2,55	2,44
L2	C	5,92	6,45
L3	C	19,66	19,35
L4	A	2,53	2,73
L4	B	4,94	4,70
L4	D	2,24	2,25
L5	A	2,28	2,06
L5	F	3,41	3,53
L7	B	2,71	2,69
L7	D	2,70	2,74

Caso 3: SKU/loja pelos quais o modelo de Holt Winter's apresenta um desempenho melhor

Loja	SKU	MAD - Decomposição Clássica	MAD - Holt Winter's
L1	C	6,66	5,44
L2	F	2,22	1,68
L3	A	2,29	1,79
L4	E	12,20	4,74
L6	A	2,84	1,69
L6	C	1,09	0,85
L6	D	1,92	0,91
L6	F	4,45	1,46
L7	E	1,76	1,58

APÊNDICE B – Indicadores de gestão de estoque

Nesse apêndice são apresentados os resultados da comparação dos indicadores de Instock e CobEstMed do nosso modelo de decisão e do sistema empírico atual para cada SKU/loja.

O nosso modelo
apresenta um
desempenho
melhor para os
dois indicadores

26% dos casos

Loja	SKU	Instock _{empírico}	CobEstMed _{empírico}	Instock _{CALNEC}	CobEstMed _{CALNEC}
L1	D	95,3%	8,2	100,0%	6,9
L1	E	95,3%	8,2	100,0%	6,9
L1	F	79,4%	5,0	100,0%	3,2
L2	C	95,7%	10,6	98,8%	6,7
L2	E	93,7%	20,1	98,9%	15,0
L3	E	93,6%	20,8	98,9%	14,9
L4	B	96,1%	9,5	100,0%	4,8
L4	C	95,8%	3,8	98,9%	3,3
L4	D	92,7%	16,0	100,0%	13,5
L5	D	87,6%	7,8	98,7%	5,9
L7	C	97,5%	9,0	98,7%	6,3

O nosso modelo
não melhora
nenhum dos
indicadores.

2% dos casos

Loja	SKU	Instock _{empírico}	CobEstMed _{empírico}	Instock _{CALNEC}	CobEstMed _{CALNEC}
L2	F	100,0%	9,3	99,6%	10,5

O nosso modelo apresenta um desempenho melhor para um indicador só.

72% dos casos:

- 24% dos casos: melhoria de Instock
- 48% dos casos: melhoria de CobEstMed

Loja	SKU	Instock _{empírico}	CobEstMed _{empírico}	Instock _{CALNEC}	CobEstMed _{CALNEC}
L1	A	96,1%	6,1	100,0%	7,2
L1	B	100,0%	10,1	98,1%	3,7
L1	C	98,3%	5,2	98,5%	3,9
L2	A	100,0%	10,7	99,2%	6,9
L2	B	99,3%	7,3	98,9%	6,8
L2	D	95,8%	9,3	98,8%	11,4
L3	A	100,0%	32,4	100,0%	17,9
L3	B	100,0%	12,7	98,1%	5,0
L3	C	98,0%	7,2	98,3%	4,6
L3	D	99,7%	11,8	99,7%	7,4
L3	F	100,0%	17,6	100,0%	7,5
L4	A	100,0%	45,1	100,0%	29,7
L4	E	98,0%	8,7	100,0%	4,1
L4	F	100,0%	12,5	98,2%	6,9
L5	A	100,0%	16,7	100,0%	8,1
L5	B	100,0%	11,7	100,0%	7,2
L5	C	83,4%	5,1	98,0%	6,6
L5	E	92,5%	9,0	100,0%	9,5
L5	F	96,7%	7,8	100,0%	8,5
L6	A	100,0%	35,5	100,0%	25,7
L6	B	76,0%	8,6	100,0%	16,4
L6	C	79,8%	5,5	100,0%	11,5
L6	D	95,8%	9,3	100,0%	12,3
L6	E	100,0%	18,0	100,0%	15,5
L6	F	82,8%	5,3	100,0%	11,3
L7	A	100,0%	20,4	99,4%	8,2
L7	B	100,0%	9,8	99,7%	3,7
L7	D	91,2%	6,3	100,0%	8,2
L7	E	100,0%	12,7	98,2%	4,9
L7	F	100,0%	10,5	98,0%	5,7