

VIRGÍNIA MARIA BARBOSA DE ALMEIDA

ESTUDO DE MODELOS DE PREVISÃO DE DEMANDA PARA
REPOSIÇÃO DE PRODUTOS DE CONSUMO

São Paulo
2010

VIRGÍNIA MARIA BARBOSA DE ALMEIDA

ESTUDO DE MODELOS DE PREVISÃO DE DEMANDA PARA
REPOSIÇÃO DE PRODUTOS DE CONSUMO

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

São Paulo
2010

VIRGÍNIA MARIA BARBOSA DE ALMEIDA

ESTUDO DE MODELOS DE PREVISÃO DE DEMANDA PARA
REPOSIÇÃO DE PRODUTOS DE CONSUMO

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

Orientador:
Prof. Dr. Marco Aurélio de Mesquita

São Paulo
2010

FICHA CATALOGRÁFICA

Almeida, Virgínia Maria Barbosa de
Estudo de modelos de previsão de demanda para reposição
de produtos de consumo / V.M.B. de Almeida. -- São Paulo, 2010.
129 p.

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

1. Produtos 2. Estoques (Sistemas) 3. Demanda (Previsão;
Modelos) I. Universidade de São Paulo. Escola Politécnica.
Departamento de Engenharia de Produção II. t.

*À minha família querida e a todos que contribuíram
de alguma forma para a realização deste trabalho.*

AGRADECIMENTOS

Primeiramente, agradeço a Deus por ter me conduzido por caminhos que possibilitaram a concretização de mais esta etapa de minha vida.

Minha profunda gratidão aos meus pais e meu irmão por todo o apoio, suporte, incentivo e dedicação. A presença deles foi fundamental para que eu conquistasse mais esta grande vitória. Agradeço por todos os momentos compartilhados juntos ou à distância.

Meu grande agradecimento ao professor Marco Aurélio de Mesquita por toda a orientação e acompanhamento realizados ao longo deste trabalho. Graças aos seus conselhos, sugestões e críticas foi possível lapidar as ideias aqui apresentadas, aprofundar meus conhecimentos e despertar meu interesse pelo assunto. Sua prontidão, paciência e disponibilidade foram decisivas para a elaboração deste estudo.

Agradeço a todos os demais professores que possibilitaram a construção do conhecimento adquirido ao longo desses anos de graduação. Deixo registrado meu agradecimento pela possibilidade de vivenciar dois preciosos anos de minha graduação no exterior, a fim de obter um segundo diploma de graduação. Obrigada, também, a todos os funcionários do departamento pelas contribuições ao longo desses anos.

Obrigada aos meus amigos e amigas de faculdade. As amizades semeadas ajudaram a deixar esses anos de faculdade mais leves e divertidos.

Meus sinceros agradecimentos à empresa que possibilitou a realização deste trabalho e a todos os envolvidos direta ou indiretamente neste desafio. Obrigada, de maneira especial, aos colegas de trabalho, Luíza Cascadan e Fabrício Alguim, por todo o apoio e suporte nesse meu primeiro ano de vida profissional.

"A menos que modifiquemos a nossa maneira de pensar, não seremos capazes de resolver os problemas causados pela forma como nos acostumamos a ver o mundo." (Albert Einstein)

RESUMO

O presente trabalho analisa o sistema de reposição de estoque em um centro de distribuição de uma grande empresa multinacional do segmento de higiene e beleza. Para atender um grupo de clientes-chave, a empresa criou um sistema de reserva de inventário que transfere diariamente, com base no alvo de vendas mensal, uma quantidade de produtos que não poderá ser utilizada para atender os demais. Isso pode causar o não atendimento desses outros clientes. O sistema apresenta algumas limitações, sobretudo, com relação ao elevado estoque médio. A partir de análises sobre o comportamento da demanda de alguns produtos selecionados, estruturou-se um modelo de reposição baseado em previsão de demanda, cujos resultados apontam para uma provável oportunidade de melhoria a ser explorada pela empresa nesse sentido. Para os testes de previsão foi utilizado o *software* Crystal Ball®. As previsões utilizando dados de *sell-in* resultaram em erros de previsão relativamente elevados. Todavia, comparando-se o modelo de reposição atual com o de previsão, este último forneceu níveis de estoque médio menores. Por fim, a metodologia apresentada ao longo deste trabalho serve de referência para a empresa dar continuidade nos esforços de melhoria dos sistemas de reserva de inventário. Vale destacar que melhores resultados poderiam ser obtidos com a utilização de dados de *sell-out*, o que não foi possível neste trabalho, além de uma revisão das práticas de vendas da empresa, através de um planejamento mais colaborativo.

Palavras-chave: Previsão de demanda. Reposição de estoques. Indústria de bens de consumo.

ABSTRACT

This work analysis the replacement inventory system of a multinational company on the beauty and personal care market. Developed especially to attend some key accounts, the company build an inventory reservation system that transfers daily an amount of products, which can't be used to attend the other clients. This inventory system presents some limitations in terms of a high average inventory level. The goal of this work is to do a critical analysis of this system functioning and to propose a study that allows the company to compare other possible replacement inventory systems. Build on the analysis of the demand behavior for some products, a replacement inventory system based on demand forecast was proposed. The forecasts tests were made with the help of the software Crystal Ball®. Forecasts tests with *sell-in* data provided high forecasts errors. Nevertheless, comparing to the current inventory reservation system, the inventory replacement based on demand forecast resulted in lower inventory levels. The results obtained lead to a possible opportunity to be investigated in more details by the company. Finally, the methodology presented through this work might be a reference to the company in further studies. However, better results could be achieved using *sell-out* data, though it was not possible in this work, and with better sales practices trough a more collaborative planning.

Keywords: Forecasting. Inventory. Consumer goods.

LISTA DE FIGURAS

Figura 1: Localização da fábrica e dos CDs	28
Figura 2: Divisão da empresa em Unidades de Negócio.....	29
Figura 3: Hierarquia dos produtos da Empresa	31
Figura 4: Principais clientes da área de Inteligência de Vendas.....	32
Figura 5: Vendas <i>sell-in</i> e <i>sell-out</i>	34
Figura 6: Fluxo de abastecimento da reserva de inventário	39
Figura 7: Consumo do estoque no atendimento dos pedidos	39
Figura 8: Fluxograma do processo de reposição da reserva de inventário.....	40
Figura 9: Abastecimento da reserva e faturamento de pedidos.....	41
Figura 10: Comparação entre quantidades faturadas e quantidades reservadas do SKU A	43
Figura 11: Métodos de previsão de demanda	48
Figura 12: Etapas do processo de previsão de demanda	52
Figura 13: Modelos de previsão disponíveis no Crystal Ball®.....	67
Figura 14: Curvas para determinação do lote econômico	71
Figura 15: Nível do estoque num sistema de reposição do máximo	72
Figura 16: Nível do estoque num sistema de reposição por ponto de pedido	74
Figura 17: Distribuição das vendas com a abertura do CD de SP	79
Figura 18: Etapas do processo de previsão de demanda aplicadas no trabalho	82
Figura 19: Análise diária de vendas para o SKU C	86
Figura 20: Análise diária de vendas para o SKU E	86
Figura 21: Exemplo de repartição das semanas no mês	88
Figura 22: Histórico de vendas semanais para o SKU C.....	89
Figura 23: Histórico de vendas semanais para o SKU E.....	89
Figura 24: Diagrama de autocorrelação para o SKU A realizado no Crystal Ball®	91
Figura 25: Diagrama de autocorrelação para o SKU C realizado no Crystal Ball®	92
Figura 26: Diagrama de autocorrelação para o SKU E realizado no Crystal Ball®	92
Figura 27: Evolução mensal de vendas do SKU B.....	93
Figura 28: Evolução mensal de vendas do SKU F	94
Figura 29: Testes de autocorrelação mensal para os SKUs B e F realizados no Crystal Ball®	94

Figura 30: Modelo de previsão de demanda sugerido pelo Crystal Ball® para a Série 9 do SKU A	99
Figura 31: Distribuição de probabilidade para os dados históricos do SKU A.....	102
Figura 32: Distribuição de probabilidade para os erros de previsão do SKU A	103
Figura 33: Curvas de <i>sell-in</i> e <i>sell-out</i> para o SKU A.....	104
Figura 34: Cálculo da NLÍq e o consumo da reserva num sistema de reposição de estoque com previsão de demanda	109
Figura 35: Reposição semanal da reserva nos meses com quatro ou cinco semanas.....	110

LISTA DE TABELAS

Tabela 1: Técnicas de previsão qualitativas	49
Tabela 2: Caracterização da amostra de SKUs.....	80
Tabela 3: Definição do número de semanas nos meses.....	88
Tabela 4: Concentração média de vendas nas semanas para o SKU C (meses com quatro semanas)	90
Tabela 5: Concentração média de vendas nas semanas para o SKU C (meses com cinco semanas)	90
Tabela 6: Períodos de sazonalidade semanal para os SKUs.....	93
Tabela 7: Divisão do horizonte de tempo em séries semanais	97
Tabela 8: Variáveis de entrada controladas pelo usuário do <i>software</i> Crystal Ball®	98
Tabela 9: Acurácia da previsão dos modelos testados - Série 9 do SKU A	100
Tabela 10: Valores dos parâmetros dos modelos de previsão testados - Série 9 do SKUA...	100
Tabela 11: Intervalos de confiança para a previsão – Série 9 do SKU A.....	100
Tabela 12: Quadro resumo dos resultados das previsões para o SKU F	101
Tabela 13: MAPEs obtidos para as previsões de demanda semanais dos SKUs	101
Tabela 14: Quadro resumo das estatísticas dos dados de vendas dos SKUs.....	102
Tabela 15: MAPEs obtidos para as previsões de demanda mensais dos SKUs	104
Tabela 16: Simulação do modelo de reposição de estoque da proposição alternativa – SKU A	112
Tabela 17: Simulação do modelo de reposição semanal da reserva – SKU A.....	113
Tabela 18: Reduções de estoque obtidas com a reposição semanal	114
Tabela 19: Simulação do modelo de reposição de estoque baseado em previsão de demanda – SKU A	117
Tabela 20: Níveis de serviço e estoques médios em função de k	117
Tabela 21: Resultados das simulações dos três modelos considerando-se diferentes níveis de serviço.....	118
Tabela 22: Comparação do nível médio de estoque para os modelos (i) e (iii)	119
Tabela 23: Tabela utilizada para os cálculos e testes dos resultados de previsão de demanda gerados pelo <i>software</i> Crystal Ball® para o SKU D	127

LISTA DE ABREVIATURAS E SIGLAS

BO	<i>Back Order</i>
BW	<i>Business Warehouse</i>
CD	Centro de Distribuição
CHC	<i>Consumer Health Care</i>
CPFR	<i>Collaborative Planning, Forecasting and Replenishment</i>
CPT	Centro de Pesquisas e Tecnologias
DPA	Depósito de Produto Acabado
GBU	<i>Global Business Unit</i>
IOV	Inteligência e Operações de Vendas
KA	<i>Key Account</i>
MAE	<i>Mean Absolute Error</i>
MAPE	<i>Mean Absolute Percentage Error</i>
MPE	<i>Mean Percentage Error</i>
MSE	<i>Mean Squared Error</i>
OTC	<i>Over-the-Counter</i>
QLE	Quantidade do Lote Econômico
RPP	Reposição por Ponto de Pedido
S&OP	<i>Sales and Operations Planning</i>
SKU	<i>Stock Keeping Unit</i>
UN	Unidade de Negócio
WMAPE	<i>Weighted Mean Percentage Error</i>

SUMÁRIO

1 INTRODUÇÃO	27
1.1 A Empresa.....	27
1.1.1 Apresentação geral.....	27
1.1.2 A estrutura da Empresa no Brasil	28
1.1.3 Marcas e produtos.....	30
1.2 Contexto do estágio e motivação do trabalho	32
1.3 Delimitação do problema.....	33
1.3.1 Definição do alvo mensal de vendas	33
1.3.2 O sistema de reserva de inventário	37
1.3.3 Delimitação e objetivos do trabalho	44
2 REVISÃO BIBLIOGRÁFICA	45
2.1 Previsão de demanda	45
2.1.1 Classificação dos métodos de previsão de demanda	47
2.1.2 Métodos Qualitativos.....	48
2.1.3 Métodos quantitativos.....	50
2.1.3 Análise dos métodos e medição dos erros de previsão	60
2.1.4 Erros de previsão	61
2.1.5 Softwares de previsão de demanda	64
2.2 Gestão do Estoque	67
2.2.1 Gerenciamento de estoques na cadeia de suprimentos.....	68
2.2.2 Custos dos estoques.....	68
2.2.3 Modelos de reposição de estoque.....	71
3 DELIMITAÇÃO DO ESTUDO	78
3.1 Escolha do CD	78
3.2 Amostra dos SKUs.....	79

3.3 Propósito do estudo.....	80
4 ANÁLISE DA PREVISÃO DE DEMANDA	82
4.1 Propósito da previsão.....	83
4.2 Coleta de dados	83
4.3 Análise preliminar.....	85
4.3.1 <i>Inspeção gráfica e ajuste dos dados</i>	85
4.3.2 <i>Análises de autocorrelação</i>	88
4.3.3 <i>Conclusões preliminares</i>	95
4.4 Escolha dos modelos de previsão de demanda	95
4.5 Avaliação dos resultados da previsão	103
5 AVALIAÇÃO DE MODELOS DE REPOSIÇÃO PARA A “RESERVA DE INVENTÁRIO”	108
5.1 Modelagem	108
5.2 Indicadores de desempenho	110
5.3 Testes de avaliação dos modelos de reposição de estoque	111
5.3.1 <i>Reposição Diária da Reserva (sistema atual)</i>	112
5.3.2 <i>Reposição Semanal da Reserva</i>	113
5.3.3 <i>Reposição Semanal da Reserva baseada em previsão de demanda</i>	114
5.4 Comparação dos modelos e análises dos resultados	118
6 CONCLUSÃO.....	121
6.1 Síntese	121
6.2 Limitações.....	122
6.3 Considerações finais	123
REFERÊNCIAS	125
ANEXO.....	126

1 INTRODUÇÃO

O presente trabalho nasceu de uma necessidade identificada ao longo do estágio de fim de curso realizado pela autora na área comercial de um fabricante de bens de consumo. Conforme será exposto nas próximas seções, o objetivo deste trabalho é o estudo do chamado sistema de reserva de inventário da organização, a fim de se identificar uma melhor metodologia para a reposição dos produtos que fazem parte desse sistema.

Neste capítulo, serão apresentados uma descrição geral sobre o fabricante e os produtos comercializados. Essas informações serão importantes para uma melhor compreensão do contexto do problema identificado. Por questões de confidencialidade, o nome da organização foi omitido e, ao longo do trabalho, denominar-se-á Empresa.

1.1 A Empresa

Nesta seção, será feita uma breve apresentação da Empresa, incluindo aspectos relevantes sobre seu histórico, produtos fabricados, estrutura e organização. Também serão abordados os vínculos da autora com a empresa, esclarecendo-se as atribuições do estágio e a relevância do trabalho de formatura no contexto do estágio.

1.1.1 Apresentação geral

A Empresa, em cujo âmbito se originou este trabalho, é uma multinacional presente em mais de 51 países e que atua na produção de uma grande variedade de produtos destinados a manter a saúde e o bem-estar das pessoas. Dentre os bens de consumo fabricados, destacam-se produtos de beleza, farmacêuticos e de higiene infantil, oral e feminina.

1.1.2 A estrutura da Empresa no Brasil

No Brasil, a Empresa representa uma das maiores afiliadas. A fim de ampliar a diversidade de seus produtos e o volume de produção em território nacional, a Empresa investiu em laboratórios de pesquisa, a exemplo de seu Parque Industrial, localizado no interior paulista. Suas instalações industriais contam com quase 910 mil metros quadrados e é onde está concentrada toda a produção de produtos da Empresa no Brasil. A Empresa também mantém um Centro de Pesquisas e Tecnologias (CPT), que supre o mercado latino-americano na busca de novos métodos e processos de fabricação de produtos.

Para facilitar a logística de distribuição de seus produtos pelo país, a empresa possui um Depósito de Produtos Acabados (DPA) e três grandes centros de distribuição (CDs). O DPA está localizado junto à planta da fábrica e recebe os produtos logo após serem fabricados. É desse grande estoque que partem os produtos com destino aos CDs localizados nos estados de São Paulo (SP), Minas Gerais (MG) e Paraíba (PB). A Figura 1 mostra onde estão localizados os CDs e a fábrica.




Figura 1: Localização da fábrica e dos CDs

A Empresa conta, ainda, com uma sede administrativa localizada na cidade de São Paulo, onde foi realizado o estágio da autora. É nesse local que se concentram as áreas administrativas, de vendas, *marketing* e *trade marketing*. Ainda com o intuito de estar mais

próxima das regiões onde atua e de gerenciar melhor suas estratégias comerciais, a empresa está dividida em Unidades de Negócio (UN), conforme ilustra a Figura 2. Essas unidades de negócio executam localmente as estratégias de vendas, *marketing* e *trade marketing* traçadas pela sede administrativa.

As UNs representam segmentos regionais do país, com exceção apenas da UN *Key Account* (UN KA), que representa as contas de grandes clientes (Grupo Carrefour, Grupo Pão de Açúcar, Walmart, Makro, etc.). A seguir, encontra-se uma breve descrição sobre cada UN.




Figura 2: Divisão da empresa em Unidades de Negócio

- UN NENO: abrange as regiões Norte e Nordeste do país. O escritório da UN NENO está localizado na cidade de Recife.
- UN RICO: corresponde ao território que engloba a região Centro-Oeste e os estados de Minas Gerais, Espírito Santo e Rio de Janeiro. Sua unidade administrativa está situada na cidade do Rio de Janeiro.
- UN SP: unidade de negócio que responde pelo estado de São Paulo. Sua célula administrativa encontra-se no prédio da Empresa na capital paulista.
- UN SUL: reúne os estados da região Sul do Brasil e seu escritório encontra-se na cidade de Porto Alegre.
- UN KA: representa a conta dos clientes KA da Empresa, conforme mencionado anteriormente.

O presente trabalho teve como objetivo propor melhorias para o sistema de reserva de inventário da UN KA, conforme será explicado na seção 1.3.

1.1.3 Marcas e produtos

A Empresa possui uma extensa gama de produtos, com mais de 600 *Stock Keeping Units* (SKUs), que estão organizados dentro de quatro grandes grupos de produtos, chamados *Global Business Units* (GBUs). São eles:

- *Baby*

Os produtos que pertencem a essa GBU são destinados aos cuidados com a higiene infantil. Eles compreendem produtos como *shampoos*, condicionadores, colônias, fraldas, loções hidratantes, entre outros.

- *Beauty*

Esse agrupamento corresponde aos itens relacionados à beleza. Ele abrange protetores solar, cremes antirrugas, produtos para tratamento de acne, etc.

- *Consumer Health Care (CHC)*

A GBU CHC traz, dentro de sua estrutura, produtos destinados aos mais variados cuidados de higiene pessoal do consumidor. Exemplos de produtos desse tipo são os absorventes, as hastes flexíveis, desodorantes, curativos, enxaguatórios bucais, etc.

- *Over-the-Counter (OTC)*

Os itens classificados como *over-the-counter* são medicamentos que não precisam de receita médica para serem comercializados. Dentro dessa classificação estão os

remédios para resfriados, dor de cabeça, má digestão, etc. São produtos comercializados em farmácias.

As GBUs estão subdivididas em outros agrupamentos. As várias classificações estão representadas na Figura 3 e, ao lado de cada uma delas, está ilustrado um exemplo para a GBU Baby.




Figura 3: Hierarquia dos produtos da Empresa

Os diversos produtos são distribuídos por diferentes canais de distribuição, dependendo da estratégia da franquia em que está inserido. Cada canal possui características distintas, o que leva a empresa a adotar estratégias de marketing e de vendas diferentes. Atualmente, na Empresa, existem dois tipos de canais:

- Alimentar: compreende os atacados, hipermercados, supermercados e pequenos varejistas.
- Farma: engloba as redes de farmácias e distribuidores farmacêuticos.

1.2 Contexto do estágio e motivação do trabalho

O estágio foi realizado no departamento de Inteligência e Operações de Vendas (IOV). O departamento centraliza as atividades da empresa ligadas ao planejamento e ao monitoramento das vendas, de forma a auxiliar nas previsões de vendas durante o processo de *Sales and Operations Planning* (S&OP), gerenciar melhor os programas de remuneração e incentivos dos gestores de vendas, entre outras atividades.

Atualmente, o departamento está dividido em duas áreas: Planejamento e Operações de Vendas e Inteligência de Vendas. O pilar Planejamento e Operações de Vendas é responsável pelo serviço de atendimento aos clientes externos da Empresa (acompanhamento dos pedidos, entrega das mercadorias, etc.), pelo planejamento do alvo de vendas e pelo gerenciamento da remuneração dos vendedores. Já o setor de Inteligência de Vendas tem como papel principal gerar informações que auxiliem os seus clientes internos na tomada de decisão. A Figura 4 apresenta quem são esses clientes, isto é, o público a quem se destinam os estudos e relatórios.



Figura 4: Principais clientes da área de Inteligência de Vendas

O presente trabalho tem por finalidade atender à UN KA, no sentido de realizar um estudo exploratório para avaliar e propor melhorias para o funcionamento do sistema de reserva de inventário, que será explorado mais detalhadamente na próxima seção.

1.3 Delimitação do problema

A ideia da reserva de inventário nasceu da necessidade de elevar os níveis de atendimento de clientes considerados prioridade da empresa. Em poucas palavras, a reserva de inventário foi criada com a intenção de garantir a existência de produtos em estoque para atender os pedidos que chegam diariamente desses clientes KA. De fato, desde a sua criação, o sistema conseguiu elevar o nível de serviço para esses clientes, entretanto, ele ainda demonstra algumas limitações, especialmente no que se refere a um alto nível de estoque. Existe, portanto, uma visível oportunidade de melhoria que será explorada mais detalhadamente nas próximas subseções.

Primeiramente, será preciso entender como é feita a elaboração do alvo de vendas da empresa, já que ele serve de base para se estabelecer os níveis das reservas de estoques destinadas a atender aos clientes KA da Empresa. Em seguida, serão expostos aspectos relativos ao funcionamento do sistema de reserva de inventário propriamente dito. A partir dos levantamentos realizados, serão feitas análises críticas a esses processos, que servirão para delimitar o problema e definir o plano de estudo.

1.3.1 Definição do alvo mensal de vendas

O processo de definição do alvo mensal de vendas dos produtos é uma tarefa conjunta de diversos departamentos da Empresa. Dentre eles, podemos citar as áreas de *marketing*, demanda, planejamento e operações de vendas e de planejamento da produção. Estes departamentos participam do processo de forma colaborativa, de modo a chegar a um consenso sobre o alvo.

Todos os meses, durante as reuniões de vendas e *marketing*, os alvos de vendas mensais são discutidos para os próximos três meses. O processo começa com a previsão estatística da demanda, elaborada pela equipe de planejamento de demanda. Localizado na fábrica, essa equipe é responsável por toda a parte de levantamento e análise dos dados históricos, utilizando alguns modelos estatísticos disponíveis no *software* Neogrid®. Os dados históricos tratados são as vendas mensais dos SKUs dos últimos três anos para os clientes

diretos da Empresa, o que representa o chamado *sell-in*. Nesse ponto, vale fazer uma breve explicação sobre a diferença entre *sell-in* e *sell-out*, os dois tipos de informação de vendas da Empresa.

- *Sell-in*: é a venda direta da Empresa para seus clientes (distribuidores e redes varejistas).
- *Sell-out*: é a venda dos clientes da Empresa para os consumidores finais.

A Figura 5 mostra um fluxo dessas vendas.




Figura 5: Vendas *sell-in* e *sell-out*

É preciso ressaltar que as vendas no *sell-in* são muito suscetíveis a pressões políticas e comerciais, tanto por parte da Empresa, quanto por parte de seus clientes. Sendo assim, essa informação, por si só, não é a melhor forma de explicar o comportamento e as escolhas dos consumidores finais, aqueles que representam a real demanda pelo produto no final da cadeia de suprimentos.

Para gerar a previsão estatística da demanda, o *software* resgata o histórico dos últimos 36 meses de *sell-in* e testa diferentes modelos estatísticos, a fim de escolher aquele que melhor representa o comportamento da demanda. O *software* foi configurado para gerar previsões por SKU, família, grupo ou franquia, dependendo do produto. O usuário não tem a opção de mudar essa agregação em suas previsões, seria preciso reconfigurar o *software* para tanto. A escolha para agregar ou não o nível da previsão foi feita logo quando o Neogrid® foi instalado na Empresa, observando-se as curvas de vendas dos últimos três anos de cada SKU. Para aqueles itens cujas curvas apresentavam grande semelhança, a agregação foi estabelecida

por família, e assim por diante. Percebe-se, portanto, não haver nenhum estudo mais criterioso para essa decisão. A unidade de previsão utilizada é a caixa.

As previsões estatísticas geradas nessa etapa são, então, transmitidas às equipes de *marketing* e vendas e servem de base para análises seguintes. Após tomar conhecimentos desses números, as duas áreas usam essa informação para elaborar de seus planos. Elas devem gerar suas próprias previsões, acrescentando seus conhecimentos sobre o produto, mercado e clientes.

A equipe de vendas utiliza, nessa etapa, a colaboração dos gestores de vendas. Eles inserem no banco de dados do *software* as suas previsões de vendas baseadas em suas experiências com o cliente, com o produto e com a meta que ele deseja cumprir para aquele mês. Os números são então compilados no sistema e encaminhados para a aprovação dos gerentes de vendas e, finalmente, para a avaliação dos líderes de cada UN.

Na área de *marketing*, o processo de previsão é conduzido pelo gerente da marca. Nessa análise, os fatores qualitativos de expectativa de crescimento de mercado, de colocação da marca, entre outros, são levados em consideração. Na maioria dos casos, a estimativa de vendas é calculada com base nas vendas do ano anterior para aquele período, aplicando-se um percentual sobre o valor. São poucos os casos em que se utiliza um *software* capaz de auxiliar nessa tarefa.

Cabe aqui ressaltar que, atualmente, não existe nenhum processo formal para se medir quantitativamente o efeito de determinados fatores na previsão da demanda, como variações no preço, na distribuição do produto, ações promocionais, etc. Outro ponto crítico nesse aspecto é que a empresa não tem registrado, de maneira sistemática, esses eventos. Sendo assim, a equipe de demanda, durante sua previsão estatística, não consegue identificar a ocorrência de eventos anteriores que impactaram na demanda. Se, por exemplo, houve em algum período um problema produtivo que ocasionasse a falta de algum produto, reduzindo drasticamente as vendas, o sistema poderá interpretar, para aquele período, um possível comportamento sazonal que influenciará as previsões futuras. Caso a pessoa que analisa a previsão não saiba interpretar criticamente esse fato, o dado pode afetar negativamente o estabelecimento do alvo de vendas.

Após gerarem suas previsões, as equipes de *marketing* e vendas dão início a uma rodada de reuniões com o objetivo de se discutir eventuais divergências entre as metas estabelecidas por cada área. Na maioria das vezes, especialmente para produtos cuja demanda é relativamente “bem comportada” e não existe forte sazonalidade, o consenso sobre a meta é

facilmente atingido. O acordo é mais dificilmente negociado para produtos com forte sazonalidade ou quando as equipes de *marketing* e vendas planejam suas metas levando-se em consideração eventos que podem alterar a demanda.

Após a reunião de *marketing* e vendas, os números consolidados são repassados à equipe de planejamento da produção, que se localiza na fábrica e é a responsável por gerenciar as estratégias de produção da Empresa. É nesse momento que as restrições de capacidade são analisadas e o *mix* de produção é definido. O planejamento de produção da Empresa não faz parte do escopo deste estudo, no entanto, a título de conhecimento, vale citar que alguns produtos são planejados a partir do Plano Mestre de Produção, ou *Master Program Scheduling* (MPS), e outros fazem parte de um sistema de produção puxada de acordo com a necessidade de reposição dos estoques dos CDs (ponto de pedido).

Caso haja algum fator que restrinja o alvo de vendas para algum produto, a fábrica faz uma nova proposta de revisão, que é submetida à análise de vendas e *marketing*. Na reunião de Pré-S&OP, que são apresentados e validados os alvos mensais de vendas dos próximos três meses, incluindo a análise de restrição da fábrica. As eventuais pendências das reuniões de *marketing* e vendas são negociadas nessa ocasião. A última etapa do processo é a reunião chamada de S&OP Executivo, durante a qual são apresentados às diretorias e à presidência os alvos de vendas e os planos de produção.

Os alvos, depois de estabelecidos, são divididos por UNs, clientes, gestores, etc. Os critérios dessa divisão foram parametrizados no *software* Neogrid®, com base nos volumes de vendas de anos passados.

Uma dificuldade encontrada é que, muitas vezes, o alvo no nível agregado (família, por exemplo) pode até ter sido adequadamente discutido nas reuniões de vendas e *marketing*, entretanto, quando o rateio é feito, esse alvo pode não representar a verdadeira demanda daquele SKU no grupo dos KA, por exemplo. Esse fato reflete-se no dimensionamento do tamanho da reserva de inventário desses clientes. Outro problema na definição do alvo é que os gestores, não raras vezes, acabam não colaborando adequadamente para a estimativa de vendas que devem fazer. Como eles são obrigados a avaliar o volume de vendas para cada SKU que comercializam, muitos reclamam do esforço e do tempo que essa tarefa exige e não se consideram preparados para propor uma estimativa adequada. Isso pode provocar uma distorção na previsão da demanda que prejudicará a disponibilidade futura de produtos, por exemplo.

1.3.2 O sistema de reserva de inventário

A reserva de inventário consiste na separação de parte do estoque de produtos selecionados para garantir o atendimento dos pedidos de alguns clientes prioritários da Empresa. A intenção é garantir um nível de serviço diferenciado para os clientes KA (Grupo Carrefour, Grupo Pão de Açúcar, Wal-Mart, Makro, etc.), reduzir o pagamento de multas por não atendimento de pedidos e aumentar as vendas nesse canal com a redução de itens em falta no estoque.

O sistema funciona como se fosse um reservatório de água que supre primeiramente os níveis superiores e o excedente abastece os demais níveis. Trata-se, na verdade, de um sistema virtual de abastecimento de estoque que funciona nos CDs de São Paulo, Minas Gerais e da Paraíba. Os produtos são reservados pelo sistema para esses clientes prioritários, impedindo que outros possam faturar esses produtos. São desses CDs que os produtos partem para serem entregues aos clientes. O DPA abastece esses CDs a partir de um critério de reposição de estoque por ponto de pedido para cada SKU. Cabe aqui ressaltar que os CDs possuem competência de clientes, não de produtos. Isso significa que cada CD é responsável por atender uma determinada carteira de clientes, distribuindo toda a gama de produtos da Empresa. Para efeitos práticos, este trabalho se limitará à análise do CD de São Paulo, conforme será explicado com maiores detalhes no capítulo 4.

No sistema de reserva de inventário, alguns produtos possuem uma determinada quantidade de seu estoque reservada para um grupo de clientes prioritários. A quantidade restante fica disponível para atender os demais clientes. Existem, atualmente, três níveis de prioridade de clientes: grupo I, II e III (grupo dos demais clientes). Os clientes do grupo I, os KA, têm preferência no momento de abastecimento de suas reservas. Por se tratarem de clientes importantes da Empresa, existe um grande interesse em dar prioridade ao atendimento de seus pedidos. Caso não existam produtos disponíveis no momento de faturamento desses pedidos, alguns clientes do grupo I aplicam uma multa sobre a quantidade não atendida do pedido, como forma de compensar as possíveis perdas de vendas por indisponibilidade da mercadoria.

O grupo II de clientes, formado principalmente pelas grandes redes de farmácia, é o próximo na ordem de abastecimento do estoque de produtos. Caso a Empresa falte com o atendimento imediato do pedido desses clientes, não existe a mesma punição prevista como

em alguns casos do grupo I. A empresa, contudo, tem grande interesse em manter um nível de serviço elevado também para esses clientes, pois representam uma parte importante de seu faturamento.

O terceiro grupo de clientes é formado por todos os demais que não se enquadram nos casos I e II. Na ordem de prioridade, os pedidos desses clientes são os últimos a serem atendidos. Durante o fluxo de abastecimento, a entrada de novos produtos nos CDs servirá para atender, primeiramente, as reservas feitas para o grupo I. O excedente abastecerá as necessidades de estoque para o grupo II. Por último, o restante dos produtos ficará disponível para os demais clientes.

Caso haja faturamento de produtos da reserva para clientes do grupo I, o pedido é atendido e o estoque diminui. Ao final do dia, ocorre uma verificação automática do sistema, programada numa rotina computacional para ser feita uma vez por dia. É, então, lançada uma ordem de reabastecimento da reserva, que voltará ao nível máximo no dia seguinte. Após o cálculo da quantidade que falta para reestabelecer o nível da reserva do grupo I, o sistema retirará essa quantidade do estoque do grupo dos demais clientes (III) e abastecerá a reserva. A mesma lógica se aplica para as reservas do grupo II. Entretanto, os produtos reservados no grupo II não são, necessariamente, os mesmos do grupo I. A escolha dos produtos será detalhada à diante. Todavia, o foco deste trabalho será a reserva para o grupo I de clientes.

Analogamente, quando ocorre a chegada de novos produtos no CD, eles abastecerão, primeiramente, as reservas do grupo I e, em seguida, do grupo II. O restante é alocado para os demais clientes. Os CDs, por sua vez, são abastecidos de acordo com uma reposição por ponto de pedido. Isto é, o estoque total é monitorado de forma que, quando a quantidade de produtos atinge um determinado nível, é lançada uma ordem de reabastecimento daquele SKU no CD. Essa ordem é dirigida ao DPA, que providencia o abastecimento do CD. Esse ponto de pedido é calculado levando-se em consideração o faturamento médio nas últimas 52 semanas por CD, o *lead time* entre o DPA e o CD, variações na demanda e no *lead time* e o nível de serviço desejado. Todavia, a análise dessa operação não faz parte dos objetivos deste trabalho.

A Figura 6 ilustra o fluxo de abastecimento do sistema de reserva de inventário nos CDs.

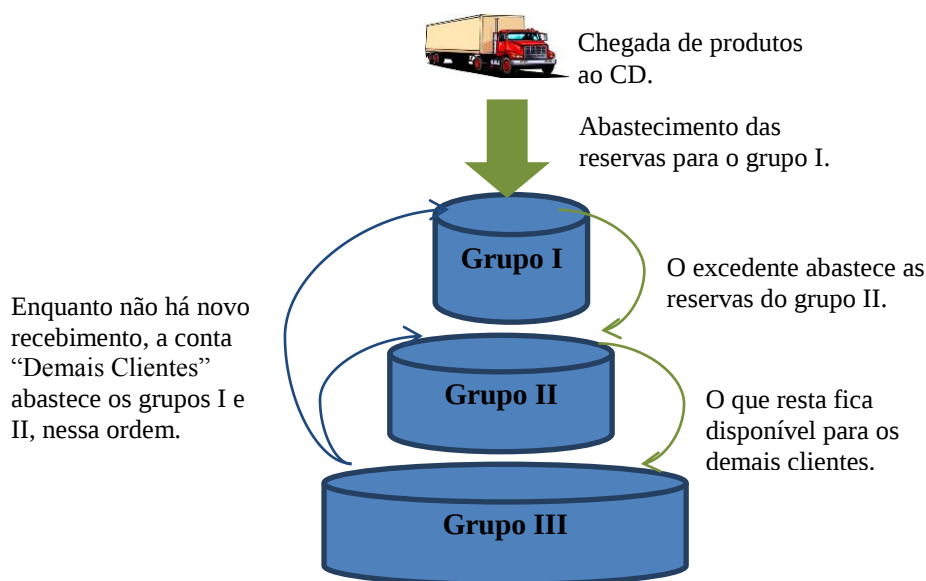


Figura 6: Fluxo de abastecimento da reserva de inventário

Clientes dos grupos I e II não consomem produtos uns dos outros, mas ambos podem recorrer ao estoque dos demais clientes caso não haja produtos suficientes na reserva para atender um determinado pedido. Os pedidos, por sua vez, podem ser digitados manualmente no sistema ou podem chegar através de ordens eletrônicas (CRM-Mobile, EDI, etc). A Figura 7 mostra como se dá o atendimento aos pedidos dos clientes.




Figura 7: Consumo do estoque no atendimento dos pedidos

O fluxograma do processo, representado na Figura 8, resume o funcionamento de abastecimento da reserva numa visão sistêmica. Para efeitos de simplificação, o processo foi representado para apenas um SKU, mas se aplica a todos os demais. Como mencionado anteriormente, este trabalho versará apenas sobre a reserva do grupo I, todavia o mesmo princípio de funcionamento aplica-se para a reserva do grupo II.




Figura 8: Fluxograma do processo de reposição da reserva de inventário

Atualmente, dos quase 600 SKUs comercializados pela Empresa, estabeleceu-se um limite de 180 para compor a lista dos itens destinados à reserva do grupo I. A escolha dos itens é feita levando-se em consideração as restrições de produção desses SKUs nos próximos dias, o alvo de vendas estipulado, a sua classificação na representatividade de faturamento do grupo dos KA (itens classe A, de acordo com o diagrama de Pareto), entre outros critérios da Empresa.

A revisão dos itens que deverão compor a reserva é feita mensalmente. Após a escolha dos SKUs, é feita a alocação, no sistema, das quantidades destinadas à reserva I. O cálculo dessa quantidade é feito, exclusivamente, com base no alvo de vendas estipulado para cada SKU. Existem dois casos para a definição dessa quantidade:

- a) Se a fábrica sinaliza que não haverá produção de um determinado item nos próximos 15 dias, o nível da reserva corresponderá à totalidade do alvo de vendas desse SKU. Isso significa que, se ainda houver desse produto no estoque, uma quantidade correspondente à totalidade do alvo de vendas do SKU será reservada.

- b) Caso contrário, a reserva é dimensionada com uma quantidade correspondente a uma estimativa de duas semanas do alvo de vendas desse produto. O nível da reserva é calculado conforme a Equação (1). Vale lembrar que a divisão dos meses em quatro ou cinco semanas segue o calendário interno da Empresa.

$$\text{Tamanho da reserva do SKU} = \frac{\text{Alvo de vendas do mês do SKU para os clientes do grupo I}}{\text{nº de semanas do mês}} \times 2 \quad (1)$$

Diariamente, tanto no caso (a), como no caso (b), o sistema buscará reservar essas quantidades calculadas. Para facilitar a compreensão do processo de abastecimento diário da reserva, bem como do faturamento dos produtos em reserva de estoque, a Figura 9 ilustra um exemplo dessa simulação do sistema para um SKU qualquer.




Figura 9: Abastecimento da reserva e faturamento de pedidos

No início do mês, dia n , é feita a escolha dos SKUs e o cálculo das quantidades que serão reservadas. O responsável pela operação insere esses dados no sistema ERP da empresa, o SAP, de acordo com as quantidades que foram calculadas separadamente em uma planilha Excel®. O sistema reservará essas quantidades buscando esses produtos no estoque do grupo III. Caso entre um pedido de um cliente KA, ele será faturado da reserva do grupo I. No dia seguinte, o sistema verificará que o nível da reserva foi reduzido. Sendo assim, ocorrerá o reabastecimento da reserva, com a retirada de produtos do estoque dos “demais clientes”. Caso não haja produtos suficientes em estoque, o sistema retirará a máxima quantidade possível a fim de tentar completar o nível estabelecido da reserva, de acordo com o que foi previsto nos casos (a) ou (b). Neste caso, o estoque ficará zerado para os demais clientes.

No dia $n+1$, os pedidos que chegam dos clientes KA continuarão a ser faturados da reserva, até enquanto existirem produtos disponíveis para tanto. Caso isso não ocorra, os pedidos não poderão ser faturados e entram em *Back Order* (BO), ou seja, ficam à espera da chegada de novos produtos em estoque para serem faturados. Em alguns casos, existe o BO parcial, que corresponde ao atendimento parcial do pedido e espera de novo abastecimento do estoque para completar a ordem. Alguns clientes KA não aceitam o BO parcial e cancelam completamente seus pedidos. Nesses casos, a Empresa é obrigada a pagar uma multa por não atendimento do contrato baseada na quantidade não faturada de produtos.

É interessante notar que os vendedores, na maioria das vezes, negociam suas vendas sem visibilidade do estoque efetivamente disponível para atender o pedido. A empresa não disponibiliza para a equipe de vendas um sistema de informação para acompanhamento da disponibilidade de produtos em tempo real. Essa ausência de informação acaba por agravar os casos de vendas sem estoque, elevando o número de BOs de produtos e, consequentemente, de cancelamentos e multas.

Voltado ao caso em questão, havendo produtos suficientes na reserva para atender ao pedido, ele é faturado. Isso gera, novamente, uma diminuição do nível da reserva. Quando a rotina computacional for efetuada, ela procurará produtos no estoque dos “demais clientes” para abastecer a reserva. Caso ocorra a chegada de mais produtos no CD, o sistema de reserva de inventário fará com que a reserva do grupo I seja primeiramente abastecida, em seguida a reserva do grupo II e, finalmente, o estoque do grupo dos “demais clientes”, assim que a rotina de abastecimento for efetuada.

Vê-se, então, que o dimensionamento da reserva depende diretamente do alvo mensal de vendas. Como exposto anteriormente, um dos problemas enfrentados é a elevada quantidade de produtos que é reservada constantemente, devido a uma rotina diária de revisão do nível da reserva. Desse modo, o sistema procura reservar, diariamente, uma quantidade de produtos que corresponde, na maioria dos casos, a 50% da previsão mensal de vendas do SKU para os clientes KA. Esse fato eleva, desnecessariamente, o nível médio de estoque diário e impede, muitas vezes, que outros clientes sejam atendidos.

Essa situação é prejudicial para a empresa, especialmente nos últimos dias de fechamento do mês, quando ocorre uma maior concentração de pedidos. Não raras vezes, a Empresa deixa poder atender pedidos de outros clientes, pois, se não existirem produtos disponíveis no estoque do grupo “demais clientes”, o sistema não permite a retirada desses produtos da reserva dos grupos I e II. Sendo assim, mesmo que essas quantidades reservadas não sejam utilizadas num determinado dia para atenderem clientes KA, elas não poderão ser utilizadas para atender pedidos de outros clientes, ainda que haja falta desses produtos no estoque destinado aos demais clientes. Um problema menos comum, mas que também ocorre é a falta de produtos para clientes KA, especialmente na última semana do mês. Durante o período de fechamento do mês, a concentração do volume de vendas é mais acentuada (podendo chegar, em alguns casos, a mais de 50% das vendas do mês), elevando os riscos de ruptura. O gráfico da Figura 10 ilustra as vendas faturadas no CD de SP para um produto da Empresa, denominado SKU A (maiores detalhes sobre a escolha dos SKUs analisados neste trabalho encontram-se no capítulo 3) e a quantidade planejada para ser reservada diariamente (de acordo com os critérios explicados anteriormente).




Figura 10: Comparação entre quantidades faturadas e quantidades reservadas do SKU A

Outra questão que merece atenção é a própria política de vendas da Empresa. Os vendedores possuem sua remuneração atrelada ao alvo de vendas que recebem mensalmente. Eles possuem uma remuneração que varia de acordo com o percentual atingido sobre o alvo total (em reais) de vendas. Isto significa que o vendedor não precisa vender as quantidades estipuladas para cada SKU. Ele pode vender mais de alguns tipos de SKUs e menos de outros, e, ainda assim, conseguir cumprir sua meta de vendas. Muitos chegam ao final do mês com a pressão de atingir o alvo e acabam negociando com o cliente uma compra mais forte de alguns produtos, em detrimento de outros. Outra possibilidade é não haver disponibilidade em estoque para um determinado SKU, dessa forma, o vendedor acaba forçando a venda de outro produto que não havia planejado vender.

A empresa já se atentou para o fato de que manter fixo o nível da reserva em quase 50% do alvo mensal de vendas acarreta essas distorções. Apesar de ser um processo crítico, não existe um acompanhamento formal estabelecido para analisar os casos de pedidos não atendidos, tanto por excesso (nesse caso, os demais clientes não são atendidos por causa da reserva elevada de produtos), quanto por falta de produtos na reserva (a concentração de vendas no fim do mês e a política de vendas são os principais causadores desse problema). É válido ressaltar, contudo, que ações no sentido de rever essa política da reserva devem ser tomadas, mas não fazem parte deste estudo.

1.3.3 Delimitação e objetivos do trabalho

A partir da análise do sistema de reserva do inventário de clientes KA e do processo de estabelecimento do alvo de vendas, percebe-se que a definição do nível de estoque para a reserva não é feita da maneira mais adequada e a principal consequência disso é o elevado nível diário de estoque.

O objetivo deste trabalho é, portanto, auxiliar no estudo de um método mais adequado para o dimensionamento e a reposição dos estoques dos produtos em reserva. Com isso, espera-se reduzir o elevado nível de estoque atual, ao mesmo tempo em que se mantenha um nível de serviço adequado para os clientes KA. Esse ajuste no nível atual de estoque poderá, consequentemente, evitar que outros clientes deixem de ser atendidos devido ao excesso de produtos reservados. Para tanto, serão analisados modelos de reposição de estoque, que poderão, futuramente, ser aplicados no sistema de reserva de inventário da Empresa.

2 REVISÃO BIBLIOGRÁFICA

Neste capítulo, serão apresentados os fundamentos teóricos mais relevantes para a abordagem do problema anteriormente exposto. A previsão de demanda e a gestão de estoques são os dois principais temas tratados nos próximos tópicos. A revisão teórica desses dois assuntos fornecerá subsídios para a formulação da proposta de solução, que será exposta nos próximos capítulos.

2.1 Previsão de demanda

Segundo Lustosa et al. (2008), demanda é a disposição dos clientes para consumir determinado produto ou serviço. Prever a demanda é um fator de extrema importância para as empresas. Os resultados gerados pela previsão de demanda constituem um dado relevante do processo de Planejamento da Produção. Consequentemente, a qualidade da previsão gera impactos diretos na qualidade desse Planejamento.

Silver; Pyke e Peterson (1998) ressaltam a necessidade de se prever demandas futuras para melhor gerenciar os estoques, para obter o nível de serviço desejado e para identificar necessidades futuras de expansão da capacidade produtiva. Makridakis, Wheelwright e Hyndman (1998) também apontam a importância da previsão para a determinação das quantidades de recursos e de matérias-primas necessárias para a fabricação dos produtos. A previsão se mostra ainda mais essencial quando a fabricação do produto demora mais tempo do que os consumidores desejam esperar para consumi-los, nesse caso, é preciso prever a demanda futura para providenciar que o produto esteja disponível no momento em que o consumidor desejar comprá-lo. (SILVER; PYKE; PETERSON, 1998).

Lewis (1997) atenta para a diferença entre previsão e predição. De modo geral, a previsão pode ser interpretada como sendo um processo científico para estimar um evento futuro, baseando-se em dados passados. Já a predição pode ser considerada uma estimativa de um evento futuro baseada em considerações subjetivas. Essas considerações podem ser

capazes de apontar mudanças nas tendências de demanda de determinado produto, devido, por exemplo, a uma alteração na política de importação do país. Todavia, Lewis (1997) afirma que, devido a seu caráter subjetivo, a predição é mais complexa e normalmente mais custosa de se produzir numa rotina computacional do que a previsão.

Em geral, a demanda pode ser classificada como dependente ou independente. Quando a demanda de certo produto estiver claramente associada à demanda de outros produtos, ela é tida como dependente. Esse é o caso, por exemplo, da demanda por pneus numa linha de montagem, que depende da quantidade de carros a serem produzidos. Torna-se importante, portanto, conhecer a demanda do produto acabado para se elaborar uma boa previsão de demanda dos componentes. Segundo Lewis (1997), a demanda é independente quanto ela não é afetada pela demanda de outros produtos relacionados.

Os métodos de previsão de demanda podem ser categorizados também com base nos horizontes de previsão. Lewis (1997) cita três classificações conforme o horizonte de tempo: curto, médio e longo prazos.

- *Previsões de curto prazo*

São as previsões que estão associadas ao nível operacional. Normalmente, são elaboradas para muitas linhas de produtos e são tipicamente utilizadas em ambientes de reposição de estoques. Os métodos empregados nesse tipo de previsão devem ser simples e relativamente de baixo custo de implementação. O período associado a esse tipo de previsão varia de uma semana a um mês. São exemplos os métodos de séries temporais como o de média móvel e a suavização exponencial. Atualmente, com a utilização de *softwares* específicos de previsão de demanda, tornou-se viável testar uma ampla gama de modelos, a fim de determinar aquele que se adequa melhor à cada padrão de demanda.

- *Previsões de médio prazo*

Em geral, são previsões feitas em nível tático. O horizonte de previsão está associado a períodos mensais ou de até um ano. Esse tipo de previsão é importante para se determinar o Plano Agregado da Produção, que inclui decisões sobre matérias-primas necessárias para a fabricação de produtos, a contratação de pessoal, etc. Com o

barateamento dos custos computacionais, métodos mais sofisticados, que requerem cálculos mais complexos, podem ser aplicados em modelos tais como os métodos de regressão, previsão Bayasiana ou certos tipos de séries temporais.

- *Previsões de longo prazo*

São previsões que exigem prazos de alguns anos. São importantes para o planejamento estratégico das empresas, na decisão de ampliação ou não redução da capacidade produtiva e da rede logística. Podem empregar métodos que exigem emprego de uma tecnologia mais sofisticada, como o método Delphi, por exemplo. As previsões de longo prazo servem para determinar os recursos que a empresa deverá dispor e programar os investimentos que deverão ser feitos.

Lustosa et al. (2008) associam, ainda, o horizonte de previsão ao nível de agregação da informação sobre a demanda. Nas previsões de longo prazo, mais empregadas no nível estratégico, as informações de demanda apresentam-se de forma bastante agregada, por tipo de produto, por exemplo. Para previsões de médio prazo, destinadas ao plano tático, as previsões são normalmente feitas por família de produtos. Já no nível operacional, de curto prazo, as informações por item são mais empregadas.

A agregação dos produtos nos níveis estratégicos e táticos, conforme explicam Lustosa et al. (2008), tem por objetivo amenizar as incertezas das previsões e não prejudicam a qualidade das decisões, uma vez que o planejamento da capacidade e as metas produção, por exemplo, não necessitam de informações muito detalhadas sobre a demanda. No nível operacional, contudo, é preciso conhecer o detalhamento da demanda por item para dar suporte a decisões tais como a reposição de estoques.

2.1.1 Classificação dos métodos de previsão de demanda

Os métodos de previsão podem se divididos em duas grandes categorias: qualitativos e quantitativos. Uma dimensão adicional para a classificação dos métodos quantitativos é aquela que considera o tipo de modelo de previsão baseado em séries temporais (projeção baseada nas variáveis tempo e demanda do item) ou em modelos causais (correlação). A Figura 11 mostra algumas dessas classificações.




Figura 11: Métodos de previsão de demanda

Fonte: Adaptado de Lustosa et al. (2008)

2.1.2 Métodos Qualitativos

Para Makridakis, Wheelwright e Hyndman (1998), as técnicas qualitativas são mais apropriadas para casos em que pouca ou nenhuma informação está disponível, mas existe um suficiente conhecimento acumulado sobre o evento que se deseja prever. Normalmente, tais métodos requerem a experiência de pessoas treinadas para tanto.

Técnicas qualitativas são, geralmente, baseadas em consenso de opiniões e podem ser empregadas em associação com métodos quantitativos a fim de oferecer maior acurácia. Devido a sua complexidade, métodos qualitativos são quase exclusivamente empregados em formulação de estratégias de médio e longo prazos ou na previsão de novos produtos (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998).

Hanke e Reitsch (1998) destacam, contudo, que por mais que estejam baseados em opiniões e julgamentos, aqueles que utilizam métodos qualitativos se apoiam, ainda que indiretamente, em algum tipo de dado histórico para a formulação mental do julgamento. Dentre os exemplos de técnicas qualitativas, Ballou (2004) cita a pesquisa de mercado, o painel de consenso, estimativas da equipe de vendas e método Delphi. Um resumo das principais características de tais técnicas está apresentado na Tabela 1.

Tabela 1: Técnicas de previsão qualitativas

Método	Descrição	Horizonte de tempo da previsão
<i>Delphi</i>	Realização de um painel de especialistas através de uma sequência de questionários, cujas respostas a um desses são usadas para se produzir o próximo. Todo conjunto de informações disponível para alguns dos especialistas é disponibilizado para os demais. Dessa forma, todos têm acesso à integralidade das informações para a previsão. Essa técnica é indicada para eliminar o efeito da influência das opiniões da maioria ou do chefe.	<i>Médio-Longo</i>
<i>Pesquisa de mercado</i>	Procedimento sistematizado, formal e consciente para avaliação da evolução dos mercados, força das marcas, testes de novos produtos, etc. Fonte de informação são os agentes externos à empresa, indicando tendências e aceitações.	<i>Médio-Longo</i>
<i>Painel de consenso</i>	Esta técnica parte do pressuposto de que a opinião de vários especialistas é melhor do que a de apenas um indivíduo. Nesse caso, a comunicação exerce forte influência e fatores sociais podem interferir não refletindo um consenso real. A solicitação da opinião dos executivos inclui-se nesta classe.	<i>Médio-Longo</i>
<i>Estimativas da equipe de vendas</i>	Como os vendedores estão mais próximos da realidade dos clientes, suas opiniões podem ser solicitadas, levando a uma melhor indicação a respeito das reais necessidades dos clientes.	<i>Curto-Médio</i>

Fonte: Adaptado de Ballou (2004)

O presente trabalho está direcionado para uma abordagem mais operacional da previsão de demanda, que, por sua vez, ajudará na decisão de reposição de estoques dos itens que fazem parte da reserva de inventário. Os métodos qualitativos, portanto, não serão analisados, pois estão mais voltados para um nível estratégico de decisão a médio ou longo prazos.

2.1.3 Métodos quantitativos

Segundo Makridakis, Wheelwright e Hyndman (1998), os métodos quantitativos só podem ser aplicados com a constatação de três condições:

- ✓ Existem dados históricos disponíveis;
- ✓ Há a possibilidade de quantificação dessas informações em dados numéricos;
- ✓ Pode-se assumir que os padrões do passado serão válidos no futuro.

Verificados os requisitos acima, Makridakis, Wheelwright e Hyndman (1998) propõem cinco etapas que devem ser seguidas num processo de previsão de demanda que emprega modelos quantitativos. São elas:

1) *Definição do problema*

Definida talvez como a etapa mais trabalhosa do processo, é crucial que exista um conhecimento claro dos objetivos aos quais a previsão se destina, quem utilizará a previsão e qual a finalidade da previsão na organização. É importante que a empresa invista no preparo das pessoas que estarão envolvidas na coleta dos dados, na manutenção da base de dados e no uso das previsões em planejamentos futuros.

Lustosa et al. (2008) destacam ainda que é a partir da definição dos objetivos que se determinam o nível de precisão que deverá ser obtido, quem participará do processo, quais são os prazos e recursos necessários.

2) *Coleta de dados*

Makridakis, Wheelwright e Hyndman (1998) ilustram dois principais tipos de informações para análise: dados históricos (geralmente numéricos) e informações de natureza pessoal de agentes relacionados ao processo. Essas informações são relevantes na construção dos modelos e não podem ser desprezadas.

3) *Análise preliminar (exploratória)*

O objetivo dessa etapa é entender quais importantes informações preliminares os dados podem revelar. Para tanto, Makridakis, Wheelwright e Hyndman (1998) sugerem uma inspeção visual através da apresentação dos dados em forma de gráficos. É interessante também realizar uma análise preliminar das informações por meio de médias, desvios padrão, mínimos e máximos, identificar a existência de tendências, sazonalidades, ciclos, e também pontos extremos (*outliers*).

É durante essa fase que são feitos os tratamentos ou correções dos dados, a fim de se eliminar eventuais distorções que possam interferir nos resultados dos modelos (LUSTOSA et al., 2008). Para tanto, a análise e o julgamento de pessoas com conhecimento no assunto se mostram importantes.

4) Escolha do modelo e determinação dos parâmetros

Essa é a etapa de testes e escolha dos valores dos parâmetros que melhor explicam o comportamento dos dados. Cada modelo é baseado em um conjunto de premissas (explícitas e implícitas) e normalmente envolvem um ou mais parâmetros que deverão ser ajustados usando os dados históricos conhecidos.

A calibração do modelo consiste, então, em simular os dados históricos de forma a se obter os valores de parâmetros do modelo que fornecem o menor erro de previsão possível.

5) Uso e avaliação do modelo de previsão

Após a seleção do modelo e estimativa dos parâmetros, o modelo gerará previsões que deverão ser comparadas com os dados reais que efetivamente ocorrem. Dessa forma, aqueles que utilizam a previsão poderão avaliar os pros e contras do modelo escolhido.

Nessa etapa, Makridakis, Wheelwright e Hyndman (1998) ressaltam a importância do julgamento de *experts* para melhorar a acurácia das previsões. É fundamental, contudo, que mesmo após a implementação do modelo, ele continue sendo monitorado e revisto periodicamente, a fim de que continue gerando os resultados desejados (LUSTOSA et al., 2008).

Russell e Taylor (2006) propõem uma abordagem semelhante quanto às etapas a serem seguidas durante o processo de previsão de demanda empregando-se métodos quantitativos. A Figura 12 resume esse processo.




Figura 12: Etapas do processo de previsão de demanda

Fonte: Adaptado de Russell e Taylor (2006).

Vale lembrar que com o avanço da tecnologia e o desenvolvimento de novos *softwares* de previsão, o uso e a seleção dos métodos de previsão de demanda se tornaram mais fáceis. Toda a parte de seleção, calibração e geração da previsão, no processo proposto por Russell e Taylor (2006), correspondentes às etapas de 4 a 8(b), tornaram-se, praticamente, automatizadas com o uso de *softwares* de previsão de demanda.

O monitoramento feito ao longo do tempo e os ajustes dos modelos são feitos automaticamente, sem exigir habilidades específicas do usuário para tanto. Esse é um fato que requer atenção especial das empresas que decidem automatizar o processo de previsão de suas organizações. Os *softwares* de previsão de demanda não devem ser encarados como um recurso capaz de gerar resultados que descrevem o comportamento futuro da demanda de forma “misteriosa” ou “mágica”. É preciso ter cautela ao se utilizar esse tipo recurso, sendo recomendável que o usuário tenha, pelo menos, um conhecimento básico a respeito dos modelos que o *software* utiliza. A capacitação do usuário também é fundamental para que ele

seja capaz de realizar uma análise crítica a respeito dos resultados gerados pelo *software* e saiba interpretá-los de maneira satisfatória. Sem esse conhecimento básico, há sempre o risco de se obter previsões ruins e que não refletem o real comportamento da demanda.

Conforme mostra a Figura 11, os métodos quantitativos podem empregar modelos de correlação (regressão) ou modelos de projeção (séries temporais). Cada um possui características próprias de complexidade e precisão. Em particular, os modelos de correlação procuram descobrir a forma de relação entre as variáveis e em que grau elas influenciam a demanda. São modelos mais empregados em situações de previsão a longo e médio prazos e para o planejamento agregado da produção e da capacidade (SILVER; PYKE; PETERSON, 1998). Tais modelos não serão abordados com maior profundidade no presente estudo, pois fogem dos objetivos pretendidos. Por se adequarem mais aos propósitos deste trabalho, apenas os modelos de projeção serão vistos com maiores detalhes.

Modelos de projeção

Os modelos de projeção, ou séries temporais, utilizam dados numéricos passados da variável que se deseja prever e procuram encontrar um padrão histórico de repetição e extrapolar esse parâmetro para tempos futuros (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998).

Hanke e Reitsch (1998) explicam que os métodos de projeção por séries temporais tratam os dados de forma estatística a fim de se identificar comportamentos, mudanças e oscilações dos dados ao longo do tempo e projetá-los para o futuro. Para Makridakis, Wheelwright e Hyndman (1998), o interessante nesses métodos é o fato de não ser preciso entender as relações que governam o comportamento dos dados e nem o porquê elas acontecem. Dessa forma, as séries temporais são mais simples de serem empregadas e apresentam resultados interessantes em termos de previsões de curto prazo e quando se deseja prever um grande volume de SKUs (SILVER; PYKE; PETERSON, 1998).

Ballou (2004) ressalta outra vantagem do modelo de projeção em horizontes curtos de tempo, que é o fato de serem capazes de adaptarem-se às mudanças nos padrões de tendência e sazonalidade a partir da coleta de novos dados. A desvantagem, entretanto, é que uma rápida mudança nesses padrões só poderá ser detectada após sua ocorrência. Esses modelos

poderiam, portanto, retardar mudanças nos padrões temporais, não sendo eficientes na sinalização dessas alterações antes que elas ocorram. Todavia, como esse tipo de previsão visa um curto horizonte de tempo, essa não é uma limitação necessariamente grave.

Silver; Pyke e Peterson (1998) e Makridakis, Wheelwright e Hyndman (1998) destacam que toda série temporal pode ser decomposta em quatro elementos: horizontalidade ou nível, tendência, sazonalidade e variação cíclica. Silver; Pyke e Peterson (1998) acrescentam ainda a aleatoriedade como outro componente.

- *Horizontalidade ou nível*: elemento que representa o padrão constante em torno do qual os dados flutuam. Séries desse tipo são chamadas de estacionárias. Se apenas existisse a horizontalidade as séries flutuariam em torno de um valor aproximadamente constante no tempo.
- *Tendência*: existência de um aumento ou diminuição sistemáticos no valor dos dados.
- *Sazonalidade*: ocorrência devido a fatores sazonais, que resultam de elementos naturais (como o clima) ou de decisões humanas (o começo das aulas nas escolas, por exemplo). Pode-se dizer que a sazonalidade ocorre em períodos mais ou menos bem definidos, apesar da repetição não ser exatamente a mesma nos períodos.
- *Variação cíclica*: Esse fator caracteriza os dados que apresentam elevações ou quedas que não são fixas nos períodos. Nas séries econômicas, as variações cíclicas ocorrem devido às flutuações econômicas, resultadas de ciclos econômicos.
- *Aleatoriedade*: flutuações irregulares podem ter origem em eventos imprevistos, como uma má condição climática ou greve. Essas variações não são captadas nos modelos de séries temporais. Outros exemplos de fatores que aumentam a variabilidade da demanda são as ações dos concorrentes (promoções, lançamentos de novos produtos, etc.) e até mesmo as práticas de vendas das organizações.

Como mencionado no capítulo 1, a venda de produtos da Empresa em estudo sofre impactos de algumas ações de seus próprios vendedores, que forçam as vendas de alguns itens para fecharem seus alvos de vendas. Esse fato contribui para gerar alguns pontos de aleatoriedade nos dados históricos disponíveis. Cabe ressaltar que outros fatores relacionados à dinâmica da cadeia de suprimentos, como a concentração de vendas no final do mês e o Efeito Chicote, que será explicado mais adiante, dificultam ainda mais a previsão de demanda

no caso da empresa em questão. Esses elementos não são devidamente captados nos modelos de séries temporais, o que prejudica a qualidade das previsões geradas.

Makridakis, Wheelwright e Hyndman (1998) ressaltam que muitas séries de dados incluem não apenas um desses componentes, mas uma combinação deles. Identificar qual o padrão de demanda é um ponto relevante para a escolha do processo de previsão de demanda. Na sequência, serão listados apenas alguns modelos de projeção por séries temporais mais relevantes.

Nos próximos parágrafos, serão empregadas as seguintes notações:

F_{t+1} – previsão feita no período t para o período seguinte

Y_t – valor real observado no período t

- *Decomposição de séries temporais*

Métodos de decomposição são aqueles que tentam encontrar dois componentes principais que caracterizam uma série temporal básica: tendência e sazonalidade.

O método da decomposição parte do princípio de que os dados podem ser divididos da seguinte maneira:

$$\text{Demanda} = \text{padrão} + \text{erro} = f(\text{tendência}, \text{sazonalidade}, \text{erro})$$

Sua representação matemática geral seria da seguinte maneira (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998):

$$Y_t = f(S_t, T_t, E_t) \quad (2)$$

Onde: Y_t – valor real da demanda no período t

S_t – componente sazonal no período t

T_t – componente de tendência no período t

E_t – componente residual no período t

Existem duas abordagens principais para decompor essa demanda. Uma que emprega a formulação aditiva:

$$Y_t = S_t + T_t + E_t \quad (3)$$

A outra é a chamada decomposição multiplicativa:

$$Y_t = S_t \times T_t \times E_t \quad (4)$$

Silver; Pyke e Peterson (1998) ainda acrescentam um modelo misto (parcialmente aditivo, parcialmente multiplicativo). Os métodos aditivos são mais indicados quando a variação da sazonalidade não é muito acentuada com o passar do tempo. Já os multiplicativos são mais adequados para os casos em que o fator sazonalidade aumenta ou diminui proporcionalmente ao nível de observação da série, como é o caso das séries econômicas.

Diversos procedimentos estatísticos podem ser empregados para se isolar cada componente. Makridakis, Wheelwright e Hyndman (1998) afirmam, contudo, que a principal dificuldade em tais métodos é gerar uma previsão adequada para os componentes da série, sendo a tendência o item mais difícil de prever. Os autores propõem, portanto, o uso da decomposição mais como uma ferramenta para entender melhor a série de dados, do que para gerar uma previsão. Esse método é mais indicado para uma etapa preliminar à seleção e aplicação do modelo de previsão.

▪ Média móvel

Esse método suaviza a influência dos períodos anteriores, descartando os dados mais antigos, à medida que entram dados mais recentes na série.

$$F_{t+1} = \frac{1}{k} \sum_{i=t-k+1}^t Y_i \quad (5)$$

Onde : k – número dos últimos períodos observados que se deseja considerar no cálculo da média.

Esse modelo lida apenas com os últimos k períodos dos dados e a quantidade de dados não muda ao longo do tempo. Contudo, atribui pesos iguais para os k dados mais recentes e nenhum peso para dados mais antigos, prejudicando a identificação de tendências e sazonalidades (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998).

- *Suavização exponencial*

A suavização exponencial traz uma alternativa à questão dos pesos iguais atribuídos aos períodos pela média móvel. Pelo método da suavização exponencial simples os valores passados possuem pesos decrescendo geometricamente. Pressupõe-se que, partindo de um valor inicial, a demanda oscila em torno de um patamar ou demanda base constante. O método utiliza a previsão do período anterior e a ajusta esse valor com o erro da previsão (que é representado pela diferença entre a demanda real no período t e a previsão feita para o período t). Dessa forma, tem-se a Equação (6):

$$F_{t+1} = F_t + \alpha(Y_t - F_t) \quad (6)$$

Onde α é conhecida como constante de suavização para base e está compreendida entre 0 e 1.

O método acrescenta à previsão do período anterior um valor de ajuste sobre o erro ocorrido para aquela previsão. De fato, quando a constante α é próxima de zero, haverá uma pequena correção. Porém, quando α se aproxima de 1, ocorrerá um ajuste maior dos valores para a previsão do período seguinte. Makridakis, Wheelwright e Hyndman (1998) lembram, contudo, que o efeito de α é similar ao efeito de se incluir uma quantidade maior ou menor de dados numa média móvel.

Para a determinação do valor de α , Lustosa et al. (2008) sugerem o uso de planilhas eletrônicas, softwares estatísticos, ou softwares específicos de previsão de demanda que fazem a calibração automática do modelo. Dessa forma é possível encontrar mais rapidamente o valor de α que produz os menores erros médios.

- *Suavização exponencial com tendência (modelo de Holt)*

O modelo de Holt propõe acrescentar o componente de tendência ao modelo de suavização exponencial. Essa segunda variável de suavização para tendência, β , acrescentada ao modelo, reflete o aumento ou diminuição da demanda de um período para o outro. Os valores de β também variam entre 0 e 1. Da mesma forma que a estimativa do nível da série no período t , L_t , a variável b_t represente a estimativa para a tendência e também será atualizada exponencialmente segundo as equações seguintes:

$$L_t = \alpha Y_t + (1 - \alpha)(L_{t-1} + b_{t-1}) \quad (7)$$

$$b_t = \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1} \quad (8)$$

$$F_{t+m} = L_t + b_t m \quad (9)$$

Onde: L_t – estimativa do nível da série no período t

b_t – estimativa para a tendência no período t

m – número de períodos a frente que se deseja prever

Nesse caso, a Equação (7) fornece um valor a partir da média ponderada entre a demanda real observada e a nova base, que recebe uma parcela de aumento ou diminuição (tendência) da demanda. A suavização da tendência é calculada na Equação (8), que se utiliza dos últimos dois níveis da série e se baseia na previsão de tendência do período anterior. Finalmente, na Equação (9), é calculada a demanda de m períodos adiante.

Lustosa et al. (2008) explicam a escolha dos valores de inicialização do nível (base) e da tendência possui influência mais presente nos primeiros resultados da previsão. Numa série mais longa e utilizando valores iniciais convenientes, essa influência tende a ser menos marcante. Todavia, os valores de α e β exercem um grande impacto, sendo a calibração concentrada nesses dois parâmetros. No modelo de suavização exponencial com tendência será preciso, portanto, escolher a combinação de valores para α e β que minimiza os erros de previsão. Novamente, recomenda-se o uso de recursos computacionais adequados para tal finalidade (planilhas eletrônicas, *softwares* de previsão, etc.).

- *Suavização exponencial com tendência e sazonalidade (modelo de Holt-Winters)*

É sabido que muitas empresas possuem itens, cuja demanda é afetada pela sazonalidade. Nesses casos, é mais indicado o uso do modelo de Holt-Winters, que incorpora o componente sazonalidade ao modelo de Holt. As equações básicas do modelo de Holt-Winters são apresentadas a seguir:

$$L_t = \alpha \frac{Y_t}{S_{t-s}} + (1 + \alpha)(L_{t-1} + b_{t-1}) \quad (10)$$

$$b_t = \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1} \quad (11)$$

$$S_t = \gamma \frac{Y_t}{L_t} + (1 - \gamma)S_{t-s} \quad (12)$$

$$F_{t+m} = (L_t + b_t m)S_{t-s+m} \quad (13)$$

Onde: s – duração da sazonalidade (número de meses, semanas, etc.)

S_t – sazonalidade da série no período t

γ – constante de suavização para sazonalidade (valores entre 0 e 1)

Esse modelo consiste em projetar a demanda base, sem o efeito da sazonalidade, representada pelo termo S_{t-s} . A partir da retirada do efeito sazonal na Equação (10), obtém-se a base sem influência da sazonalidade. O efeito da tendência é calculado na Equação (11), como no método de Holt. Em seguida, a sazonalidade do período t é calculada na Equação (12), que é uma média ponderada entre o índice real observado e o índice anterior calculado. Por fim, a Equação (13) calcula a previsão para o instante $t+m$ multiplicando a demanda base pelo componente de sazonalidade.

A inicialização do processo se dá com a definição do nível, tendência e sazonalidade iniciais. Conforme Lustosa et al. (2008) recomendam, isso pode ser feito considerando o primeiro ciclo sazonal da série e fixando, em seguida, a razão entre demanda de cada período e a demanda média dos períodos. Os autores explicam que o modelo de Holt-Winters requer uma quantidade maior de dados, contendo pelo menos três ciclos sazonais completos.

2.1.3 Análise dos métodos e medição dos erros de previsão

Uma ferramenta útil na análise de séries temporais é a análise de autocorrelação. Esse método ajuda a identificar algumas características na série de dados tais como sazonalidade, ciclos e outros padrões. O coeficiente de autocorrelação compara dois dados na série temporal, Y_t e Y_{t-1} , defasados de um período entre si. Similarmente, é possível comparar dados defasados de dois, três, ou mais períodos. A fórmula para se calcular o coeficiente de autocorrelação é dada pela Equação (14).

$$r_k = \frac{\sum_{t=k+1}^n (Y_t - \bar{Y})(Y_{t-k} - \bar{Y})}{\sum_{t=1}^n (Y_t - \bar{Y})^2} \quad (14)$$

O coeficiente r_1 indica o quanto sucessivos valores de Y estão relacionados uns com os outros, r_2 mostra o quanto valores defasados de dois períodos estão defasados entre si, e assim sucessivamente. Os coeficientes de autocorrelação $r_1, r_2, \dots$, formam a chamada função de autocorrelação (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998).

Quanto menos os dados forem correlacionados, mais próximos de zero serão os valores dos coeficientes. Caso os dados mostrem forte autocorrelação, o valor do coeficiente será alto. Por exemplo, para dados com sazonalidade de 12 períodos, o coeficiente de r_{12} , $r_{24}, \dots$, se mostrarão mais elevados que os coeficientes para os demais períodos.

Um fator importante na estimativa da autocorrelação é identificar a significância do coeficiente. Makridakis, Wheelwright e McGee (1983) explicam que, assumindo uma amostra de tamanho infinito, em teoria, todos os coeficientes de autocorrelação deveriam ser zero. Tomando-se uma amostra limitada de dados, pode-se determinar a distribuição dos coeficientes de autocorrelação usando uma aproximação estatística. Os coeficientes de autocorrelação de uma amostra aleatória, conforme explicam Makridakis, Wheelwright e McGee (1983), possuem uma distribuição amostral que pode ser aproximada por uma curva normal com média zero e desvio-padrão igual a $1/\sqrt{n}$. Usando testes de hipótese, pode-se determinar se o coeficiente r_k é significativamente diferente de zero. A um nível de confiança de 95%, todos os coeficientes de autocorrelação da base amostral devem estar dentro de um

intervalo especificado. Isto é, a série de dados pode ser considerada puramente aleatória se os coeficientes de autocorrelação estão dentro do intervalo $-V_L \leq r_k \leq V_L$, onde $V_L = \frac{1,96}{\sqrt{n}}$. Esse teste de distribuição da amostra fornece indícios para distinguir o que é significativamente diferente de zero ou acaso. Logo, r_k será significativamente relevante caso $r_k \geq V_L$ ou $r_k \leq -V_L$.

2.1.4 Erros de previsão

Sabe-se que a demanda pode ser influenciada por diversos fatores, dentre eles, as condições macroeconômicas, como inflação e políticas fiscais do governo, e as questões operacionais, tais como a disponibilidade do produto no ponto-de-venda e o preço praticado ao consumidor (LUSTOSA et al., 2008). Todas essas variabilidades elevam as incertezas sobre a demanda e, por consequência, dificultam a sua previsão. Sobre esse fato, Silver; Pyke e Peterson (1998) afirmam que a única certeza que se pode ter sobre as previsões de demanda é que elas sempre apresentam alguma margem de erro.

A acurácia da previsão é um fator crucial para a escolha do modelo de previsão que melhor descreve a série de dados que se deseja prever. Os indicadores de erro são frequentemente usados nessas situações. Em muitos casos, a acurácia da previsão está relacionada ao quão bem o modelo consegue descrever os dados históricos (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998). Todavia, é a acurácia das previsões futuras a que mais interessa ao usuário do modelo de previsão.

O indicador básico de erro de previsão (e_t) é dado pela diferença (ou desvio) entre o valor real (Y_t) e o valor previsto (F_t).

$$e_t = Y_t - F_t \quad (15)$$

A Equação (15) define o erro de previsão no período t . Se existirem n períodos, então existirão n medidas de erro. A seguir, serão apresentadas algumas medidas estatísticas que levam essas parcelas de erro em consideração.

- *Erro médio (ME)*

O ME (*Mean Error*) é média dos erros dos n períodos dada pela Equação (16).

$$ME = \frac{1}{n} \sum_{t=1}^n e_t \quad (16)$$

O indicador ME tende a apresentar valores próximos de zero quando a série não possui viés ou erros sistemáticos. Outra forma mais prática é analisar graficamente o viés de previsão, por meio de um diagrama de resíduos. Se houver predominância de desvios positivos ou negativos, a previsão apresenta um viés.

- *Erro absoluto médio (MAE)*

No MAE (*Mean Absolute Error*) é a média dos desvios absolutos que é calculada.

$$MAE = \frac{1}{n} \sum_{t=1}^n |e_t| \quad (17)$$

Esse tipo de erro tem a vantagem de ser mais facilmente compreendido e resolve a questão do cancelamento dos termos positivos e negativos do ME. É um método ainda muito empregado, no entanto funciona melhor para erros normalmente distribuídos.

- *Erro quadrático médio (MSE)*

O MSE (*Mean Squared Error*) assemelha-se ao conceito de variância da Estatística ao elevar cada desvio ao quadrado. Ele apresenta a mesma ideia do MAE, porém ele eleva as variações de erro ao quadrado, evitando o cancelamento de termos positivos e negativos.

$$MSE = \frac{1}{n} \sum_{t=1}^n e_t^2 \quad (18)$$

Uma característica do MSE é que ele acaba fornecendo um peso maior aos desvios mais elevados e ao contrário no caso de desvios menores. Sua desvantagem é o fato de não ser expresso na mesma unidade dos dados observados.

Uma maneira alternativa de se comparar diferentes medidas de erro é trabalhar numa base percentual de medidas. Para tanto, pode-se expressar o erro percentual conforme a Equação (19).

$$PE_t = \left(\frac{Y_t - F_t}{Y_t} \right) \times 100 \quad (19)$$

Seguindo esse raciocínio, têm-se uma medida de erro frequentemente utilizada: *Mean Mean Absolute Percentage Error* (MAPE).

- *Erro percentual absoluto médio* (MAPE)

O MAPE considera os desvios percentuais absolutos dos erros como expresso na Equação (20).

$$MAPE = \frac{1}{n} \sum_{t=1}^n |PE_t| \quad (20)$$

Caso existam valores nulos observados na série, o uso dos métodos percentuais não é indicado, devido à divisão da equação por um termo nulo (Y_t). Da mesma forma, caso ocorram valores muito próximos de zero, a informação do erro perde sentido, pois a divisão por um elemento próximo de zero eleva consideravelmente o valor do indicador.

- *Erro absoluto médio ponderado* (WMAPE)

O *Weighted Mean Absolute Error* (WMAPE) é uma solução alternativa ao problema dos dados nulos ou próximos de zero do método MAPE. O WMAPE pode ser calculado como mostra a Equação (21).

$$WMAPE = \frac{\sum_{t=1}^n |Y_t - F_t|}{\sum_{t=1}^n Y_t} \quad (21)$$

Os métodos estatísticos apresentados para o cálculo do erro são, em geral, utilizados para medir o quão adequado é o ajuste do modelo de previsão aos dados históricos de demanda. Vale lembrar que apenas um bom ajuste aos dados históricos não garante, necessariamente, uma boa previsão. Poder-se-ia, por exemplo, obter valores nulos de MSE e MAPE ajustando os dados a polinômios de graus suficientemente elevados.

Uma alternativa proposta por Makridakis, Wheelwright e Hyndman (1998) para se contornar esse problema seria medir os valores dos erros utilizando-se dados reais da série histórica, porém que não foram utilizados durante a fase de ajuste. Essa técnica, chamada de *holdout*, consiste em dividir a série histórica em duas partes: um conjunto de dados para calibração do modelo e outro (*holdout set*) para a previsão. Dessa forma, os dados de calibração são utilizados para estimar os parâmetros e inicializar o modelo. A avaliação da acurácia de previsão do modelo é feita utilizando-se apenas os valores do conjunto de dados excluídos da fase de parametrização. Essa técnica permite que se obtenham valores de medição de erro genuínos, isto é, a comparação entre o real e o previsto leva em consideração dados históricos que não foram previamente utilizados no modelo. Reserva-se uma porcentagem p dos dados para parametrização do modelo de previsão e $(1-p)$ para testes, sendo $p > 0,5$. Usualmente, reservam-se pelo menos 2/3 dos dados para calibração do modelo.

2.1.5 Softwares de previsão de demanda

Conforme já comentado anteriormente, existem diversos *softwares* disponíveis no mercado com a finalidade de auxiliar nas previsões de demanda. Atualmente, existem *softwares* estatísticos que possuem módulos de previsão de demanda integrados. Alguns

exemplos são o Minitab®, SPSS® e SAS®. Há, também, *softwares* de previsão de demanda exclusivamente destinados a essa finalidade, tais como o Forecast Pro®, SmartForecasts® e Autobox 6.0®. *Softwares* estatísticos com módulos de demanda integrados possuem a vantagem de oferecerem uma gama maior de opções de uso, podendo ser usados para outras análises estatísticas e não apenas a previsão de demanda. Entretanto, *softwares* dedicados apenas à previsão de demanda possuem mais recursos e opções de análises de previsões, além de poderem gerar previsões mais automatizadas.

Muitos desses *softwares* de previsão de demanda podem ser integrados ao banco de dados da empresa, tornando ainda mais automatizadas as previsões. O sistema ERP da Empresa, o SAP®, possui um módulo chamado APO que também faz previsão. Todavia, seu uso substituído pelo *software* Neogrid®, que também está integrado ao SAP®.

Yurkiewicz (2010), em sua publicação para a revista *Operations Research and the Management Sciences Today*, revela que os usuários consideram a automatização um fator relevante na escolha do *software* de previsão de demanda. Eles são classificados como automático (o *software* escolhe o modelo que melhor se adequa aos dados históricos realizando testes automáticos), semiautomático (o usuário deve especificar o modelo que ele deseja que o *software* calcule) e manual (deve-se especificar o método e os parâmetros do modelo).

Outros fatores, como a variedade de modelos disponíveis, a compatibilidade do sistema operacional, a capacidade máxima de dados históricos que o *software* suporta, a compatibilidade com o Excel® (exportação e importação de dados), preço e suporte técnico, também são analisados na pesquisa.

No presente trabalho, foi utilizado o *software* Crystal Ball®, que funciona como um aplicativo do Excel®. Na realidade, o *software* utiliza a interface do Excel® para gerar todas suas análises. Esse fato, aliado à automatização das previsões, permite ao usuário escolher o tipo de erro que deve ser utilizado na escolha dos modelos (RMSE, MAD ou MAPE), foram importantes na escolha do *software*. Além disso, a Empresa já possuía esse recurso, o que foi muito conveniente, pois já era um *software* homologado pelo departamento de TI da Empresa. O *software* Neogrid® não foi utilizado, porque a Empresa não autorizou a autora o acesso a esse recurso.

O Crystal Ball® também disponibiliza a escolha de diferentes técnicas de previsão, como a de *holdout*, que foi utilizada neste trabalho. O *software* pode analisar várias séries de dados simultaneamente (até 10.000 séries históricas com 256 dados cada uma), permite

escolher o intervalo de confiança desejado para a previsão, fazer análises de autocorrelação, entre outras possibilidades.

Nesta seção, foram apresentadas apenas alguns principais modelos de previsão de demanda. O Crystal Ball®, contudo, possibilita a escolha automática do melhor método a partir de uma lista de diferentes modelos, a saber:

- ✓ Média móvel simples;
- ✓ Média móvel dupla;
- ✓ Suavização exponencial simples;
- ✓ Suavização exponencial com tendência (modelo de Holt);
- ✓ Suavização exponencial aditiva;
- ✓ Suavização exponencial multiplicativa;
- ✓ Suavização exponencial com tendência e sazonalidade (modelo de Holt-Winters);
- ✓ Suavização exponencial multiplicativa com tendência e sazonalidade.

A Figura 13 mostra a caixa de diálogo da galeria de métodos do Crystal Ball®.




Figura 13: Modelos de previsão disponíveis no Crystal Ball®

A próxima seção aborda da gestão de estoques e como a previsão de demanda pode auxiliar nessa questão.

2.2 Gestão do Estoque

Estoques são definidos como acumulações, em diversos pontos da cadeia de suprimentos, de matérias-primas, suprimentos, componentes, materiais em processo e produtos acabado que aguardam uso futuro (BALLOU, 2004). Sendo um importante ativo das empresas, é de fundamental importância que sejam bem gerenciados. O objetivo do gerenciamento de estoques é garantir que haja estoque suficiente para atender à demanda, ao mesmo tempo em que os custos a ele relacionados sejam os mais baixos possíveis. Ballou (2004) destaca que o custo de manutenção dos estoques pode representar de 20 a 40% de seu valor por ano.

Simchi-Levi; Kaminsky e Simchi-Levi (2003) apresentam alguns pontos sobre a relevância da manutenção de estoques nas empresas:

- Proteger a empresa contra alterações não previstas e flutuações na demanda do cliente.
- Reduzir os impactos das incertezas no fornecimento dos suprimentos, tanto com relação à quantidade e qualidade, quanto aos custos e prazos de entrega.
- Aproveitar as economias de escalas oferecidas pelas empresas de transporte que encorajam a entrega de produtos em grandes quantidades.

Todavia, com a intensa competitividade no mundo dos negócios e a crescente diversificação dos mercados consumidores, as empresas não se podem dar mais ao luxo de possuírem “generosos” estoques de produtos. O frequente lançamento de novas mercadorias, levando à obsolescência mais rápida dos produtos, e o interesse de se oferecer produtos com custos cada vez mais reduzidos, levam as empresas a buscarem a máxima eficiência no gerenciamento de seus estoques.

2.2.1 Gerenciamento de estoques na cadeia de suprimentos

Segundo Simchi-Levi; Kaminsky e Simchi-Levi (2003), um dos maiores desafios da cadeia de suprimentos é equilibrar o suprimento e a demanda adequadamente. O gerenciamento de estoques é uma tarefa que requer especial atenção, pois, além de impactar nos custos da cadeia, exerce significativa influência no nível de serviço ao cliente. Por nível de serviço entende-se a habilidade de atender ao pedido do cliente na data de entrega estabelecida, ou até mesmo antes. Vários fatores podem influenciar a entrega do pedido no prazo adequado, tais como o sistema logístico de distribuição utilizado, a capacidade de produção para atender à demanda, a disponibilidade do produto no estoque, entre outros (SIMCHI-LEVI; KAMINSKY; SIMCHI-LEVI, 2003).

O simples fato de prever a demanda, entretanto, não é suficiente para a determinação do nível mais adequado de estoque. É preciso levar também em consideração a variabilidade à qual essa demanda está sujeita. Sobre a propagação das incertezas da demanda na cadeia de suprimentos, Lustosa et al. (2008) destacam o fenômeno chamado Efeito Chicote. Ao observarem mudanças nos pedidos dos varejistas (clientes), os distribuidores também modificarão seus pedidos juntos aos fabricantes (fornecedores). Esses, por sua vez, alterarão seus pedidos junto aos fornecedores de matérias-primas, conforme a variação percebida. Dessa forma, esse comportamento se propaga ao longo de toda a cadeia. Devido a fatores como a política de compras em grandes lotes para se ganhar em escala no transporte e na produção e a falta de um real acompanhamento da demanda do consumidor final, a tendência é de que as variações da demanda a montante da cadeia sejam percebidas mais acentuadamente (LUSTOSA et al., 2008). Os resultados desse efeito elevam a complexidade da gestão da cadeia de suprimentos, especialmente no que tange à reposição de estoques.

2.2.2 Custos dos estoques

Os custos relacionados aos estoques podem ser agrupados em três principais categorias (RUSSELL; TAYLOR, 2006):

- **Custos de armazenagem** – são custos relacionados à posse do estoque. Eles variam de acordo com a quantidade de itens estocados e com o período de tempo de armazenagem. Normalmente, esses custos que aumentam linearmente com o número de unidades em estoque são classificados como de armazenagem. Estima-se que o custo de armazenagem anual representa de 10 a 40% do custo de um item manufaturado.
- **Custos de pedidos** – são associados ao custo de reabastecimento do estoque e são fixos por pedido, não variando com o tamanho do lote. As despesas embutidas nesse tipo de custo estão relacionadas à inspeção, manuseio, transporte, auditoria, etc. Esses custos aumentam com o número de pedidos feitos.
- **Custos de faltas** – esse custo refere-se às situações em que a demanda não pode ser atendida devido à falta de produto em estoque. O custo de falta pode levar à insatisfação do cliente, resultando uma imagem ruim para a empresa. Em alguns casos, essa incapacidade de atender à demanda pode implicar no pagamento de multa ao cliente. Esse tipo de custo é mais difícil de ser medido. Ao contrário do custo de armazenagem, o custo por falta é reduzido aumentando a disponibilidade de produtos no estoque.

Vale ressaltar que o custo total da operação do estoque está relacionado à interação entre esses três tipos de custos. De maneira simplificada, o custo de pedido tende a elevar o tamanho do lote (para reduzir a frequência de pedidos) e o custo de armazenagem busca reduzir esse tamanho (para diminuir o volume de estoque médio). Busca-se o equilíbrio dos custos tentando balancear a frequência dos pedidos e a quantidade pedida. Os custos de faltas aumentam a complexidade na definição desse equilíbrio, entretanto, Lustosa et al. (2008) explicam que o problema se baseia principalmente em determinar o momento e a quantidade a repor.

Um modelo clássico que ilustra os *trade-offs* entre os custos de pedir e armazenar é o Modelo do Lote Econômico. O cálculo do lote econômico baseia-se na minimização dos custos totais de operação. As premissas do modelo são:

- ✓ Demanda constante;
- ✓ Único item;
- ✓ Quantidades do pedido são fixas (Q itens por pedido);

- ✓ Custos lineares (custo de estocagem é proporcional à quantidade de itens estocados e o custo de pedido é fixo por pedido);
- ✓ Capacidade de suprimento ilimitada;

O interesse deste trabalho não é a demonstração da formulação matemática em si, mas apresentar a ideia geral do modelo. A Equação (22) apresenta expressão matemática da Quantidade do Lote Econômico (QLE).

$$QLE = \sqrt{\frac{2 \times D \times c_P}{c_A}} \quad (22)$$

Onde: D – demanda

c_P – custo de pedido

c_A – custo de armazenagem

O modelo do lote econômico possui como premissas a demanda constante e o *lead time* nulo, o que raramente acontece na prática. O modelo ignora variações e incertezas na demanda, fato ainda mais acentuado com a existência do Efeito Chicote. Sendo assim, modelos que permitem um ajuste no nível do estoque diante de uma demanda variável e *lead times* não nulos foram desenvolvidos e serão tratados nas próximas seções. A Figura 14 ilustra a curva do custo total em função dos custos de pedido e de armazenagem.




Figura 14: Curvas para determinação do lote econômico
 Fonte: Adaptado de Lustosa et al. (2008)

2.2.3 Modelos de reposição de estoque

Segundo Lustosa et al. (2008), quando se considera a gestão de estoques, os diferentes modelos de reposição de estoques se baseiam em três principais aspectos: o que repor (quais itens), quando acionar a reposição (através de ordens de reposição ou aquisição) e quanto repor (quantidade de itens necessários para estabelecer o nível de estoque desejado).

Para se determinar qual o melhor modelo de reposição de estoques a ser utilizado é preciso, primeiramente, conhecer o padrão de demanda existente. Nesse sentido, saber se a demanda de determinado item está associada à de outro (demanda dependente, vista na seção anterior) é o primeiro passo. Caso os itens possuam demanda independente, que é o caso dos produtos da Empresa analisada, eles podem ter seus estoques modelados de duas formas: com o uso de previsão de demanda (modelos ativos) ou sem previsão de demanda (modelos reativos).

Modelos reativos

Modelos desse tipo recebem esse nome, porque reagem ao comportamento da demanda e não se antecipam a ela. Sendo assim, são mais indicados para demandas estacionárias, que não variam muito ao longo do tempo. Esses modelos se baseiam no nível de estoque no momento do pedido de reposição e em outros parâmetros característicos de

cada modelo. Dentro dessa classe, os modelos reativos podem ser de dois tipos: de revisão periódica e de revisão contínua (RUSSELL; TAYLOR, 2006).

➤ Revisão periódica

Os modelos de revisão periódica baseiam-se no reabastecimento do estoque em intervalos de tempo regulares. O nível do estoque é revisto a cada intervalo de revisão (R) e a quantidade de abastecimento, normalmente, corresponde àquela que reestabelecerá o estoque ao nível máximo desejado (S). Esse nível é um parâmetro do modelo determinado a partir da demanda esperada durante o intervalo entre reposições, acrescida de uma margem de segurança contra eventuais incertezas sobre a demanda.

Um exemplo de modelo de reposição periódica é o da Reposição do Máximo (RUSSELL; TAYLOR, 2006). Esse modelo trabalha com dois parâmetros: período de revisão (R) e estoque máximo (S). Nesse caso, fixando-se os intervalos de revisão, se a demanda for variável, o tamanho dos lotes também será variável.

Sendo X o nível de estoque do item no momento do lançamento do pedido de reposição, a quantidade a ser pedida (Q) será a diferença entre S e X .

Na prática, o valor de R é arredondado para um número inteiro de períodos, tentando-se agrupar produtos de mesmos fornecedores para um mesmo período de revisão. Lustosa et al. (2008) propõem o arredondamento dos valores de R na forma de 2^k períodos, onde k é um número inteiro, o que facilita o agrupamento de diferentes pedidos para reposição.

A Figura 15 ilustra o nível de estoque ao longo do tempo quando esse tipo de modelo é implementado. O *lead time* é representado pela variável L .




Figura 15: Nível do estoque num sistema de reposição do máximo

Fonte: Adaptado de Lustosa et al. (2008)

Considerando uma demanda variável, o parâmetro S é calculado através da demanda média durante o período de revisão (R) mais o *lead time* (L). Esse seria, portanto, o estoque que seria consumido entre o momento que o pedido é feito até a chegada dos itens. Pode-se acrescentar, ainda, um estoque de segurança associado ao nível de serviço que se deseja manter. Admitindo-se o *lead time* constante e as demandas diárias variáveis normais e independentes, o cálculo final seria, então, dado pela Equação (23).

$$S = (L + R) \times \bar{d} + z\sigma_d\sqrt{(L + R)} \quad (23)$$

Onde: $\bar{d}$ – taxa de demanda média diária

σ_d – desvio-padrão da demanda

L – *lead time* em dias

R – período de revisão em dias

z – constante baseada no nível de serviço e associada à distribuição normal de probabilidade da demanda. Para um nível de serviço de 95%, z é igual a 1,65.

De maneira semelhante, os cálculos podem ser feitos considerando-se outros períodos, como semanas, meses, etc., dependendo do período de reposição com que se deseja trabalhar. Essa mesma premissa valerá para os cálculos que seguem.

Uma vantagem desse método é poder agrupar itens em grupos que terão o mesmo intervalo de revisão. Por exemplo, se existe um grupo de produtos comprados sempre de um mesmo fornecedor, poder-se-ia agendar a revisão desses níveis de estoque para um mesmo dia da semana, reduzindo custos de frete e operações. Contudo, a desvantagem é que, como existe um menor controle entre os períodos de revisão, são maiores as chances de ocorrer desabastecimentos do estoque entre os intervalos de revisão.

➤ Revisão contínua

Nesse caso, o monitoramento do nível do estoque é constante. Sempre que o nível de estoque atinge um nível mínimo pré-estabelecido, chamado de ponto de pedido ou de

reposição (s), uma ordem de reposição é feita. Essa quantidade mínima deve ser suficiente para atender à demanda durante o tempo de entrega do pedido (*lead time*). A quantidade pedida corresponde a um valor fixo. O método de revisão contínua baseia-se, portanto, em intervalos variáveis de revisão (sendo a demanda, em geral, variável) e em quantidades fixas de pedido. Essa quantidade fixa do lote é calculada de forma a minimizar o custo total do estoque, buscando um equilíbrio entre os custos de pedido e de estocagem, conforme o modelo do Lote Econômico explicado anteriormente.

Como esse método exige um monitoramento contínuo dos níveis dos estoques, é possível saber o status do estoque em qualquer período. A maior vantagem de métodos de revisão contínua é que eles exigem um menor estoque de segurança para garantir o mesmo nível de serviço dos modelos de revisão periódica (SILVER; PYKE; PETERSON, 1998).

Um modelo clássico de reposição contínua é o de Reposição por Ponto de Pedido (RPP), conforme será visto a seguir. Nesse modelo, o ponto de pedido (s) é calculado em função da demanda que pode ocorrer entre o lançamento do pedido e a chegada do lote. A Figura 16 mostra essa relação.




Figura 16: Nível do estoque num sistema de reposição por ponto de pedido

Fonte: Adaptado de Lustosa et al. (2008)

Admitindo-se o *lead time* constante e as demandas diárias variáveis normais e independentes, o cálculo do ponto de pedido pode ser feito conforme a Equação (24):

$$s = L \times \bar{d} + z\sigma_d\sqrt{L} \quad (24)$$

Onde: $\bar{d}$ – taxa de demanda média diária

σ_d – desvio-padrão da demanda

L – *lead time* em dias

z – constante baseada no nível de serviço e associada à distribuição normal de probabilidade da demanda. Para um nível de serviço de 95%, z é igual a 1,65.

Em muitos casos, supor o *lead time* fixo nem sempre corresponde à realidade. Assumindo-se que o *lead time* também seja normalmente distribuído, o ponto de pedido pode ser calculado segundo a Equação (25) (SIMCHI-LEVI; KAMINSKY; SIMCHI-LEVI, 2003).

$$s = \bar{L} \times \bar{d} + z \sqrt{\sigma_d^2 \times \bar{L} + \sigma_L^2 \times \bar{d}^2} \quad (25)$$

Onde: $\bar{L}$ – *lead time* médio

σ_L – desvio-padrão do *lead time*

Modelos baseados em previsão de demanda

Ao contrário dos modelos reativos, são modelos mais indicados quando a demanda apresenta sazonalidades ou tendência. Por meio da previsão de demanda, esses modelos conseguem antecipar variações no volume de itens necessário para repor o estoque. Diferentemente dos modelos reativos, que reagem à demanda, os modelos ativos tentam se antecipar a ela. Nesse caso, a previsão de demanda é utilizada para se calcular o tamanho dos lotes de reposição, de maneira a atender uma necessidade futura.

A previsão da demanda para a definição dos tamanhos dos lotes de reposição é melhor aplicada em um modelo de revisão periódica. Com o auxílio dos modelos de previsão vistos anteriormente, é possível definir o tamanho do lote de reposição, que é a necessidade líquida para o próximo período. Essa necessidade líquida ($NL_{\text{líq}}$) é calculada em função (NB_{bruta}), que é a demanda prevista até a próxima atualização do estoque ($R + L$) acrescida de um estoque de

segurança (EstSeg), menos o estoque disponível no momento da revisão (EstAtual). As Equações (26) e (27) mostram esse racional.

$$NBruta = \text{Previsão de Demanda } (R + L) + \text{EstSeg} \quad (26)$$

$$NLiq = NBruta - \text{EstAtual} \quad (27)$$

Onde R é o tamanho do período de revisão e L , o *lead time* de abastecimento. O estoque de segurança deve ser calculado de tal forma que possa cobrir os erros de previsão durante o tempo de espera. Dessa maneira, para previsões com baixos erros, o estoque de segurança também será menor.

Para o cálculo do estoque de segurança, Silver; Pyke e Peterson (1998) propõem a Equação (28).

$$\text{EstSeg} = k \times \sigma_{R+L} \quad (28)$$

Onde: k – fator de segurança (no caso de uma distribuição normal dos erros de previsão, é a própria constante z anteriormente apresentada)

σ_{R+L} – desvio-padrão dos erros de previsão durante o período $(R + L)$

Antes de se calcular σ_{R+L} , é preciso encontrar o desvio-padrão dos erros de previsão para uma unidade de período, $\hat{\sigma}_1$, que pode ser feito a partir do MSE da amostra de dados, conforme a Equação (29).

$$\hat{\sigma}_1 = \sqrt{MSE} \quad (29)$$

Em teoria, a Equação (12) poderia ser usada para atualizar a estimativa do MSE cada vez que um novo período de informação fosse incluído na amostra. Entretanto, Silver; Pyke e Peterson (1998) apresentam uma alternativa mais simples, utilizando uma suavização exponencial simples, segundo a Equação (30).

$$MSE_t = w(Y_t - F_t)^2 + (1 - w)MSE_{t-1} \quad (30)$$

Onde: MSE_t – estimativa do MSE ao final do período t .

w – constante de suavização, normalmente contida entre 0,01 e 0,1.

A principal vantagem de utilizar a Equação (26) é que os erros mais recentes recebem um peso maior ao longo do tempo, ao contrário do MSE que atribui pesos iguais para todos os períodos. A inicialização do MSE pode ser feita adotando-se como estimativa o MSE_0 , que é o MSE obtido durante a fase de calibração do modelo de previsão.

Finalmente, σ_{R+L} pode ser estimado por $\hat{\sigma}_{R+L}$, a partir de $\hat{\sigma}_1$, através da relação dada pela Equação (31) (SILVER; PYKE; PETERSON, 1998).

$$\hat{\sigma}_{R+L} = \hat{\sigma}_1 \times \sqrt{R+L} \quad (31)$$

Silver; Pyke e Peterson (1998) sugerem que o usuário deve ter a opção de ajustar manualmente o fator de segurança k , a fim de refletir fatores não captados pelo sistema de previsão.

3 DELIMITAÇÃO DO ESTUDO

Para dar sequência ao estudo sobre o sistema de reserva de inventário, descrito no capítulo 1, foram selecionados alguns SKUs. Neste capítulo, são descritos os critérios de seleção dos SKUs e do CD que serão analisados neste trabalho.

3.1 Escolha do CD

Como mencionado anteriormente, a Empresa possui três centros de distribuição de onde partem os produtos destinados a seus clientes. Não existem transferências entre esses CDs, isto é, entre eles, não há envio ou recebimento de produtos. É sabido, também, que o sistema de reserva de inventário é válido para todos eles.

Para este estudo, decidiu-se restringir a análise para um CD apenas. No entanto, a mesma metodologia poderá ser aplicada para o estudo dos outros dois. O CD escolhido foi o de SP, pois é o primeiro em termos de volume de produtos atualmente distribuídos. Representando aproximadamente 40% dos produtos enviados aos clientes, o CD de SP é o maior centro de distribuição da Empresa na América Latina. Todavia, por ter sido inaugurado somente no início de 2009, apresenta uma quantidade mais limitada de dados disponíveis para análise. A escolha do CD de MG, por exemplo, não melhoraria muito essa questão da disponibilidade dos dados. Com a entrada do CD de SP, o volume da demanda do CD de MG sofreu significativa redução a partir de abril de 2009. O CD de SP incorporou boa parte das distribuições feitas pelo CD de MG. O estudo do CD da PB não seria muito representativo, pois ele tem baixa participação no atendimento do grupo dos KA, que se concentram mais fortemente na região Sudeste. Sendo assim, os dados de vendas analisados são para o CD de SP e datam a partir de abril de 2009. A Figura 17 ilustra o impacto da entrada do CD de SP sobre o volume de faturamento do CD de MG.




Figura 17: Distribuição das vendas com a abertura do CD de SP

Vale lembrar que cada CD é responsável por abastecer um determinado número de clientes e não existe transferências entre os CDs, isto é, caso falte produtos em um centro de distribuição, ele não pode receber produtos de outro CD e um cliente é sempre abastecido pelo mesmo CD.

3.2 Amostra dos SKUs

Dado o amplo portfólio de produtos, decidiu-se por, inicialmente, limitar o estudo a apenas alguns SKUs. É claro que, uma vez validada a metodologia, o método poderá ser estendido aos demais. Como descrito anteriormente, a lista de SKUs que compõem a reserva de inventário do grupo I abrange 180 itens. Para reduzir o esforço operacional da coleta dos dados num primeiro momento, tarefa que será descrita na próxima seção, optou-se por escolher apenas 6 SKUs, pertencentes à diferentes famílias. A escolha desses SKUs foi feita com base na representatividade de vendas desses itens em termos de *sell-in* para os clientes KA. Por motivos de confidencialidade, seus nomes não serão revelados. A Tabela 2 apresenta um resumo das principais características dos SKUs escolhidos.

Tabela 2: Caracterização da amostra de SKUs

Código SKU	Família	GBU
A	Shampoo	Baby
B	Absorvente interno	CHC
C	Escova dental	CHC
D	Sabonete	Baby
E	Absorvente externo	CHC
F	Enxaguatório bucal	CHC

3.3 Propósito do estudo

Conforme apresentado no capítulo 1, este trabalho tem como objetivo auxiliar na definição de propostas de melhorias para a reposição dos estoques dos produtos em reserva. A partir do levantamento bibliográfico feito no capítulo 2, a hipótese que mais chama a atenção é a de que um sistema que incorpora a previsão de demanda para a realização das reposições possa gerar melhores resultados, conforme apresentado na teoria.

Sendo assim, o capítulo 4 será dedicado aos estudos de aplicações de métodos de previsão de demanda. Ele fornecerá subsídios que possibilitarão entender melhor o comportamento da demanda para os SKUs escolhidos. Além disso, servirá de embasamento para o capítulo 5, gerando resultados que serão aplicados no modelo de reposição de estoque baseado em demanda.

4 ANÁLISE DA PREVISÃO DE DEMANDA

Após a definição da abrangência do estudo, segue-se a fase de análise do comportamento das vendas dos SKUs escolhidos. Neste capítulo, serão discutidos os resultados de previsão de demanda gerados pelo software Crystal Ball® em diferentes tipos de testes. Os próximos subcapítulos correspondem às etapas do processo de previsão de demanda propostas por Makridakis, Wheelwright e Hyndman (1998) e explicadas no capítulo 2. Todavia, essas etapas também estão em concordância com o processo proposto por Russell e Taylor (2006) e que será abordado ao longo deste capítulo como ilustra a Figura 18.




Figura 18: Etapas do processo de previsão de demanda aplicadas no trabalho

Fonte: Adaptado de Russell e Taylor (2006).

4.1 Propósito da previsão

A previsão de demanda dos SKUs que fazem parte da reserva de inventário servirá para auxiliar na reposição dos estoques da reserva. Conforme explicado no capítulo 1, o nível da reserva é definido pela quantidade equivalente a duas semanas do alvo mensal de vendas, conforme dado pela Equação (1). Nos meses que possuem quatro semanas, essa quantidade equivale, conseqüentemente, a 50% do alvo.

Espera-se que a previsão ajude a reduzir os níveis elevados de estoque observados, ao mesmo tempo em que o nível de serviço seja considerado adequado aos interesses da Empresa, que deseja fornecer aos seus clientes KA um nível de serviço mínimo de 95%.

É fundamental que o processo de previsão de demanda seja relativamente simples e rápido de ser executado. Os resultados desta previsão servirão de suporte ao modelo de reposição de estoque que será proposto no capítulo seguinte. Dessa forma, o usuário do sistema deverá lidar com um grande volume de informações, não possuindo muito tempo para avaliar caso a caso. Portanto, é importante que o processo seja o mais simples e automatizado possível.

4.2 Coleta de dados

No capítulo 3, foram definidos os SKUs e o CD que serão analisados neste estudo, o próximo passo é extração dos dados. A Empresa utiliza o software de sistemas integrados de gestão empresarial SAP®, cujo módulo denominado Business Warehouse (BW) é o mais utilizado na área de vendas. Ela apresenta uma interface mais amigável para gerar relatórios e fazer seleções personalizadas.

Os dados de vendas mais comuns na empresa são de dois tipos: pedidos “entrados” e pedidos faturados. Pedido “entrado” é toda a venda (*sell-in*) feita durante o mês corrente, não importando se o pedido poderá ser faturado ou não. Os motivos que podem impedir o faturamento do pedido são: falta de produto em estoque, ausência de crédito para o cliente, pedidos pré-datados, entre outros. O faturamento do pedido ocorre depois de verificada a disponibilidade em estoque dos produtos e a autorização de crédito. Depois disso, o pedido é faturado e está pronto para ser enviado ao cliente. Tanto os pedidos “entrados”, quanto os

faturados podem ser medidos em unidade financeira (R\$) e unidades físicas (caixas, litros, quilos, etc). Para os SKUs escolhidos, a unidade em caixas foi escolhida para neutralizar a influência de efeitos como as variações de preços por cliente e outros ajustes contábeis da empresa. Além disso, é uma medida mais fácil de ser interpretada do que litros ou quilos, por exemplo, e é essa a medida mais comumente empregada na gestão dos estoques da Empresa.

Para realizar os cálculos de previsão de demanda, a empresa utiliza o histórico dos pedidos faturados e não o de pedidos “entrados”. Isso ocorre porque dentro dos pedidos “entrados” estão sendo considerados pedidos bloqueados, sem crédito, etc., que, em certos casos, são repetidamente lançados no sistema até serem faturados (o cliente pode fazer um pedido e, caso não haja produto, ele é cancelado, mais tarde esse mesmo cliente pode tentar emitir outro, até que seja faturado). Esse fato acaba elevando o número de pedidos para uma quantidade acima da realmente necessária.

Por outro lado, utilizar as quantidades que foram faturadas para fazer uma previsão de demanda, também não é a situação ideal. Dos pedidos faturados, são excluídas todas as faltas de produtos (*BO*), por exemplo. Os pedidos faturados, portanto, refletem mais a capacidade da empresa em atender os pedidos do que a vontade de compra dos clientes. O ideal, contudo, seria somar aos pedidos faturados, toda aquela quantidade correspondente ao cancelamento de pedidos por falta de produto.

Para os estudos sobre o comportamento das vendas, que serão discutidos na seção seguinte, partiu-se da carteira de pedidos diários, para, em seguida, agregá-los em semanas e meses, conforme a necessidade das análises. Cabe enfatizar, todavia, a dificuldade encontrada na extração dos dados. Como explicado no capítulo 1, a previsão de demanda da empresa é feita utilizando-se dados mensais. No sistema BW, os dados de vendas estão disponíveis apenas mensalmente. No SAP, contudo, é possível obter-se um detalhamento pedido a pedido.

É importante lembrar que a extração dos dados no SAP elevou muito o tempo da fase de coleta. No SAP, as vendas em nível de SKU são apresentadas pedido a pedido por cliente, fato que eleva consideravelmente o tempo de extração. Cada pedido possui a descrição de data, cliente, código, quantidade faturada, etc.

A Empresa deveria considerar a possibilidade de disponibilizar dados semanais (ou até mesmo diários) no BW a fim de contribuir para uma extração mais rápida e prática dessa informação.

4.3 Análise preliminar

Antes de dar prosseguimento à etapa de verificação dos dados, é preciso ressaltar que os dados analisados correspondem ao histórico de vendas (*sell-in*) da Empresa, mais precisamente, aos pedidos faturados. Será discutida, mais adiante, a relação desse fato nas análises sobre a demanda.

Para efeito de esclarecimento, as datas correspondem aos dias (semanas, meses, etc.) de entrada dos pedidos, mas as quantidades representam apenas o que pode ser efetivamente faturado dos pedidos. O faturamento pode demorar alguns dias para ocorrer, devido aos procedimentos internos de cada CD (cada CD possui dias da semana específicos para faturar pedidos de clientes de regiões diferentes). Mas para efeito de previsão, a data de entrada corresponde ao momento de colocação do pedido de compra do cliente. Será considerado, portanto, que o pedido “entrado” pode ser faturado no mesmo dia (como se o cliente pudesse levar na mesma hora o seu pedido).

4.3.1 Inspeção gráfica e ajuste dos dados

A análise dos dados começa, portanto, com uma inspeção gráfica de todo o histórico de dados disponível, um horizonte de tempo que vai do dia 01/04/2009 ao 31/07/2010. Essa visualização inicial permitirá a identificação de *outliers* e alguns padrões no comportamento da demanda. As Figura 19 e Figura 20 mostram a distribuição diária de vendas para os SKUs C e E.




Figura 19: Análise diária de vendas para o SKU C




Figura 20: Análise diária de vendas para o SKU E

Observando-se os gráficos, percebe-se uma grande oscilação na quantidade de vendas diária. Destacam-se alguns picos de vendas muito acentuados, como no caso do SKU C, que apresenta em um único dia vendas que ultrapassam largamente os outros picos de vendas. Isso

pode ser consequência de promoções, descontos aos clientes, ou, até mesmo, decorrência de uma negociação que o vendedor fez para bater sua meta de vendas, compensando, possivelmente, a venda ruim de outros SKUs. Essa última hipótese ganha ainda mais força quando se verifica que esse volume foi destinado a apenas um único cliente no último dia da semana de fechamento do mês. Nesses casos, a venda será substituída pela média dos últimos 30 dias. Cabe frisar, contudo, o efeito desses picos, principalmente, sobre as vendas dos dias imediatamente subsequentes, já que, após essa forte colocação de vendas, os clientes ficam estocados e não compram até terem seus estoques novamente reduzidos. Infelizmente, é difícil medir o impacto dessa ação sobre os volumes de vendas posteriores e, como a reserva de inventário trabalha com quase duas centenas de SKUs, isso seria inviável na prática.

Nota-se, também, dias com faturamento zero. É preciso, contudo, fazer duas ressalvas. Nos dias que vão de 24/12/2009 ao dia 03/01/2010, não ocorreram vendas devido ao recesso de final de ano. Na semana correspondente aos dias 29/06/2009 ao dia 05/07/2009, a organização passou por um processo de reestruturação nacional de sua estrutura de vendas, não existindo, portanto, ocorrências para esses dias.

Os demais dias com faturamento nulo podem ter ocorrido por duas razões: ausência efetiva de venda ou cancelamento de pedido (falta de crédito do cliente no momento do faturamento, desistência da compra, cancelamento da compra por impossibilidade de faturamento imediato do pedido, já que alguns clientes não admitem faturamento parcial, ou a falta total do produto em estoque). O ideal seria poder corrigir os dados, limitando a influência da falta de produto na demanda. Infelizmente, no sistema da Empresa, não é possível distinguir o que realmente foi cancelado por falta de produto para fazer uma correção dos dados. Além disso, como já mencionado, há outro problema referente à falta de produto. O cliente que não aceita receber os produtos parcialmente, cancela o pedido total em caso de BO. Entretanto, ele pode refazer esse pedido posteriormente, mas não é possível saber se essa nova solicitação se deve a uma tentativa anterior de compra sem sucesso ou, de fato, a uma nova demanda sem relação direta com o BO. Devido a essas limitações, nenhum tratamento quanto à falta de produto poderá ser feito. Vale destacar, contudo, que sugestões internas à Empresa estão sendo feitas para mitigar esse problema e espera-se, num futuro próximo, poder identificar quais cancelamentos por BO ocorreram devido à falta de produto e quais foram apenas um relançamento de pedido do sistema.

Como o presente trabalho tem interesse maior no comportamento semanal das vendas, os dados diários serão agrupados por semana. Nesse caso, é mais difícil ocorrer alguma

semana com venda nula (mesmo sendo a última semana do ano, ainda ocorrem vendas dias antes do recesso). Caso haja alguma semana com venda nula, será tomada a média das últimas três semanas correspondentes ao número daquela semana no mês. A divisão das semanas nos meses (1ª, 2ª, 3ª, 4ª ou 5ª semana no mês) será explicada mais adiante. Escolher semanas de mesmo número na posição no mês é importante para considerar os efeitos de sazonalidade semanal dentro dos meses, fato que também será abordado a seguir.

4.3.2 Análises de autocorrelação

Observando-se a distribuição diária de vendas, pode-se suspeitar da existência de uma sazonalidade semanal, já que em alguns dias a concentração de vendas é maior que em outros.

Visto que os dias da semana não possuem concentração uniforme de vendas, é preciso entender se esse fato está relacionado, também, à semana do mês. Para tanto, adotou-se o calendário que a Empresa utiliza para definir quando um mês terá quatro ou cinco semanas. Todas as primeiras semanas começam na segunda-feira. Dessa forma, podem existir meses, cuja primeira semana se inicia com os últimos dias do mês anterior, e meses, cuja última semana abrange também os primeiros dias do próximo mês. Poucas vezes, as primeiras semanas do mês que começam no dia 1º. A Figura 21 ilustra o exemplo do mês de

	S	T	Q	Q	S	S	D
JAN	4	5	6	7	8	9	10
(4 semanas)	11	12	13	14	15	16	17
	18	19	20	21	22	23	24
	25	26	27	28	29	30	31

Figura 21: Exemplo de repartição das semanas no mês

A Tabela 3 resume essa classificação da quantidade de semanas nos meses segundo o calendário da Empresa.

Tabela 3: Definição do número de semanas nos meses

Meses	Número de semanas no mês
Janeiro, Fevereiro, Abril, Maio, Julho, Agosto, Outubro, Novembro	4
Março, Junho, Setembro e Dezembro	5

Para uma melhor visualização da concentração de vendas nas diferentes semanas do mês, os dias foram agrupados em semanas, conforme o critério anteriormente explicado. As Figuras 22 e 23 mostram a distribuição semanal para os SKUs C e E.




Figura 22: Histórico de vendas semanais para o SKU C




Figura 23: Histórico de vendas semanais para o SKU E

Observa-se, portanto, uma forte concentração das vendas principalmente nas últimas semanas dos meses, comprovando a afirmação feita no capítulo 1 sobre a política de vendas da Empresa. A fim de tornar mais clara a presença dessa sazonalidade semanal, as Tabela 4 e Tabela 5 mostram a representatividade média das semanas, em termos de vendas, dentro dos

meses com quatro e cinco semanas, tomando-se como exemplo o SKU C. Os resultados para os demais SKUs encontram-se no Anexo deste trabalho.

Tabela 4: Concentração média de vendas nas semanas para o SKU C (meses com quatro semanas)

<i>Núm. da semana</i>	<i>Dias da semana</i>							<i>Representatividade da sem. para o mês</i>
	<i>dom</i>	<i>seg</i>	<i>ter</i>	<i>qua</i>	<i>qui</i>	<i>sex</i>	<i>sáb</i>	
1a sem	0%	2%	1%	1%	5%	1%	1%	12%
2a sem	0%	5%	3%	4%	7%	4%	1%	24%
3a sem	0%	2%	4%	10%	5%	5%	0%	27%
4a sem	0%	3%	9%	3%	9%	12%	0%	37%

Tabela 5: Concentração média de vendas nas semanas para o SKU C (meses com cinco semanas)

<i>Núm. da semana</i>	<i>Dias da semana</i>							<i>Representatividade da sem. para o mês</i>
	<i>dom</i>	<i>seg</i>	<i>ter</i>	<i>qua</i>	<i>qui</i>	<i>sex</i>	<i>sáb</i>	
1a sem	0%	0%	3%	0%	3%	6%	0%	13%
2a sem	0%	5%	2%	0%	4%	3%	1%	15%
3a sem	0%	4%	3%	3%	7%	0%	0%	17%
4a sem	0%	3%	2%	3%	15%	6%	0%	29%
5a sem	0%	4%	3%	3%	2%	6%	8%	26%

Analisando-se os dados das tabelas, tanto nos meses com quatro, quanto com cinco semanas, a concentração de vendas é mais forte na quarta semana, especialmente nos últimos dias da semana. A quinta semana aparece em seguida em termos de representatividade de vendas. Esse comportamento também foi confirmado nos demais SKUs. Tal fato está fortemente relacionado à política de vendas da empresa, conforme explicado no capítulo 1. Como este estudo trata das vendas do tipo *sell-in* é importante frisar que esse não reflete o real comportamento da demanda do consumidor final, mas, sim, a política de compras e negociações que acontecem junto aos clientes KA.

É relevante destacar, também, que o objetivo destas análises é entender o comportamento das vendas, para, em seguida, propor de melhorias para o sistema de reserva de inventário da Empresa. Dessa forma, será mais relevante entender, não a evolução diária das vendas, mas, sim, o seu comportamento semanal e mensal, já que é em um nível mais agregado de tempo que será feita a proposição de solução para a reposição da reserva.

A sazonalidade das semanas pode ser confirmada pelo diagrama de autocorrelação, como apresentado no capítulo 2. Entretanto, como existem meses com quatro ou com cinco semanas, é mais difícil realizar uma análise da sazonalidade semanal dentro do mês. Para evitar distorções desse tipo, para o mês com cinco semanas, foram somadas a quarta e a quinta semanas, transformando todos os meses em meses de quatro semanas. Esse tratamento é válido, pois o objetivo final da análise de autocorrelação que será realizada é comprovar se existe ou não sazonalidade semanal dentro do mês. Como visto nas tabelas anteriores, nos meses com cinco semanas, a quarta e a quinta semanas dos meses possuem representatividades mais ou menos parecidas (podendo, até mesmo, a quarta semana ser mais representativa que a quinta). Dessa forma, a soma das duas semanas ajuda a reforçar a ideia da última semana do mês como o período de maior concentração de vendas. Para efeito de previsão para a reposição do estoque, esta consideração continua sendo válida, conforme será explicado no capítulo 5.

Os testes de autocorrelação podem ser realizados no Excel® ou com a ajuda do próprio Crystal Ball®, que permite análises de autocorrelação para a determinação dos períodos de sazonalidade. No caso do Crystal Ball®, a cor verde-escura no gráfico de barras indica que o valor do coeficiente de autocorrelação atende ao critério $|r_k| > V_L$. Nesse caso, k representa o número de defasagens entre as semanas para se testar uma possível sazonalidade. Se, por exemplo, para $k = 5$ houver um valor elevado para o coeficiente r_5 , o teste indica uma sazonalidade para um período de cinco semanas. No caso do SKU A, os três maiores valores para os coeficientes de autocorrelação ocorrem para $k = 4$, $k = 12$ e $k = 16$, o que significa que as sazonalidades ocorrem a cada quatro semanas, comprovando-se a suspeita da sazonalidade da semana dentro do mês. Um exemplo dessa análise para o SKU A encontra-se na Figura 24.




Figura 24: Diagrama de autocorrelação para o SKU A realizado no Crystal Ball®

Quanto ao SKU C, os coeficientes de autocorrelação foram maiores para $k = 4$, $k = 8$ e $k = 20$. Neste caso, é preciso cautela ao se concluir sobre a sazonalidade, pois este SKU teve sua série influenciada pela ocorrência de uma venda concentrada em um único dia (conforme explicado anteriormente) e que, apesar de ter sido corrigida no tratamento de dados, os efeitos desse evento influenciaram as vendas posteriores. Apesar dessa possível distorção, os coeficientes para $k = 12$ e $k = 16$ possuem valores relativamente elevados no intervalo $8 < k < 20$. Será considerada, portanto, uma sazonalidade de período igual a quatro semanas. Finalmente, é preciso ressaltar que eventos dessa natureza contribuem para elevar os erros de previsão da demanda. A figura 25 ilustra o diagrama de autocorrelação do SKU C.




Figura 25: Diagrama de autocorrelação para o SKU C realizado no Crystal Ball®

Já no caso do SKU E, os maiores valores do coeficiente de autocorrelação ocorrem para $k = 12$, seguido de $k = 24$. Isso leva a crer na possibilidade de uma sazonalidade trimestral. A Figura 26 ilustra esse fato.




Figura 26: Diagrama de autocorrelação para o SKU E realizado no Crystal Ball®

Esse comportamento também apareceu na análise de autocorrelação das séries históricas do SKU B. Uma análise mais aprofundada revela que esse comportamento é influenciado pelo fechamento do trimestre de vendas. Além das metas mensais, a Empresa acompanha trimestralmente o acumulado de vendas, que é enviado para a matriz. Os terceiros meses dos trimestres, muitas vezes, possuem um volume maior de vendas que os demais.

Os testes mostram, portanto, que os SKUs podem possuir diferentes períodos de defasagem para sazonalidade semanal. Com base no valor mais elevado para o coeficiente de autocorrelação, a Tabela 6 da mostra os diferentes intervalos de defasagem propostos pelo Crystal Ball® para a sazonalidade semanal dos SKUs.

Tabela 6: Períodos de sazonalidade semanal para os SKUs

	SKUs					
	A	B	C	D	E	F
<i>Períodos de sazonalidade identificados (semanas)</i>	4	12	4	4	12	4

Em todos os casos, os picos ocorrem na quarta semana do mês (seja mensalmente, ou trimestralmente). Tendo em vista a natureza dos SKUs apresentados (sabonete, shampoo, absorvente, etc.) essas sazonalidades semanais não representam um comportamento diretamente relacionado a características específicas do produto (como no caso de um protetor solar, por exemplo). Essas sazonalidades são, portanto, consequência da política de vendas da empresa. As Figura 27 e Figura 28 mostram a evolução mensal das vendas para os SKUs B e F.




Figura 27: Evolução mensal de vendas do SKU B




Figura 28: Evolução mensal de vendas do SKU F

Visualmente, as vendas mensais (16 meses ao todo) não apresentam padrões de tendência ou sazonalidade. Para comprovar, realmente, a inexistência de sazonalidade mensal para os SKUs analisados neste trabalho, testes de autocorrelação foram realizados com a ajuda do *software* Crystal Ball®. Nenhum SKU apresentou coeficiente de autocorrelação com valores relevantes para a constatação da sazonalidade mensal ($|r_k| > V_L$). No Crystal Ball®, essa ausência de sazonalidade é verificada pela ausência de barras verde-escuras. A Figura 29 ilustra os testes feitos para os SKUs B e F.




Figura 29: Testes de autocorrelação mensal para os SKUs B e F realizados no Crystal Ball®

Essa ausência de sazonalidade mensal no ano está em acordo com o que foi explicado sobre a natureza dos produtos testados, que não apresentam um comportamento de consumo tipicamente sazonal ao longo do ano.

4.3.3 Conclusões preliminares

A inspeção preliminar e o ajuste dos dados permitiram a correção da série histórica de forma a reduzir impactos causados por *outliers*. Apesar da correção dos dados, fica claro que o impacto desses eventos não se limita apenas ao período em que ocorrem, mas também exerce influência sobre períodos subsequentes, o que é de difícil correção (especialmente quando são analisadas centenas de SKUs). Cabe lembrar que a Empresa não mantém registros sistemáticos de eventos que podem afetar a curva de demanda (promoções, descontos, etc.). Isso também dificulta a realização de qualquer estudo mais aprofundado que se queira fazer sobre a demanda dos produtos. Fica a recomendação para a Empresa manter, de forma sistemática e organizada, os registros desses eventos, a fim de utilizá-los para melhorar a qualidade dos dados das previsões de demanda (séries temporais) de seus produtos.

Outra conclusão importante desta etapa é que os SKUs apresentam sazonalidades semanais relacionadas, principalmente, à dinâmica de vendas da Empresa. Sazonalidades mensais ao longo do ano não foram identificadas.

Essa análise preliminar é importante para se entender com mais clareza e embasamento o comportamento das vendas dos SKUs, o que será fundamental para a etapa de estudo de modelos de gestão de estoques relacionados ao sistema de reserva de inventário da empresa.

A próxima seção abordará a escolha dos modelos de previsão de demanda que melhor descrevem os comportamentos das séries históricas de vendas dos SKUs.

4.4 Escolha dos modelos de previsão de demanda

A partir dos dados históricos, o Crystal Ball® realizará, automaticamente, as etapas de (4) a (8b) do modelo proposto por Russell e Taylor (2006). As previsões foram feitas

utilizando-se os dados semanais do faturamento de vendas. É preciso ressaltar, contudo, os dados semanais da quarta e quinta semana, nos meses em que ela existia, foram agrupados como explicado anteriormente. É com a suposição de que todos os meses possuem quatro semanas que foram realizadas as previsões de demanda deste trabalho. Vale lembrar, mais uma vez, que o propósito do uso da previsão de demanda no presente trabalho é o de auxiliar na proposição de melhorias na parametrização do sistema de reserva de inventário da Empresa. Quando este assunto for novamente retomado no capítulo seguinte, será explicado o procedimento a ser feito quando a previsão envolver meses com cinco semanas. Sendo assim, a intenção é gerar previsões que servirão de subsídio para a gestão do estoque de clientes KA da Empresa e, nesse caso, agregar a quarta e quinta semanas facilitará o processo e ajudará a gerar previsões mais acuradas, evitando distorções nas sazonalidades das séries históricas.

Para esta etapa de testes e parametrização dos modelos de previsão de demanda, é preciso realizar uma divisão dos dados históricos, a fim de que uma quantidade seja reservada para os testes dos modelos. Conforme explicado anteriormente a respeito da entrada do CD de SP em abril de 2009, o histórico disponível compreende os dados a partir dessa data, somando-se, no total, 64 semanas. Para que os dados fossem testados com pelo menos um período de 52 semanas (um ciclo anual completo), as 12 semanas restantes serviram para embasar os testes de acurácia dos modelos.

O horizonte de tempo foi, então, dividido em séries. Cada série será usada para gerar uma previsão para o período imediatamente seguinte ao seu último dado. Os dados históricos foram divididos em séries, de tal forma que representassem uma situação em se inicia com uma quantidade histórica de 52 semanas, chamada Série 1 (período que vai de abril de 2009 a março de 2010). O *software* testa e define qual o melhor modelo que descreve essa série e gera uma previsão para a 1ª semana de abril de 2010. Essa previsão (F_1) é comparada com o dado real para aquela semana (Y_1) utilizando-se como medida de erro o PE. Em seguida, os dados reais relativos à 1ª semana de abril de 2010 são adicionados à Série 1, dando origem, assim, à Série 2. Novamente, o software testará o melhor modelo que se adequa a essa série e calculará a previsão para a próxima semana (2ª semana de abril de 2010). Essa previsão (F_2) será comparada com o dado real para aquela semana (Y_2) e um novo PE será calculado. Essa rotina seguirá até a penúltima semana de dados disponível, que servirá para gerar uma previsão para a 4ª semana de julho de 2010 (o último dado real disponível para comparação). As semanas compreendidas entre os meses de abril de 2010 a julho de 2010 (12 semanas ao

todo) foram destinadas para essa fase de comparação dos resultados de previsão. A Tabela 7 sintetiza a lógica da divisão do horizonte de tempo para o processo de previsão.

Tabela 7: Divisão do horizonte de tempo em séries semanais

	Série 1	Série 2	Série 3	...	Série 10	Série 11	Série 12	Série 13
Horizonte de tempo da série	1a semAbr 09 - 4a semMar 10	1a semAbr 09 - 1a semAbr 10	1a semAbr 09 - 2a semAbr 10	...	1a semAbr 09 - 1a semJul 10	1a semAbr 09 - 2a semJul 10	1a semAbr 09 - 3a semJul 10	1a semAbr 09 - 4a semJul 10
Total de semanas na série	52	53	54	...	61	62	63	64
Período que se deseja prever	1a semAbr 10	2a semAbr 10	3a semAbr 10	...	2a semJul 10	3a semJul 10	4a semJul 10	
Previsão CB	F ₁	F ₂	F ₃	...	F ₁₀	F ₁₁	F ₁₂	
Real	Y ₁	Y ₂	Y ₃	...	Y ₁₀	Y ₁₁	Y ₁₂	
PE	PE ₁	PE ₂	PE ₃	...	PE ₁₀	PE ₁₁	PE ₁₂	

Finalmente, todos os PEs calculados foram utilizados para o cálculo do MAPE das previsões geradas para as 12 semanas. Aqui o conceito do erro MAPE não será usado para medir a acurácia de um modelo específico, já que o *software* testa todos os modelos a cada nova série. Esse conceito será utilizado mais como um indicador para monitorar o desempenho das previsões como um todo, ou seja, se o processo de previsão está gerando resultados satisfatórios.

Solicitou-se, portanto, que o *software* calculasse 12 previsões, para cada SKU, relativos às Séries 1, 2,..., 12. Esses valores foram, em seguida, comparados com os dados reais das respectivas semanas. A Tabela 23, no Anexo deste trabalho, mostra um fragmento da tabela de dados usada para gerar as previsões no Crystal Ball®, tomando como exemplo o SKU D.

A técnica de previsão utilizada no *software* é o *holdout*, que, como explicado no levantamento bibliográfico, permite que os testes de erros sejam utilizados em um conjunto de dados que não foram previamente utilizados na parametrização do modelo. Os erros obtidos são, portanto, valores realmente procedentes de uma comparação entre os dados projetados pelo modelo e os dados reais, não utilizados na parametrização. O Crystal Ball® permite que o usuário escolha a quantidade de dados (n) que ele deseja reservar para o chamado *holdout set*. Essa quantidade de dados será destinada aos testes de acurácia realizados pelo *software* para a escolha do modelo de previsão. O Crystal Ball® selecionará, portanto, o modelo que fornece o menor erro, comparando-se a previsão gerada com os dados reais reservados. O dilema dessa técnica é que ao mesmo tempo em que se deseja um grande número de dados para a calibração do modelo, também se deseja uma quantidade razoável de dados para testá-

lo. Usualmente, reservam-se aproximadamente 30% da quantidade de dados da série histórica para testes. Como a quantidade de dados disponível para o presente estudo já é relativamente baixa, o número de períodos reservados para teste (*holdout*) será de 15 semanas. Como para a calibração dos modelos foram utilizadas entre 52 e 63 semanas (12 séries no total), decidiu-se reservar um número $n = 15$ semanas para os seis SKUs.

O *software* permite, ainda, a escolha de três tipos de erros para serem usados na calibração do modelo: MAE, RMSE (raiz quadrada do MSE) e MAPE. No caso estudado, foi escolhido o MAPE, pois é uma medida que permite uma comparação mais fácil e intuitiva dos resultados, já que é calculado em termos percentuais. Para casos de valores de entrada nulos, o *software* desconsidera o erro percentual absoluto obtido para aquele dado, evitando distorções que inviabilizariam o uso do indicador de erro.

Outra entrada que o software solicita é o valor do período de sazonalidade da série histórica que se deseja testar. Para tanto, ele disponibiliza análises de autocorrelação dos dados (como feito na seção anterior). Os valores das sazonalidades semanais, resumidos na Tabela 6, serão usados nos testes dos modelos.

O Crystal Ball® também permite a escolha do número de períodos que se deseja prever e o intervalo de confiança da previsão, que define o intervalo dentro do qual é provável que a previsão aconteça, assumindo que os erros de previsão estão normalmente distribuídos. Foi estipulado um intervalo de confiança de 95% para todos os testes.

A Tabela 8 resume as variáveis que o usuário deverá ajustar no *software* antes que ele gere automaticamente as previsões e os valores que foram utilizados na realização deste trabalho.

Tabela 8: Variáveis de entrada controladas pelo usuário do *software* Crystal Ball®

Parâmetro	Valor
Tipo da série (dias, semanas, meses...)	Semanas
Seleção da série histórica	Séries de dados variando entre 52 e 63 semanas
Nº de períodos que se deseja prever	1
Sazonalidade dos dados	4 ou 12 semanas (dependendo do SKU)
Erro utilizado para testes dos modelos	MAPE
Intervalo de confiança	95%
<i>Holdout set</i>	15 semanas

Após a definição dos valores dos parâmetros de entrada, inicia-se a fase de testes realizada automaticamente pelo *software*. Como explicado anteriormente, cada série de dados (12 séries para cada SKU) foi testada e descrita por um modelo de previsão que minimiza os erros para a série em questão. A vantagem desse tipo de *software* é que ele automatiza os testes de escolha dos modelos e permite que, a cada atualização dos dados, todas as opções de modelos disponíveis sejam novamente testadas, não limitando, portanto, o usuário a um único modelo para cada SKU. Dessa forma, foram definidos para o total das 72 séries quais modelos melhor se adequava a cada uma. A título de exemplo, foi escolhida a Série 9 (1ª semana de abril de 2009 a 4ª semana de junho de 2010) do SKU A para ilustrar os principais resultados e análises de previsão fornecidos pelo Crystal Ball®. A série possui 60 dados e a previsão será feita para a 1ª semana de julho de 2010.

Como já comentado no capítulo 2, o Crystal Ball® testa um total de 8 modelos de previsão diferentes. Para o caso da Série 9 do SKU A, o método da Suavização Exponencial Multiplicativa forneceu o menor MAPE (55%). O gráfico da Figura 30, gerado pelo software, mostra a série histórica de dados, em verde, e a série ajustada pelo modelo, em azul. O ajuste do modelo foi realizado utilizando-se 46 dados semanais. Os outros 15 restantes (*holdout set*) foram utilizados para os testes de acurácia dos modelos.




Figura 30: Modelo de previsão de demanda sugerido pelo Crystal Ball® para a Série 9 do SKU A

As Tabelas 9, 10 e 11 resumem os principais resultados dos modelos testados para essa série.

Tabela 9: Acurácia da previsão dos modelos testados - Série 9 do SKU A

Method	RMSE	MAD	MAPE
Best: Seasonal Multiplicative	668,14	493,01	55,31%
2nd: Holt-Winters' Multiplicative	947,38	642,92	57,86%
3rd: Holt-Winters' Additive	715,76	520,84	58,14%
4th: Seasonal Additive	666,91	492,57	59,28%
5th: Single Exponential Smoothing	1130,4	820,53	80,61%
6th: Single Moving Average	1194	895,93	83,69%
7th: Double Moving Average	999,02	663,89	84,28%
8th: Double Exponential Smoothing	1179,8	870,54	108,73%

Tabela 10: Valores dos parâmetros dos modelos de previsão testados - Série 9 do SKUA

Method	Parameter	Value
Best: Seasonal Multiplicative	Alpha	0,938
	Gamma	0,5
2nd: Holt-Winters' Multiplicative	Alpha	0,292
	Beta	0,504
	Gamma	0,5
3rd: Holt-Winters' Additive	Alpha	0,055
	Beta	0,585
	Gamma	0,247
4th: Seasonal Additive	Alpha	0,782
	Gamma	0,323
5th: Single Exponential Smoothing	Alpha	0,956
6th: Single Moving Average	Periods	1
7th: Double Moving Average	Periods	11
8th: Double Exponential Smoothing	Alpha	0,481
	Beta	0,618

Tabela 11: Intervalos de confiança para a previsão – Série 9 do SKU A

Date	Lower: 5%	Forecast	Upper: 95%
61	-2584	162	2909

Comparando o resultado da previsão com o dado real ocorrido na 1ª semana de julho de 2010, obtém-se um PE de 69%. Os PEs de todas as 12 séries testadas para os 6 SKUs foram calculados em uma planilha Excel®, de forma similar os exemplo da Tabela 23, no

Anexo. A partir desses valores, foram calculados, separadamente em uma planilha Excel®, os MAPEs de cada SKU, comparando o valor previsto pelo *software* com o valor que efetivamente ocorreu para aquela semana. Esse indicador fornece indícios de quão acurada está sendo a previsão para o SKU de forma geral (e não apenas a acurácia de um único modelo), já os resultados da previsão são obtidos testando-se, para cada série histórica, todas as oito possibilidades de modelos de previsão disponíveis no *software*.

A Tabela 12 mostra um resumo dos resultados obtidos para cada série testada do SKU F. O APE representa a comparação entre o valor previsto pelo *software* e o dado real em valor absoluto. E o MAPE é a média dos valores absolutos dos erros percentuais (APE). Os demais resultados encontram-se no Anexo deste trabalho.

Tabela 12: Quadro resumo dos resultados das previsões para o SKU F

SKU F	Método escolhido	APE	MAPE
Série 1	<i>Single Exponential Smoothing</i>	210%	175%
Série 2	<i>Single Exponential Smoothing</i>	164%	
Série 3	<i>Holt-Winters' Additive</i>	319%	
Série 5	<i>Holt-Winters' Additive</i>	145%	
Série 6	<i>Seasonal Multiplicative</i>	73%	
Série 7	<i>Seasonal Additive</i>	99%	
Série 8	<i>Seasonal Multiplicative</i>	25%	
Série 9	<i>Holt-Winters' Multiplicative</i>	157%	
Série 10	<i>Holt-Winters' Multiplicative</i>	23%	
Série 11	<i>Holt-Winters' Multiplicative</i>	48%	
Série 12	<i>Seasonal Multiplicative</i>	833%	

Observa-se, portanto, um MAPE muito elevado. A Tabela 13 mostra os valores dos MAPEs obtidos para cada SKU, de acordo com o processo explicado anteriormente.

Tabela 13: MAPEs obtidos para as previsões de demanda semanais dos SKUs

	SKU A	SKU B	SKU C	SKU D	SKU E	SKU F
MAPE	156%	376%	179%	133%	668%	176%

Todos os SKUs obtiveram um MAPE maior que 100%. Sendo o pior caso o do SKU E, com mais de 600%. Esses resultados levam a concluir que a previsão de demanda nas circunstâncias apresentadas é extremamente insatisfatória. Não é possível prever com uma acurácia relativamente boa a demanda desses SKUs. Vários fatores podem estar relacionados a essa alta variabilidade. A Tabela 14 mostra um resumo estatístico dos dados de vendas das 64 semanas para cada SKU.

Tabela 14: Quadro resumo das estatísticas dos dados de vendas dos SKUs

<i>Resumo estatístico das séries históricas de vendas dos SKUs</i>						
	SKU A	SKU B	SKU C	SKU D	SKU E	SKU F
Nº de dados (semanas)	64	64	64	64	64	64
Média	1004	215	122	530	458	336
Desvio-pradrão	804,22	119,71	114,00	411,68	380,82	320,30
Máximo	3234	769	506	2471	1508	1515
Mínimo	55	9	5	14	9	21

Esses resultados levam à confirmação da alta variabilidade dos dados de vendas, que oscilam entre máximos e mínimos distantes. Os valores dos desvios-padrão são muito elevados, aproximando-se da própria média. Tratam-se, portanto, de distribuições que não se aproximam de um comportamento normal. Testes realizados com o auxílio do Crystal Ball® comprovaram que nenhuma das séries de dados se aproximou de uma distribuição normal. A Figura 31 mostra, por exemplo, que a distribuição de probabilidade para os dados históricos do SKU A se aproxima melhor de uma distribuição Lognormal.




Figura 31: Distribuição de probabilidade para os dados históricos do SKU A

É também importante verificar se os erros de previsão seguem uma distribuição normal, já que essa hipótese é considerada para o cálculo do estoque de segurança na maioria dos casos. Testes semelhantes realizados no Crystal Ball® mostram que nenhum dos SKUs apresentou erros de previsão que seguissem uma distribuição normal. A Figura 32 mostra um exemplo para o caso da distribuição de probabilidade dos erros de previsão do SKU A.




Figura 32: Distribuição de probabilidade para os erros de previsão do SKU A

Os resultados obtidos com a previsão de demanda para os SKUs, portanto, não se mostraram satisfatórios para estimar as vendas semanais. A próxima seção fará uma análise a respeito dessas implicações.

4.5 Avaliação dos resultados da previsão

O elevado valor do MAPE Real na previsão de demanda dos SKUs incita a alguns questionamentos sobre os dados em si. Conforme apresentado, os dados coletados representavam o faturamento das vendas do *sell-in* da empresa para clientes KA. Tal fato é fundamental para ajudar a explicar as grandes oscilações nos valores levantados. Sabe-se que esse tipo de venda reflete a tomada de decisão de poucos atores, estando, portanto, sujeita a pressões comerciais e entre cliente-fabricante, além de ser reflexo de interesses circunstanciais. Diferentemente do *sell-out*, que é a venda para o consumidor final, e é resultado da tomada de decisão de vários indivíduos, que agem de forma a gerar uma

distribuição normal de demanda. A autora deste trabalho teve acesso aos dados mensais de *sell-out* de alguns clientes KA da Empresa. Para efeito comparativo, o gráfico da Figura 33 mostra as curvas de *sell-in* (vendas a Empresa para esses clientes) e *sell-out* (desses clientes




Figura 33: Curvas de *sell-in* e *sell-out* para o SKU A

KA selecionados para o consumidor final).

Simulando-se previsões mensais, para esse determinado número de clientes, utilizando dados de *sell-in* e de *sell-out*, obteve-se para o SKU A um MAPE Real menor nas previsões que utilizavam dados de *sell-out* (10% para o *sell-out*, enquanto o MAPE para *sell-in* foi de 58%). Nesse caso, é preciso ressaltar que a previsão agregada também gera melhores resultados. Analisando-se previsões mensais é possível obter um MAPE significativamente inferior ao das previsões semanais. Agrupando-se as semanas em meses (abril de 2009 a julho de 2010) e realizando as previsões de forma semelhante o que foi feito para os dados semanais (com previsões para os meses de abril de 2010 a julho de 2010), chega-se aos resultados da Tabela 15. Não foram encontradas evidências de sazonalidade mensal, conforme visto na seção anterior.

Tabela 15: MAPEs obtidos para as previsões de demanda mensais dos SKUs

	<i>SKU A</i>	<i>SKU B</i>	<i>SKU C</i>	<i>SKU D</i>	<i>SKU E</i>	<i>SKU F</i>
MAPE	68%	21%	26%	37%	8%	96%

Apesar de alguns SKUs ainda apresentarem valores de elevados, percebe-se que a previsão de demanda agregada por mês é melhor que a semanal. Sendo as previsões realizadas por CD, valores melhores também poderiam ser obtidos prevendo-se para os três CDs conjuntamente. De fato, Simchi-Levi; Kaminsky e Simchi-Levi (2003) explicam que informações de demanda agregadas são sempre mais precisas que dados desagregados, apresentando menor variabilidade. Apesar dos dados das vendas agregadas por mês fornecerem melhores resultados, o objetivo é prever a demanda semanal para utilizá-la na reposição da reserva.

Vale ressaltar que fatores como condições especiais de promoção, ações da concorrência, a oferta de crédito e a indisponibilidade de produto por parte da empresa exercem influência sobre a demanda pelo produto, tornando ainda mais complexa a previsão de demanda, mesmo num nível mais agregado.

Outro ponto importante e que merece destaque é o chamado Efeito Chicote, descrito no capítulo 2. Como visto para o exemplo do SKU A, a variabilidade nas previsões utilizando-se dados de *sell-in* é maior do que a observada nas previsões com dados de *sell-out*, devido, também, à propagação das incertezas sobre a demanda na cadeia de suprimentos. As oscilações a montante da cadeia são maiores do que as observadas junto ao consumidor final por todos aqueles motivos já explicitados na revisão bibliográfica a respeito do Efeito Chicote. Todavia, é preciso ressaltar que previsões utilizando dados de *sell-out* não fazem parte dos objetivos deste trabalho por diversos motivos. Ainda existem, atualmente, limitações na extração e no acesso a esses dados no sistema de informação da empresa.

Um ponto relevante é que o uso das informações de *sell-out* teria maior significância, caso o cenário em que a Empresa estivesse inserida fosse um ambiente colaborativo, no qual as informações sobre a demanda do cliente final são levadas em consideração durante as negociações comerciais, de forma a minimizar os riscos e incertezas nas tomadas de decisão ao longo da cadeia. Mas isso, na maioria das vezes, não ocorre atualmente, visto que as políticas de vendas ainda estão voltadas mais para o atingimento de metas, mais do que para atender às reais necessidades dos clientes em termos de volume de produtos. Sendo assim, seria irrealista propor uma solução levando em consideração a projeção da demanda final, enquanto as negociações de vendas para os clientes diretos, os grandes varejistas neste caso, não ponderam apenas esse fator.

Apesar dos elevados erros obtidos na previsão, é preciso ressaltar que o objetivo não é prever a demanda do SKU pura e simplesmente. A intenção é usar essa informação para definir as quantidades que deverão ser destinadas à reserva de inventário de cada SKU. Sendo assim, os erros de previsão serão importantes para estimar o estoque de segurança que deverá ser mantido, conforme explicado mais detalhadamente no próximo capítulo.

5 AVALIAÇÃO DE MODELOS DE REPOSIÇÃO PARA A “RESERVA DE INVENTÁRIO”

Após a análise do comportamento da demanda de alguns SKUs selecionados, este capítulo avalia modelos de reposição de estoque que possam auxiliar na melhoria da reserva de inventário, descrita no capítulo 1.

5.1 Modelagem

As melhorias pretendidas neste trabalho visam reduzir os níveis elevados da reserva, dado um nível de serviço esperado em torno de 95% para os clientes KA. Levando-se em consideração esses dois principais aspectos, acredita-se que o modelo de reposição baseado em previsão de demanda proporcione melhores resultados que o atual sistema da Empresa, descrito no capítulo 1. Serão testadas duas políticas de estoque: i) reposição da reserva diariamente conforme alvo de vendas (modelo atual), ii) reposição semanal conforme alvo de vendas, iii) reposição semanal da reserva com base em previsão de demanda.

Antes de iniciar os testes com os modelos, é válido lembrar algumas premissas do funcionamento do sistema da reserva de inventário. Primeiramente, considerar-se-á que o *lead time* de abastecimento da reserva é de um dia, ou seja, a reserva pode ser abastecida sempre no dia seguinte à liberação da ordem de reposição. A quantidade definida para reposição será retirada do estoque dos “demais clientes”. Parte-se, portanto, do princípio que esse sistema funciona de tal forma que sempre que uma ordem de abastecimento da reserva for feita, haverá produtos suficientes para suprir essa demanda.

Para os SKUs escolhidos, os pedidos de reposição, para o caso (iii), deverão ser calculados toda segunda-feira, para que se tenha o dado da demanda da semana anterior completa para atualização do modelo baseado em previsão de demanda. Isso implica que o abastecimento ocorrerá na terça-feira. Na prática, esse “atraso” de um dia no abastecimento, não impactará no nível de serviço, visto que, em média, as segundas-feiras apresentam aproximadamente a mesma representatividade dentro do mês, logo, a quantidade destinada à

segunda-feira da semana (t) será “consumida” na segunda-feira da semana ($t+1$). A Figura 34 ilustra as sequências de reposição da reserva durante as semanas.




Figura 34: Cálculo da NLÍq e o consumo da reserva num sistema de reposição de estoque com previsão de demanda

De toda forma, diante da grande variabilidade da demanda apresentada no capítulo anterior, essa consideração não exerce impacto significativo sobre os resultados almejados e poderá ser absorvida pelo estoque de segurança. Logo, para efeitos de simplificação, o período de revisão que será utilizado no cálculo da previsão será $R = 1$ semana e $L = 0$.

Outra consideração, feita no capítulo 4, foi o agrupamento da quarta e quinta semanas do mês para o cálculo da previsão de demanda. De forma a preservar os resultados alcançados com essa simplificação, a mesma consideração será mantida no cálculo da NLÍq, para o modelo (iii). Todavia, para os meses que possuírem cinco semanas, haverá uma adaptação na reposição das duas últimas semanas. A previsão será feita como se existissem apenas quatro semanas, porém o cálculo da NLÍq para a quarta semana atenderá às demandas da quarta e quinta semanas do mês. Sendo assim, não haverá nova reposição no começo da quinta semana. Na prática, contudo, se alguma demanda extraordinária estiver prevista para ocorrer (promoções, negociações especiais, etc.), poderia ser programada uma nova reposição. A Figura 35 ilustra esse processo.




Figura 35: Reposição semanal da reserva nos meses com quatro ou cinco semanas

Vale lembrar que não existe restrição quanto ao tamanho do lote de reposição. A unidade mínima é de uma caixa e a máxima é limitada à quantidade disponível no estoque dos “demais clientes”, considera suficientemente grande para efeito de transferência à reserva na simulação.

5.2 Indicadores de desempenho

Durante os testes dos modelos de reposição de estoque, serão avaliados dois principais indicadores, com vista aos objetivos pretendidos: nível de serviço e nível médio de estoque. O nível de serviço (NS) está relacionado à disponibilidade de produto para atender à demanda e representa, neste trabalho, o percentual de atendimento à demanda num determinado período de teste. A Equação (32) mostra esse cálculo.

$$NS = \frac{D_{atendida\ em\ n}}{D_{total\ em\ n}} \quad (32)$$

Onde: n – número total de períodos considerados na simulação. Neste trabalho, para modelos simulados com semanas, $n=13$ semanas (os testes simulam as semanas sem agrupamento da quarta e quinta semanas do mês). Para a simulação do sistema atual da reserva de inventário, que trabalha em uma base diária, $n = 92$ dias.

Para simplificar a análise, considerar-se-á que, entre dois períodos de reposição consecutivos, o consumo do estoque se dê de forma linear. Essa aproximação reduzirá a complexidade na estimativa do estoque médio. Vale lembrar que o objetivo final da simulação

não é calcular com exatidão esse indicador, mas, sim, fornecer uma orientação na escolha do modelo mais adequado. Dessa forma, o nível médio de estoque durante o período total n ($E_{médio}$) será a média entre o Estoque Inicial médio durante n (média da quantidade de produtos em estoque logo após a reposição, no início do período) e o Estoque Final médio durante n (média da quantidade de produtos em estoque no final do período, antes da próxima reposição).

$$\text{Estoque Inicial médio} = \frac{\sum_{t=1}^n \text{Estoque no início de } t}{n} \quad (33)$$

$$\text{Estoque Final médio} = \frac{\sum_{t=1}^n \text{Estoque no final de } t}{n} \quad (34)$$

$$\text{Estoque}_{médio} = \frac{\text{Estoque Inicial médio} + \text{Estoque Final médio}}{2} \quad (35)$$

O objetivo da Empresa é oferecer um nível de serviço mínimo de 95% e ideal de 99% para os clientes KA. Quanto aos níveis médios de estoque, a Empresa não possui metas específicas, mas espera que haja uma redução dos atuais níveis, que, como apresentado, são muito elevados.

5.3 Testes de avaliação dos modelos de reposição de estoque

Conforme explicado anteriormente, neste trabalho $L = 0$ e, para o modelo de reposição baseado em previsão de demanda, esta será feita considerando um horizonte de reposição de uma semana. Sendo assim, serão utilizados os resultados obtidos para as 12 séries históricas de cada SKU, conforme os cálculos do capítulo 4. Como no mês de junho de 2010 foram somadas a quarta e a quinta semanas, existem, na realidade, 13 dados históricos semanais que serão utilizados para a simulação dos modelos, valendo-se da adaptação explicada na seção anterior para meses com cinco semanas, no caso no modelo baseado em previsão de demanda. Para efeito de simulação, a posição do estoque da reserva dos SKUs, para o período

imediatamente anterior ao início dos testes, foi considerada nula para os três modelos. Essa consideração não afeta os resultados e é uma situação que pode ocorrer, ou seja, a reserva pode ser “esvaziada” a qualquer momento pelo usuário, bastando apenas atribuir no sistema um valor nulo à reserva. Os produtos que estavam reservados voltam, portanto, ao estoque dos “demais clientes”. Ao iniciar-se a simulação, no primeiro período de teste, a reserva é abastecida completamente, de acordo com a quantidade calculada em cada modelo.

Os resultados gerados pelo modelo baseado em previsão serão comparados com a simulação do sistema atual, considerando reposição diária e semanal. Vale lembrar que proposta de reposição por previsão de demanda, para ser viabilizada, precisa de um suporte da TI para que o sistema de informação da empresa disponibilize dados semanais de demanda de todos os SKUs.

5.3.1 Reposição Diária da Reserva (sistema atual)

Conforme já explicado no capítulo 1 a respeito do funcionamento desse sistema, a reposição é feita diariamente. Este tópico não pretende retomar as discussões anteriormente apresentadas, mas, sim, apresentar dados sobre o seu desempenho simulando-se uma situação semelhante à operação real. Para definição da quantidade que deverá ser reservada, coletou-se no sistema BW da Empresa os alvos de vendas mensais a partir de maio de 2010 até julho de 2010. Em seguida, o cálculo da reserva foi feito segundo a Equação (1). A Tabela 16 mostra os resultados obtidos para o SKU A.

Tabela 16: Simulação do modelo de reposição de estoque da proposição alternativa – SKU A

<i>t</i>	<i>Dias</i>	<i>Demanda (t)</i> (faturamento)	<i>Quantidade</i> <i>para reserva</i> <i>diária</i>	<i>Nível de</i> <i>estoque no</i> <i>final do dia</i> <i>anterior (t-1)</i>	<i>Recebimento do</i> <i>lote de rep. no</i> <i>começo do dia (t)</i>	<i>Nível de estoque</i> <i>após abastecimento</i> <i>no começo do dia (t)</i>	<i>Demanda</i> <i>atendida (t)</i>	<i>Nível de estoque</i> <i>final do dia (t)</i>	<i>Qtd. para reposição</i> <i>(Qres - Qtd. fim do dia)</i>
1	01/05/2010	0	1450	0	1450	1450	0	1450	818
2	02/05/2010	29	2269	1450	818	2269	29	2240	29
3	03/05/2010	0	2269	2240	29	2269	0	2269	0
4	04/05/2010	36	2269	2269	0	2269	36	2233	36
5	05/05/2010	0	2269	2233	36	2269	0	2269	0
6	06/05/2010	7	2269	2269	0	2269	7	2262	7
7	07/05/2010	0	2269	2262	7	2269	0	2269	0
8	08/05/2010	0	2269	2269	0	2269	0	2269	0
9	09/05/2010	12	2269	2269	0	2269	12	2257	12
10	10/05/2010	743	2269	2257	12	2269	743	1526	743
...	...	...	...	...	...	...	...	...	...
88	27/07/2010	80	1126	854	272	1126	80	1046	80
89	28/07/2010	57	1126	1046	80	1126	57	1069	57
90	29/07/2010	200	1126	1069	57	1126	200	926	200
91	30/07/2010	284	1126	926	200	1126	284	842	284
92	31/07/2010	0	1126	842	284	1126	0	1126	-1126

Constata-se, portanto, que o elevado *NS* de 100% para esse SKU é obtido à custa de um nível de estoque médio diário de 2021 caixas, o que também equivale a uma média semanal de 2021 caixas aproximadamente.

5.3.2 Reposição Semanal da Reserva

Este modelo assemelha-se ao sistema atual, entretanto, ao invés de reposição diária, serão feitas reposições semanais, também com base no alvo de vendas. A Tabela 17 ilustra a simulação desse modelo para o SKU A.

Tabela 17: Simulação do modelo de reposição semanal da reserva – SKU A

<i>t</i>	<i>Dias</i>	<i>Demanda (t)</i> (faturamento)	<i>Quantidade</i> <i>para reserva</i> <i>diária</i>	<i>Nível de</i> <i>estoque no</i> <i>final do dia</i> <i>anterior (t-1)</i>	<i>Recebimento do</i> <i>lote de rep. no</i> <i>começo do dia (t)</i>	<i>Nível de estoque</i> <i>após abastecimento</i> <i>no começo do dia (t)</i>	<i>Demanda</i> <i>atendida (t)</i>	<i>Nível de estoque</i> <i>final do dia (t)</i>	<i>Qtd. para reposição</i> <i>(Qres - Qtd. fim do dia)</i>
1	01/05/2010	0	1450	0	1450	1450	0	1450	818
2	02/05/2010	29	2269	1450	818	2269	29	2240	0
3	03/05/2010	0	2269	2240	0	2240	0	2240	0
4	04/05/2010	36	2269	2240	0	2240	36	2204	0
5	05/05/2010	0	2269	2204	0	2204	0	2204	0
6	06/05/2010	7	2269	2204	0	2204	7	2197	0
7	07/05/2010	0	2269	2197	0	2197	0	2197	72
8	08/05/2010	0	2269	2197	72	2269	0	2269	0
9	09/05/2010	12	2269	2269	0	2269	12	2257	0
10	10/05/2010	743	2269	2257	0	2257	743	1514	0
11	11/05/2010	4	2269	1514	0	1514	4	1510	0
12	12/05/2010	8	2269	1510	0	1510	8	1502	0
13	13/05/2010	16	2269	1502	0	1502	16	1486	0
14	14/05/2010	10	2269	1486	0	1486	10	1476	793
15	15/05/2010	4	2269	1476	793	2269	4	2265	0
16	16/05/2010	2	2269	2265	0	2265	2	2263	0
17	17/05/2010	40	2269	2263	0	2263	40	2223	0
18	18/05/2010	0	2269	2223	0	2223	0	2223	0
19	19/05/2010	400	2269	2223	0	2223	400	1823	0
...	...	...	...	...	...	...	...	...	...
88	27/07/2010	80	1126	825	0	825	80	745	0
89	28/07/2010	57	1126	745	0	745	57	688	0
90	29/07/2010	200	1126	688	0	688	200	488	0
91	30/07/2010	284	1126	488	0	488	284	204	922
92	31/07/2010	0	1126	204	922	1126	0	1126	0

Os resultados obtidos para o SKU A mostram um nível de serviço de serviço também de 100% para o período testado e o estoque médio foi de 1923, sendo inferior ao modelo (i). Verifica-se, contudo, que a redução não foi expressiva, ficando em torno de 5%. Resultados semelhantes foram obtidos para os demais SKUs. Apenas para os SKUs B e D, foram obtidas reduções maiores que 10%. Analisando o nível de serviço obtido, para os SKUs B e E, o NS ficou inferior a 95%. A Tabela 18 apresenta as reduções de estoque médio adotando-se o modelo (ii).

Tabela 18: Reduções de estoque obtidas com a reposição semanal

	<i>Estoque médio</i>		<i>Redução do estoque médio</i>
	Reposição diária	Reposição semanal	
SKU A	2021	1923	5%
SKU B	240	202	16%
SKU C	231	216	6%
SKU D	1081	931	14%
SKU E	938	915	2%
SKU F	434	419	3%

5.3.3 Reposição Semanal da Reserva baseada em previsão de demanda

Para o modelo de reposição baseado em previsão, serão utilizados os resultados das previsões calculados no capítulo 4. Sendo assim, F_1 é a previsão feita na Série 1 (1ª semana de abril de 2009 até a 4ª semana de março de 2010) para o período seguinte (1ª semana de abril de 2010). Essa previsão, acrescentada de um estoque de segurança representa a $NBruta_1$, que é a necessidade bruta que se deve ter na reserva para atender a 1ª semana de abril de 2010.

A partir das Equações (28) e (29), o estoque de segurança será calculado conforme a Equação (36).

$$EstSeg = k \times \hat{\sigma}_R \quad (36)$$

No caso deste estudo, tem-se para $R = 1$:

$$\hat{\sigma}_R = \hat{\sigma}_1 \times \sqrt{R} = \hat{\sigma}_1 = \sqrt{MSE_t} \quad (37)$$

De acordo com a Equação (30),

$$MSE_1 = w(Y_1 - F_1)^2 + (1 - w)MSE_0 \quad (38)$$

No presente trabalho, será considerado $w = 0,1$ e MSE_0 será inicializado com o cálculo do MSE fornecido pelo Crystal Ball® durante a fase de ajuste do modelo de previsão aos dados históricos da Série 1. Para o cálculo do estoque de segurança do primeiro período de previsão, será utilizado o MSE_0 , pois ainda não se conhece o valor de Y_1 . De maneira semelhante, para o cálculo do estoque de segurança do período 2, será utilizado o MSE_1 , pois o valor de Y_2 ainda é desconhecido. Sendo assim:

$$\hat{\sigma}_{R_1} = \sqrt{MSE_1} \quad (39)$$

$$EstSeg_2 = k \times \hat{\sigma}_{R_1} \quad (40)$$

No final do período 2, tem-se Y_2 , portanto:

$$MSE_2 = w(Y_2 - F_2)^2 + (1 - w)MSE_1 \quad (41)$$

E o estoque de segurança para o período 3 é dado por:

$$EstSeg_3 = k \times \hat{\sigma}_{R_2} \quad (42)$$

Os demais estoques de segurança são calculados da mesma forma até o $EstSeg_{12} = k \times \hat{\sigma}_{R_{11}}$. O valor do coeficiente de segurança k , contudo, não pode ser obtido considerando-se a distribuição normal dos erros de previsão, uma vez que, conforme visto no

capítulo 4, a distribuição dos erros de previsão dos SKUs não seguem exatamente uma distribuição normal.

Procurar descrever a distribuição de probabilidade dos erros de previsão que melhor se ajusta para cada SKU não faz parte do escopo deste trabalho. A intenção é propor uma sugestão que possa ser implementada na realidade da Empresa, sendo assim, quanto mais simples e intuitivo for o modelo, melhor (sem perder de vista, é claro, os objetivos de redução do estoque e nível de serviço adequado). Não obstante, Silver; Pyke e Peterson (1998) explicam que, usualmente, a distribuição normal oferece um bom ajuste empírico para os dados, além de ser conveniente do ponto de vista analítico. Os benefícios advindos da adoção de outras distribuições são, em geral, baixos, especialmente quando se reconhecem outras imprecisões, como as estimativas dos parâmetros de distribuição, dos fatores de custo, etc. (SILVER; PYKE; PETERSON, 1998). Sendo assim, serão feitos testes variando o valor de k , de forma a obter um $NS = 95\%$ e 99% .

Na simulação do modelo baseado em previsão se demanda, são utilizadas as Equações (43) e (44). As notações tentam seguir o mesmo padrão da referência bibliográfica.

$$NBruta_t = Prev.CB_t + EstSeg_t \quad (43)$$

$$NLiq_{t+1} = NBruta_{t+1} - EstAtual_t \quad (44)$$

Onde: $Prev.CB_t$ – é a previsão feita no Crystal Ball® para o período t .

Com o auxílio do *software* Excel®, foram elaboradas planilhas que simularam o funcionamento desse modelo, de acordo com as proposições feitas. Devido à alta variabilidade da demanda, o software gerou, em alguns casos, uma previsão “negativa”. Durante as simulações, esse fato foi interpretado como uma demanda nula, sendo o valor da previsão igualado a zero nesses casos. Outra situação que também poderia ocorrer é do nível do estoque no final de uma determinada semana ser maior do que a necessidade calculada para o próximo período. Nesses casos, o modelo sugere uma $NLiq$ negativa, que significa uma diminuição do nível de estoque para o próximo período. A Tabela 19 mostra um exemplo dessa planilha para o SKU A.

É preciso lembrar que se os erros de previsão seguissem uma distribuição normal, poderia ser adotado um valor de $k = 1,64$ para um nível de serviço desejado de 95%

(conforme a tabela de valores de z para a distribuição normal). O problema encontrado foi que, para esse valor de k , o valor do estoque de segurança para os SKUs seria desnecessariamente elevado. Sendo assim, variou-se o valor de k para obterem-se níveis de serviços de 95% e 99%.

Tabela 19: Simulação do modelo de reposição de estoque baseado em previsão de demanda – SKU A

t	Semanas	Demanda (t) (faturamento)	Previsão CB(t)	MSE_t	$\hat{\sigma}_{R_t}$	$EstSeg_t$	Nível de estoque final da semana ($t-1$) $EstAtual_{t-1}$	Recebimento do lote de rep. no começo da semana (t) $NLiq_t$	Nível de estoque após abastecimento no começo da semana (t) $NBruta_t$	Demanda atendida (t)	Nível de estoque final da semana (t) $EstAtual_t$	Tamanho do lote de reposição para a semana ($t+1$) $NLiq_{t+1}$
1	1a semMai-10	55	94	309212	556,1	762	0	856	856	55	801	276
2	2a semMai-10	787	354	297041	545,0	723	801	276	1077	787	290	1991
3	3a semMai-10	461	1573	390922	625,2	709	290	1991	2281	461	1820	701
4	4a semMai-10	630	1709	468225	684,3	813	1820	701	2522	630	1892	-957
5	1a semJun-10	385	45	432949	658,0	890	1892	-957	935	385	550	403
6	2a semJun-10	171	97	390199	624,7	855	550	403	953	171	782	466
7	3a semJun-10	530	436	352067	593,4	812	782	466	1248	530	718	1892
8	4a semJun-10	660	1839	382220	618,2	771	718	1892	2610	660	1950	0
9	5a semJun-10	1987	-	-	-	-	1950	0	1950	-37	0	966
10	1a semJul-10	527	162	357288	597,7	804	0	966	966	527	439	1741
11	2a semJul-10	119	1403	486335	697,4	777	439	1741	2180	119	2061	-501
12	3a semJul-10	634	653	437737	661,6	907	2061	-501	1559	634	925	785
13	4a semJul-10	893	851	394142	627,8	860	925	785	1711	893	818	...

No exemplo da Tabela 19, tem-se um nível de serviço de 99% para um valor de $k = 1,36$. Contudo, variando o valor de k , obtêm-se valores menores de estoque médio. A Tabela 20 mostra como se dá a variação do nível de serviço e do nível médio de estoque modificando-se os valores do fator de segurança k .

Tabela 20: Níveis de serviço e estoques médios em função de k

k	NS	Estoque médio (semanal)
0,7	94,4%	948
0,8	95,7%	1006
0,9	96,5%	1065
1,0	97,3%	1125
1,1	98,0%	1184
1,2	98,8%	1244
1,3	99,5%	1304

Evidentemente, valores mais elevados de k elevam o nível de serviço, ou seja, o atendimento à demanda. Em contrapartida, elevam também o estoque médio, ao aumentarem o valor do estoque de segurança. Verifica-se, portanto, o dilema entre o quanto se deseja ter em estoque e o quanto da demanda se pretende atender. Vale lembrar que os valores obtidos referem-se apenas a um curto horizonte de tempo (12 semanas). É fundamental, portanto, a realização de testes com uma maior quantidade de dados para se atestar a validade do modelo com maior certidão. Além disso, encontrar o valor de k mais adequado para cada SKU é também uma tarefa que exige mais dados disponíveis e poderia ser feito por meio de simulações.

Outro ponto que merece atenção é o fato da demanda sofrer grandes variações, conforme visto no capítulo anterior. Esse comportamento altamente variável da demanda influencia na determinação do valor do desvio-padrão dos erros e, por conseguinte, no estoque de segurança. Se fossem excluídos todos os picos atípicos da demanda ocorridos no período de teste, valores menores para os desvios-padrão poderiam ser encontrados. Todavia, decidiu-se simular o modelo com os dados reais para que se pudesse estabelecer uma comparação com o atual sistema em funcionamento.

5.4 Comparação dos modelos e análises dos resultados

Para comparar os resultados de cada modelo, serão avaliados os indicadores de nível de serviço e estoque médio durante o período de avaliação. Portanto, para o modelo baseado em previsão, serão simuladas duas situações: uma em que o **NS** seja de 99% e outra de 95%.

Tabela 21: Resultados das simulações dos três modelos considerando-se diferentes níveis de serviço

	<i>Reposição diária</i>		<i>Reposição semanal</i>		<i>Modelo baseado em previsão</i>			
	<i>da reserva</i>		<i>da reserva</i>		NS 95%		NS 99%	
	NS	Estq. méd.	NS	Estq. méd.	k	Estq. méd.	k	Estq. méd.
SKU A	100%	2021	100%	1923	0,74	971	1,36	1339
SKU B	100%	240	97%	202	0,51	185	0,75	224
SKU C	100%	231	100%	216	0,39	78	0,66	111
SKU D	100%	1081	100%	931	0,57	645	1,1	954
SKU E	100%	938	93%	915	1,41	707	2,1	1009
SKU F	87%	434	80%	419	0,39	377	0,59	463

Para se atingir esses valores de *NS*, serão variados os valores de *k*. Nos modelos de reposição diária e semanal não há a possibilidade de ajuste de parâmetros, uma vez que são modelos parametrizados de acordo com o alvo de vendas que é definido segundo o processo descrito no capítulo 1. A Tabela 21 resume os resultados.

Para um *NS* de 95%, o modelo de reposição por previsão de demanda apresentou os menores níveis de estoque médio. Ainda considerando-se um *NS* próximo de 100%, o modelo de previsão também forneceu melhores resultados para os SKUs A e C.

As simulações mostram que, mesmo mantendo uma elevada quantidade diária em reserva, o sistema de reposição atual não é garantia de um elevado nível de serviço sempre. Observando-se os resultados obtidos para o SKU F, com um nível de estoque médio de 434 caixas, obteve-se um nível de serviço de 87% no período analisado simulando-se o funcionamento do sistema atual. Entretanto, a simulação da reposição baseada em previsão de demanda forneceu um melhor nível de serviço, próximo de 99%, para um estoque médio de valor aproximadamente igual. Apenas para o SKU E, simulando-se um *NS* de 99%, a reposição do sistema atual forneceu um melhor nível médio de estoque em comparação com os outros dois modelos.

A Tabela 22 mostra uma comparação entre o nível de estoque médio semanal com o sistema atual de reposição da reserva e com o de reposição baseado em previsão de demanda para um *NS* de 99%. A redução dos níveis de estoque médio foi possível para quatro SKUs, obtendo-se reduções significativas principalmente para os SKUs A e C. Para o SKU E, a redução do estoque médio não foi constatada, apesar da diferença não ser muito expressiva, ficando em torno de 7%. Já a comparação entre os modelos com o SKU F não pode ser feita pura e simplesmente olhando o nível médio de estoque, pois o sistema de reposição atual forneceu um *NS* inferior a 99% para esse SKU, conforme explicado acima. De toda forma, uma consideração sobre esse caso já foi feita no parágrafo anterior.

Tabela 22: Comparação do nível médio de estoque para os modelos (i) e (iii)

	Nível médio de estoque para <i>NS</i> de 99%		% de redução do nível médio de estoque adotando-se (iii)
	(i) Modelo atual de reposição da reserva	(iii) Modelo baseado em previsão	
SKU A	2021	1339	34%
SKU B	240	224	7%
SKU C	231	111	52%
SKU D	1081	954	12%
SKU E	938	1009	x
SKU F	434	463	x

Apesar das evidências de que um sistema de reposição baseado em previsão consiga fornecer melhores resultados que o atual sistema de reposição (diário ou semanal), não é possível uma conclusão definitiva, sem antes efetuar uma análise mais abrangente incluindo um número maior de SKUs e também investigando o comportamento da demanda para os outros CDs. É preciso ressaltar que a insuficiência de uma quantidade maior de dados, tanto em termos de variedade de SKUs, quanto do tamanho da série de dados, impõe um limite quanto à assertividade destes resultados preliminares.

O intuito das análises realizadas não é o de fazer generalizações a respeito dos resultados obtidos com as simulações dos modelos. É provável que os modelos apresentados forneçam resultados diferentes dependendo do SKU. Sendo assim, não é possível concluir que um modelo único produzirá resultados satisfatórios em todos os 180 casos.

Apesar de todas essas ressalvas, as análises feitas ao longo deste trabalho fornecem subsídios que permitam questionar a adequação do atual sistema da reserva de inventário em termos de nível de estoque médio mantido para atender aos clientes preferenciais. O modelo de reposição baseado em previsão, por exemplo, poderia auxiliar a Empresa a gerenciar melhor esses níveis médios de estoque, ao mesmo tempo em que o nível de serviço desejado fosse mantido. Melhorias no sistema de previsão de demanda implicariam automaticamente na melhoria do desempenho do controle de estoque.

O presente trabalho deve ser entendido como um estudo exploratório sobre o problema. No entanto, a metodologia apresentada ao longo deste estudo servirá de base para a realização de uma análise mais extensiva, auxiliando a Empresa na simulação dos resultados que poderão ser obtidos com os modelos avaliados. A partir das simulações dos modelos, a Empresa poderá comparar os resultados previstos com aqueles realmente obtidos. Isso fornecerá subsídios mais concretos para a Empresa decidir sobre a mudança do seu sistema atual de reposição da reserva.

6 CONCLUSÃO

A conclusão deste trabalho se divide em três principais tópicos: uma síntese do problema e da metodologia adotada para sua solução, uma reflexão crítica a respeito das limitações do estudo e, por fim, uma apresentação dos possíveis desdobramentos futuros.

6.1 Síntese

A fim de atender de forma preferencial um grupo de clientes-chave, a Empresa desenvolveu um sistema de reposição de estoque diferenciado. A chamada reserva de inventário tem por objetivo elevar o nível de serviço no atendimento desses clientes. O problema, contudo, é que esse sistema tem trabalhado com níveis médios de estoque muito elevados. Não totalmente satisfeita com a atual situação, a Empresa solicitou um estudo de previsão demanda, que pudesse sinalizar alguma oportunidade de melhoria, ou, até mesmo, a possibilidade de reformulação do atual sistema de reserva de inventário.

A partir do levantamento de referências bibliográficas sobre o tema, decidiu-se estudar mais detalhadamente os possíveis benefícios de um modelo de reposição de estoques baseado em previsão de demanda. Através de análises sobre o comportamento da demanda de um conjunto de SKUs, tomando-se como ponto de partida o CD de SP, o trabalho evidencia o comportamento altamente variável dos dados de *sell-in* da Empresa. Os resultados dos testes de previsão de demanda com esse tipo de dado forneceram erros relativamente elevados, quase todos maiores que 100%. Esse fato, conforme discutido ao longo do trabalho, está relacionado à própria política de vendas da Empresa, que concentra suas vendas mais ao final dos meses, além de forçar vendas para o atingimento das metas comerciais.

Após a etapa de análise do comportamento da demanda, partiu-se para um estudo comparativo de três diferentes modelos de reposição de estoques: reposição diária ou semanal da demanda com base no alvo de vendas mensal (modelo atual) e reposição com base em previsão de demanda (proposição deste trabalho).

Definidos os dois principais indicadores para a comparação dos modelos, nível de serviço e estoque médio no período, a autora elaborou simulações em planilha Excel® para o teste de validade dos modelos. Os resultados dos testes de simulação fornecem indícios de que o modelo de reposição baseado em previsão de demanda, apesar dos ainda elevados

valores dos erros de previsão, consegue reduzir os atuais níveis médios de estoque sem prejuízo do nível de serviço mínimo desejado pela Empresa que é de 95% para seus clientes preferenciais. Contudo, mais do que fornecer uma resolução definitiva para o sistema atual de reposição da reserva de inventário, o presente trabalho propõe uma sistemática que poderá ser seguida pela Empresa para embasar as discussões que tratam da comparação de modelos de reposição para a reserva.

6.2 Limitações

Os testes realizados neste estudo não são suficientemente conclusivos para afirmar que o modelo de reposição baseado em previsão de demanda seja, efetivamente, o mais adequado para todos os 180 SKUs. Seria preciso uma análise mais extensa, envolvendo uma maior variedade de produtos e também com uma quantidade maior de dados. Entretanto, é preciso lembrar que isso não foi possível neste primeiro momento por diversas razões. A primeira delas refere-se à própria limitação interna da TI da Empresa. A etapa de extração de dados demandou um esforço operacional que inviabilizou uma coleta mais abrangente. Vale lembrar que para obter os dados diários, foi preciso exportar a totalidade de pedidos por cliente e por dia durante o período disponível. Outra limitação foi com relação à extensão do período de dados coletado. A abertura de um novo CD gerou uma redistribuição nos volumes de demanda dos demais CDs, limitando a quantidade de dados úteis (tamanho das séries históricas) para análises.

Outro ponto que merece ser lembrado é que a análise se restringe apenas ao funcionamento do sistema da reserva de inventário. De fato, esse sistema é apenas uma parte do sistema de gestão de estoques do CD como um todo. Nos testes realizados, considerou-se que há sempre disponibilidade de estoque no CD para transferência para a reserva. A política de reposição de estoques no CD não estava previsto no presente trabalho.

Durante as análises de previsão de demanda, seria de grande importância ter conhecimento dos eventos que impactaram a demanda. A Empresa não possui nenhum acompanhamento mais sistemático desses fatores, o que também dificulta uma análise de maior qualidade nesse sentido, até mesmo para identificar e tratar os *outliers* das séries históricas.

Por fim, vale ressaltar que, com base na revisão teórica, Os dados de *sell-out* (venda ao consumidor final) devem ser mais previsíveis que o *sell-in* (venda direta). De alguma forma, a reposição de estoques do cliente deveria refletir as vendas de *sell-out*. Todavia, o acesso a esses dados para avaliar a qualidade de previsão também foi limitado pelas restrições do sistema de informação atual da Empresa. Além disso, de pouco adiantaria gerar previsões baseadas na demanda final do consumidor, se as vendas para os clientes direto da Empresa acontecem de forma imprevisível e sujeitas a negociações e eventos que não refletem a real demanda pelo produto.

6.3 Considerações finais

Considera-se que o objetivo inicial do trabalho, que era analisar o sistema atual de reserva de inventário a fim de identificar propostas para encontrar um melhor equilíbrio entre nível de serviço e estoque médio, foi alcançada. Conforme apresentado neste estudo, o modelo de reposição baseado em previsão de demanda mostra-se uma alternativa interessante, fornecendo resultados interessantes nos casos analisados (6 SKUs). A importância das simulações propostas está no fato de que elas auxiliarão nos testes dos modelos antes de uma implementação na prática.

Uma próxima etapa, após a validação dos resultados pelos gerentes responsáveis pelo processo, seria testar efetivamente o funcionamento da reposição da reserva baseada em previsão de demanda, começando-se com um projeto piloto para apenas alguns SKUs. A partir dos resultados alcançados, a Empresa poderia identificar pontos a melhorar nas simulações, por exemplo, e adaptar o modelo para a situação real.

É preciso enfatizar que, por melhor que seja o modelo de reposição escolhido, a reserva de inventário apresentará resultados insatisfatórios, caso a política de vendas da Empresa não seja revista de forma a minimizar os picos de demanda, que acabam induzindo uma elevação do nível médio de estoques. Essa mudança passa por um melhor gerenciamento da demanda, trabalhando em parceria com os clientes de forma a reduzir os impactos negativos que a variabilidade da demanda exerce sobre a cadeia de suprimentos. Nesse sentido, estratégias de colaboração na cadeia de suprimentos, também chamadas de *Collaborative Planning, Forecasting and Replenishment* (CPFR) ganham destaque.

Finalmente, vale ressaltar que o desenvolvimento deste trabalho foi de grande relevância para a confrontação dos conceitos teóricos com as práticas empresariais. Espera-se que o presente estudo contribuía para aproximar essas duas realidades no caso da Empresa analisada.

REFERÊNCIAS

BALLOU, R.H. **Gerenciamento da cadeia de suprimentos: planejamento, organização e logística empresarial**. 5ª ed. Porto Alegre: Bookman, 2004.

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

LEWIS, C. D. **Demand Forecasting and Inventory Control**. New York: John Wiley & Sons, 1997.

LUSTOSA, L. J.; MESQUITA, M. A. de; QUELHAS, O. L. G.; OLIVEIRA, R. J. de. **Planejamento e controle da produção**. Rio de Janeiro: Campus, 2008. ix, 355 p.

MAKRIDAKIS, S.; WHEELWRIGHT, S.C.; McGEE, V.E. **Forecasting: Methods and Applications**. 2nd ed. New York: John Wiley & Sons, 1983.

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

RUSSELL, R.; TAYLOR, B. W. **Operations Management: Quality and Competitiveness in a Global Environment**. 5th ed. New York: John Wiley & Sons, 2006.

SILVER, E.A.; PYKE, D.; PETERSON, R. **Decision Systems for Inventory Management and Production Planning and Scheduling**. 3rd ed. New York: John Wiley & Sons, 1998.

SIMCHI-LEVI, D.; KAMINSKY, P.; SIMCHI-LEVI, E. **Cadeia de suprimentos: Projeto e Gestão** – Conceitos, estratégias e estudos de casos. Porto Alegre: Bookman, 2003.

YURKIEWICZ, J. Forecasting: What Can You Predict for Me? **Operations Research and the Management Sciences Today**, Atlanta, Jun. 2010. Disponível em: < <http://www.lionhrtpub.com/orms/orms-6-10/frsurvey.html> >. Acesso em: 10 ago. 2010.

ANEXO

Concentração média de vendas nas semanas para os SKUs

SKU A

<i>da semana</i>	<i>Dias da semana (meses com 4 semanas)</i>							<i>Representatividade da sem. para o mês</i>
	<i>dom</i>	<i>seg</i>	<i>ter</i>	<i>qua</i>	<i>qui</i>	<i>sex</i>	<i>sáb</i>	
1a sem	0%	3%	1%	0%	4%	0%	0%	9%
2a sem	0%	4%	2%	7%	5%	2%	0%	20%
3a sem	1%	5%	6%	4%	5%	5%	0%	26%
4a sem	0%	2%	7%	4%	12%	19%	0%	45%

<i>da semana</i>	<i>Dias da semana (meses com 5 semanas)</i>							<i>Representatividade da sem. para o mês</i>
	<i>dom</i>	<i>seg</i>	<i>ter</i>	<i>qua</i>	<i>qui</i>	<i>sex</i>	<i>sáb</i>	
1a sem	1%	4%	5%	0%	5%	1%	0%	16%
2a sem	0%	1%	3%	4%	3%	2%	2%	14%
3a sem	0%	2%	4%	3%	6%	1%	0%	16%
4a sem	0%	9%	2%	5%	5%	2%	0%	23%
5a sem	0%	4%	1%	6%	6%	11%	3%	32%

SKU B

<i>da semana</i>	<i>Dias da semana (meses com 4 semanas)</i>							<i>Representatividade da sem. para o mês</i>
	<i>dom</i>	<i>seg</i>	<i>ter</i>	<i>qua</i>	<i>qui</i>	<i>sex</i>	<i>sáb</i>	
1a sem	0%	14%	1%	0%	9%	4%	3%	30%
2a sem	0%	9%	9%	1%	9%	2%	1%	31%
3a sem	0%	2%	4%	0%	6%	1%	0%	14%
4a sem	0%	3%	4%	0%	5%	12%	0%	25%

<i>da semana</i>	<i>Dias da semana (meses com 5 semanas)</i>							<i>Representatividade da sem. para o mês</i>
	<i>dom</i>	<i>seg</i>	<i>ter</i>	<i>qua</i>	<i>qui</i>	<i>sex</i>	<i>sáb</i>	
1a sem	0%	9%	2%	1%	14%	0%	0%	26%
2a sem	1%	1%	1%	1%	17%	0%	0%	21%
3a sem	0%	6%	2%	1%	12%	0%	1%	23%
4a sem	0%	1%	6%	15%	2%	0%	0%	24%
5a sem	0%	0%	3%	1%	0%	1%	0%	6%

SKU D

da semana	Dias da semana (meses com 4 semanas)							Representatividade da sem. para o mês
	dom	seg	ter	qua	qui	sex	sáb	
1a sem	0%	2%	5%	1%	1%	3%	1%	13%
2a sem	0%	3%	3%	3%	8%	6%	0%	24%
3a sem	0%	2%	3%	4%	7%	6%	0%	22%
4a sem	0%	4%	12%	4%	14%	7%	1%	42%

da semana	Dias da semana (meses com 5 semanas)							Representatividade da sem. para o mês
	dom	seg	ter	qua	qui	sex	sáb	
1a sem	0%	2%	3%	1%	2%	0%	1%	10%
2a sem	0%	1%	2%	3%	2%	3%	2%	13%
3a sem	0%	4%	5%	2%	6%	1%	0%	19%
4a sem	0%	3%	10%	2%	9%	6%	0%	29%
5a sem	0%	4%	3%	6%	4%	3%	9%	29%

SKU E

da semana	Dias da semana (meses com 4 semanas)							Representatividade da sem. para o mês
	dom	seg	ter	qua	qui	sex	sáb	
1a sem	0%	2%	2%	1%	3%	1%	0%	9%
2a sem	0%	5%	3%	1%	13%	4%	0%	26%
3a sem	0%	9%	3%	2%	9%	5%	0%	28%
4a sem	0%	4%	3%	5%	17%	8%	0%	36%

da semana	Dias da semana (meses com 5 semanas)							Representatividade da sem. para o mês
	dom	seg	ter	qua	qui	sex	sáb	
1a sem	0%	2%	0%	3%	3%	1%	0%	10%
2a sem	0%	1%	1%	0%	5%	1%	0%	8%
3a sem	0%	5%	3%	1%	13%	4%	0%	25%
4a sem	0%	9%	1%	6%	10%	5%	0%	31%
5a sem	0%	1%	6%	7%	7%	5%	0%	27%

SKU F

da semana	Dias da semana (meses com 4 semanas)							Representatividade da sem. para o mês
	dom	seg	ter	qua	qui	sex	sáb	
1a sem	0%	3%	2%	3%	5%	1%	0%	14%
2a sem	0%	6%	1%	2%	8%	4%	0%	23%
3a sem	2%	6%	3%	1%	5%	2%	0%	20%
4a sem	1%	9%	2%	5%	6%	21%	0%	44%

da semana	Dias da semana (meses com 5 semanas)							Representatividade da sem. para o mês
	dom	seg	ter	qua	qui	sex	sáb	
1a sem	1%	5%	2%	0%	1%	1%	0%	10%
2a sem	0%	3%	2%	2%	3%	1%	6%	16%
3a sem	1%	6%	4%	0%	2%	1%	0%	14%
4a sem	0%	4%	2%	2%	12%	10%	0%	29%
5a sem	0%	11%	8%	2%	2%	2%	6%	31%

Resultados das previsões de demanda para os SKUs

SKU A	Método escolhido	APE	MAPE
Série 1	<i>Seasonal Additive</i>	72%	156%
Série 2	<i>Seasonal Multiplicative</i>	55%	
Série 3	<i>Seasonal Multiplicative</i>	241%	
Série 4	<i>Seasonal Multiplicative</i>	171%	
Série 5	<i>Holt-Winters' Multiplicative</i>	88%	
Série 6	<i>Holt-Winters' Additive</i>	43%	
Série 7	<i>Seasonal Multiplicative</i>	18%	
Série 8	<i>Seasonal Additive</i>	31%	
Série 9	<i>Seasonal Multiplicative</i>	69%	
Série 10	<i>Holt-Winters' Multiplicative</i>	1079%	
Série 11	<i>Holt-Winters' Multiplicative</i>	3%	
Série 12	<i>Holt-Winters' Multiplicative</i>	5%	

SKU B	Método escolhido	APE	MAPE
Série 1	<i>Holt-Winters' Additive</i>	2269%	376%
Série 2	<i>Holt-Winters' Additive</i>	114%	
Série 3	<i>Seasonal Additive</i>	10%	
Série 4	<i>Holt-Winters' Additive</i>	49%	
Série 5	<i>Holt-Winters' Additive</i>	531%	
Série 6	<i>Holt-Winters' Additive</i>	706%	
Série 7	<i>Seasonal Multiplicative</i>	91%	
Série 8	<i>Seasonal Additive</i>	45%	
Série 9	<i>Seasonal Multiplicative</i>	479%	
Série 10	<i>Seasonal Multiplicative</i>	31%	
Série 11	<i>Single Exponential Smoothing</i>	18%	
Série 12	<i>Seasonal Multiplicative</i>	161%	

SKU C	Método escolhido	APE	MAPE
Série 1	<i>Holt-Winters' Multiplicative</i>	630%	179%
Série 2	<i>Holt-Winters' Multiplicative</i>	80%	
Série 3	<i>Seasonal Multiplicative</i>	19%	
Série 4	<i>Seasonal Multiplicative</i>	25%	
Série 5	<i>Holt-Winters' Additive</i>	50%	
Série 6	<i>Holt-Winters' Additive</i>	27%	
Série 7	<i>Seasonal Multiplicative</i>	821%	
Série 8	<i>Single Exponential Smoothing</i>	64%	
Série 9	<i>Seasonal Multiplicative</i>	37%	
Série 10	<i>Seasonal Multiplicative</i>	306%	
Série 11	<i>Seasonal Multiplicative</i>	58%	
Série 12	<i>Holt-Winters' Multiplicative</i>	25%	

SKU D	Método escolhido	APE	MAPE
Série 1	<i>Holt-Winters' Additive</i>	89%	133%
Série 2	<i>Seasonal Additive</i>	144%	
Série 3	<i>Seasonal Additive</i>	43%	
Série 4	<i>Seasonal Additive</i>	133%	
Série 5	<i>Holt-Winters' Additive</i>	234%	
Série 6	<i>Holt-Winters' Additive</i>	160%	
Série 7	<i>Seasonal Multiplicative</i>	96%	
Série 8	<i>Holt-Winters' Multiplicative</i>	17%	
Série 9	<i>Single Exponential Smoothing</i>	545%	
Série 10	<i>Holt-Winters' Multiplicative</i>	23%	
Série 11	<i>Seasonal Additive</i>	39%	
Série 12	<i>Single Exponential Smoothing</i>	67%	

SKU E	Método escolhido	APE	MAPE
Série 1	<i>Single Moving Average</i>	4600%	668%
Série 2	<i>Seasonal Additive</i>	104%	
Série 3	<i>Seasonal Additive</i>	84%	
Série 4	<i>Seasonal Additive</i>	35%	
Série 5	<i>Holt-Winters' Multiplicative</i>	1276%	
Série 6	<i>Single Exponential Smoothing</i>	535%	
Série 7	<i>Single Moving Average</i>	92%	
Série 8	<i>Seasonal Additive</i>	58%	
Série 9	<i>Seasonal Multiplicative</i>	1167%	
Série 10	<i>Seasonal Additive</i>	28%	
Série 11	<i>Seasonal Additive</i>	22%	
Série 12	<i>Holt-Winters' Additive</i>	18%	

Tabela 23: Tabela utilizada para os cálculos e testes dos resultados de previsão de demanda gerados pelo software Crystal Ball® para o SKU D

	Série 1	Série 2	Série 3	Série 4	Série 5	Série 6	...	Série 10	Série 11	Série 12	Série 13
Horizonte de tempo da série	1a semAbr 09 - 1a semAbr 09 - 5a semMar 10	1a semAbr 09 - 1a semAbr 09 - 1a semAbr 10	1a semAbr 09 - 1a semAbr 09 - 2a semAbr 10	1a semAbr 09 - 1a semAbr 09 - 3a semAbr 10	1a semAbr 09 - 1a semAbr 09 - 4a semAbr 10	1a semAbr 09 - 1a semAbr 09 - 1a semMai 10	...	1a semAbr 09 - 1a semJul 10	1a semAbr 09 - 2a semJul 10	1a semAbr 09 - 3a semJul 10	1a semAbr 09 - 4a semJul 10
Total de semanas na série	52	53	54	55	56	57	...	61	62	63	64
Base de dados utilizada pelo Crystal Ball®											
											174
										174	327
									174	327	542
								174	327	542	14
							...	327	542	14	336
							...	542	14	336	713
						174	...	244	520	98	1692
					174	327	...	520	98	1692	290
				174	327	542	...	98	1692	290	198
		174	327	542	14	336	...	1692	290	198	633
174		327	542	14	336	713	...	290	198	633	547
327		542	14	336	713	651	...	198	633	547	682
...		...	...	...	...	...	...	633	547	682	355
161		475	971	164	854	854	...	...	...	...	...
971		164	854	854	924	279	...	366	1192	173	415
	1a semAbr 10	2a semAbr 10	3a semAbr 10	4a semAbr 10	1a semMai 10	1a semJun 10	...	2a semJul 10	3a semJul 10	4a semJul 10	1a semAgo 10
Período que se deseja prever	1a semAbr 10	2a semAbr 10	3a semAbr 10	4a semAbr 10	1a semMai 10	1a semJun 10	...	2a semJul 10	3a semJul 10	4a semJul 10	1a semAgo 10
Previsão CB	336,6933315	765,1051171	43,40200069	585,2965581	467,5748251	283,6698758	...	326,314156	351,4715313	435,9651175	
Real	164	854	854	924	279	240	...	415	458	773	
PE	105%	10%	95%	37%	68%	18%	...	21%	23%	44%	