

**UNIVERSIDADE DO VALE DO RIO DOS SINOS**  
**CIÊNCIAS EXATAS E TECNOLÓGICAS**  
**PROGRAMA INTERDISCIPLINAR DE PÓS-GRADUAÇÃO**  
**EM COMPUTAÇÃO APLICADA – PIPCA**  
**NÍVEL MESTRADO**

FERNANDO GROMOWSKI ARTMANN

**Otimização de Níveis de Estoque de uma Rede  
Varejista através do uso de Modelos Previsores,  
Simulação Discreta Determinística e Metaheurísticas**

São Leopoldo

2011

FERNANDO GROMOWSKI ARTMANN

**Otimização de Níveis de Estoque de uma Rede  
Varejista através do uso de Modelos Previsores,  
Simulação Discreta Determinística e Metaheurísticas**

Dissertação de mestrado apresentada como requisito parcial para obtenção do título de Mestre pelo programa de Pós-Graduação em Computação Aplicada da Universidade do Vale do Rio dos Sinos.

Orientador: Prof. Dr. Leonardo Dagnino Chiwiacowsky

São Leopoldo

2011

A791o Artmann, Fernando Gromowski  
Otimização de níveis de estoque de uma rede varejista através do uso de modelos previsores, simulação discreta determinística e metaheurísticas / Fernando Gromowski Artmann. -- 2011.  
171 f. : il. ; 30cm.

Dissertação (mestrado) -- Universidade do Vale do Rio dos Sinos. Programa de Pós-Graduação em Computação Aplicada, São Leopoldo, RS, 2011.

Orientador: Prof. Dr. Leonardo Dagnino Chiwiacowsky.

1. Computação aplicada. 2. Estoque - Otimização de níveis. 3. Gerenciamento - Cadeia de suprimento. 4. Demanda - Previsão. 5. Guided Local Search. I. Título. II. Chiwiacowsky, Leonardo Dagnino.

CDU 004

Catálogo na Publicação:  
Bibliotecário Eliete Mari Doncato Brasil - CRB 10/1184

*Dedico este trabalho à minha família, em especial a meus pais, Maria e Cláudio. Se hoje cheguei aqui, foi devido ao apoio incondicional de vocês, sempre. Dedico este trabalho também à minha noiva Paloma, pelo apoio e compreensão dados durante seu desenvolvimento.*

## **AGRADECIMENTOS**

Gostaria de agradecer, primeiramente, ao professor Dr. Leonardo Dagnino Chiwiacowsky, orientador acadêmico e da dissertação, pelo apoio dispensado ao desenvolvimento deste trabalho. Meus sinceros agradecimentos. Espero um dia conseguir retribuir.

Agradeço ainda ao professor Dr. José Vicente Canto dos Santos pelo incentivo dado para o ingresso no mestrado, no final da minha graduação.

Também agradeço à Unisinos e ao corpo docente do PIPCA, por impulsionar meu desenvolvimento durante os dois anos do mestrado. O salto foi imenso.

Este trabalho foi desenvolvido com o apoio da CAPES.

## RESUMO

Em um contexto empresarial, a competitividade entre companhias de um mesmo ramo de atividade se torna mais presente a cada dia que passa. Empresas estruturadas de forma enxuta em termos de custo podem ter maior vantagem competitiva sobre seus concorrentes. Reduzir custos é, portanto, um objetivo almejado por todas as organizações.

A gestão e controle de estoques de produtos é um problema presente em diversas empresas e organizações. Diversos custos estão associados a este problema. O volume monetário relacionado é bastante grande. Assim, quanto melhor for o processo de controle e gerenciamento de estoques de uma empresa, menor será o custo para manutenção dos mesmos.

Este trabalho propõe uma ferramenta para otimização dos níveis de estoque de uma rede varejista, considerando características como lucratividade, custos e atendimentos às demandas. Isto é feito através do uso de um método previsor baseado em Suavização Exponencial com Sazonalidade Multiplicativa, um módulo Otimizador baseado na metaheurística *Guided Local Search*, além de um Simulador Discreto Determinístico. A ferramenta conta com uma série de parâmetros que permitem a criação de diferentes cenários relativos ao sistema de estocagem da rede varejista.

Os resultados obtidos durante a fase de experimentação da ferramenta demonstram sua capacidade de encontrar soluções para o problema de níveis de estoque de forma satisfatória, além de possibilitar a criação de cenários alternativos à realidade observada no sistema físico.

**Palavras chave:** Otimização de Níveis de Estoque, Previsão de Demandas, Otimização da Simulação, *Guided Local Search*, Suavização Exponencial.

## ABSTRACT

Competitiveness is an element that increases on a daily basis considering nowadays businesses. Companies with more efficient structures in terms of costs have an important advantage when compared to their competitors. This greatly motivates companies to reduce costs.

Inventory control is an existing problem in many companies and organizations. Many types of costs are associated to this problem. Also, the amount of money involved in inventory maintenance is very considerable. So, the better the inventory control process is, the lower the costs related to it will be.

This paperwork proposes a tool to optimize inventory levels on a retailer company, considering profit, costs and service level attendance. This is done by using a Forecasting Method called Exponential Smoothing with Multiplicative Seasonality, an Optimizer based on the Guided Local Search metaheuristic and a Discrete Deterministic Simulator. This tool uses a series of parameters in order to allow users to create different scenarios.

The results obtained with the conducted experiments show that the tool is capable of finding good solutions to the problem of inventory levels, as well as creating alternative scenarios to operate the inventory system.

**Keywords:** Inventory Level Optimization, Sales Forecasting, Simulation Optimization, Guided Local Search, Exponential Smoothing.

## LISTA DE FIGURAS

|   |     |
|---|-----|
| Figura 2.1 – Passos para a criação de um projeto de simulação .....                                   | 49  |
| Figura 2.2 – Fluxograma de um simulador .....   | 51  |
| Figura 2.3 – Esquema geral do algoritmo <i>Guided Local Search</i> (GLS).....                         | 60  |
| Figura 2.4 – Esquema de funcionamento da Otimização da Simulação .....                                | 62  |
| Figura 4.1 – Disposição dos dados e exemplo de produto não pertencente<br>ao <i>mix</i> da loja ..... | 75  |
| Figura 4.2 – Diagrama geral da ferramenta desenvolvida.....   | 78  |
| Figura 4.3 – Solução para o problema de Reposição de Estoques.....                                    | 85  |
| Figura 4.4 – Espaço tridimensional que representa as entidades<br>envolvidas no simulador .....       | 91  |
| Figura 4.5 – Funcionamento do Simulador .....   | 92  |
| Figura 4.6 – Atributos ou PREs alternativas para o problema com um<br>produto e uma loja.....         | 108 |
| Figura 4.7 – Atributos ou PREs alternativas para o problema com<br>dois produtos e uma loja .....     | 109 |
| Figura 4.8 – Estrutura do algoritmo desenvolvido no trabalho .....                                    | 128 |
| Figura 4.9 – Rotinas de Geração de Soluções vizinhas integradas<br>ao módulo simulador .....          | 129 |
| Figura 5.1 – Análise do indicador MAPE da categoria de produtos 18 .....                              | 133 |
| Figura 5.2 – Demanda observada do produto da categoria 7 em seu<br>primeiro ano.....                  | 134 |

## LISTA DE FIGURAS (continuação)

|  |     |
|--|-----|
| Figura 5.3 – Demanda observada e prevista do produto da categoria 7 em seu segundo ano ..... | 134 |
| Figura 5.4 – Evolução da FO para cada iteração – Experimento 1 .....                         | 145 |
| Figura 5.5 – Evolução da FO para cada iteração – Experimento 2 .....                         | 147 |
| Figura 5.6 – Evolução da FO para cada iteração – Experimento 3 .....                         | 149 |
| Figura 5.7 – Evolução da FO para cada iteração – Experimento 4 .....                         | 151 |
| Figura 5.8 – Evolução da FO para cada iteração – Experimento 5 .....                         | 154 |
| Figura 5.9 – Evolução da FO para cada iteração – Experimento 6 .....                         | 156 |
| Figura 5.10 – Evolução da FO para cada iteração – Experimento 7 .....                        | 158 |
| Figura 5.11 – Evolução da FO para cada iteração – Experimento 8 .....                        | 161 |

## LISTA DE TABELAS

|  |     |
|--|-----|
| Tabela 4.1 – Cadastro de Produtos.....   | 76  |
| Tabela 4.2 – Exemplo de saída do módulo previsor com a Lista de<br>Eventos de Demanda..... | 82  |
| Tabela 4.3 – Política de Reposição de Estoques (PRE) .....                                 | 83  |
| Tabela 4.4 – Avaliação dos dados para verificação de reposição do<br>estoque .....         | 87  |
| Tabela 4.5 – Parâmetros do Simulador.....  | 93  |
| Tabela 4.6 – Parâmetros do Otimizador.....   | 103 |
| Tabela 4.7 – Probabilidades de escolha das estratégias de geração de<br>vizinhança .....   | 105 |
| Tabela 4.8 – Representação da Solução do Problema para uma loja e<br>dois produtos.....    | 110 |
| Tabela 4.9 – Representação da Solução do Problema para duas lojas e<br>dois produtos.....  | 111 |
| Tabela 4.10 – Solução Alternativa do Problema para duas lojas e dois<br>produtos .....     | 111 |
| Tabela 4.11 – PRE antes da Divisão do Evento com Maior Reposição .....                     | 116 |
| Tabela 4.12 – PRE após da Divisão do Evento com Maior Reposição .....                      | 116 |
| Tabela 4.13 – PRE antes da Remoção Aleatória de Evento de<br>Reposição .....               | 117 |
| Tabela 4.14 – PRE após a Remoção Aleatória de Evento de Reposição .....                    | 118 |
| Tabela 4.15 – PRE antes da Variação Uniforme na Quantidade<br>Reposta.....                 | 119 |

## LISTA DE TABELAS (continuação)

|  |     |
|--|-----|
| Tabela 4.16 – PRE após a Variação Uniforme na Quantidade Reposta .....                             | 119 |
| Tabela 4.17 – PRE antes da Variação Singular na Quantidade Reposta .....                           | 120 |
| Tabela 4.18 – PRE após a Variação Singular na Quantidade Reposta .....                             | 121 |
| Tabela 4.19 – PRE antes da Inserção Aleatória de Evento de<br>Reposição .....                      | 122 |
| Tabela 4.20 – PRE após a Inserção Aleatória de Evento de Reposição.....                            | 122 |
| Tabela 4.21 – PRE antes da Distribuição Uniforme da Quantidade<br>Reposta.....                     | 123 |
| Tabela 4.22 – PRE após a aplicação da Distribuição Uniforme da<br>Quantidade Reposta .....         | 124 |
| Tabela 4.23 – PRE antes da aplicação da Distribuição Local da<br>Quantidade Reposta .....          | 125 |
| Tabela 4.24 – PRE antes da aplicação da Distribuição Local da<br>Quantidade Reposta .....          | 125 |
| Tabela 4.25 – Parâmetros Gerais da Ferramenta.....   | 126 |
| Tabela 5.1 – Parâmetros para o módulo previsor .....   | 131 |
| Tabela 5.2 – Avaliação do indicador MAPE frente aos dados obtidos no<br>processo de previsão ..... | 132 |
| Tabela 5.3 – Parâmetros utilizados nos Experimentos dos Problemas<br>da Instância IP1 .....        | 139 |
| Tabela 5.4 – Parâmetros utilizados nos Experimentos dos Problemas<br>da Instância IP2 .....        | 140 |
| Tabela 5.5 – Parâmetros utilizados nos Experimentos dos Problemas<br>da Instância IP3 .....        | 141 |

## LISTA DE TABELAS (continuação)

|   |     |
|---|-----|
| Tabela 5.6 – Parâmetros da ferramenta comuns a todos os experimentos..... | 142 |
| Tabela 5.7 – Características do Experimento 1.....                        | 144 |
| Tabela 5.8 – Resultados do Experimento 1.....                             | 145 |
| Tabela 5.9 – Características do Experimento 2.....                        | 146 |
| Tabela 5.10 – Resultados do Experimento 2.....                            | 147 |
| Tabela 5.11 – Resultados do Experimento 3.....                            | 148 |
| Tabela 5.12 – Resultados do Experimento 4.....                            | 150 |
| Tabela 5.13 – Resultados do Experimento 5.....                            | 153 |
| Tabela 5.14 – Resultados do Experimento 6.....                            | 155 |
| Tabela 5.15 – Resultados do Experimento 7.....                            | 157 |
| Tabela 5.16 – Resultados do Experimento 8.....                            | 160 |

## LISTA DE ABREVIATURAS

|               |   |
|---------------|---|
| <b>ACO</b>    | <i>Ant Colony Optimization</i>  |
| <b>AG</b>     | Algoritmo Genético  |
| <b>AR</b>     | <i>Autoregressive model</i>   |
| <b>ARIMA</b>  | <i>Autoregressive Integrated Moving Average Model</i>                 |
| <b>CGE</b>    | Custo Global de Estocagem   |
| <b>CS</b>     | Cadeia de Suprimentos   |
| <b>CTE</b>    | Custo Total de Estocagem  |
| <b>DAN2</b>   | <i>Dynamic Artificial Neural Network</i>                              |
| <b>DAN2-H</b> | <i>Dynamic Artificial Neural Network</i> Híbrida com Série de Fourier |
| <b>DP</b>     | Demanda Prevista  |
| <b>ER</b>     | Evento de Reposição   |
| <b>ES</b>     | <i>Exponential Smoothing</i>  |
| <b>FO</b>     | Função Objetivo   |
| <b>FOA</b>    | Função Objetivo Aumentada   |
| <b>GCS</b>    | Gerenciamento da Cadeia de Suprimentos                                |
| <b>GLS</b>    | <i>Guided Local Search</i>  |
| <b>GMROI</b>  | <i>Gross Margin Return On Investment</i>                              |
| <b>HIP</b>    | <i>Hybrid Inventory-Production</i>                                    |
| <b>IA</b>     | Inteligência Artificial   |
| <b>IES</b>    | Indicador de Eficiência do Sistema                                    |
| <b>IR</b>     | Intervalo de Reposição  |
| <b>IRT</b>    | Intervalo de Reposição Total  |
| <b>JIT</b>    | <i>Just In Time</i>   |
| <b>LBV</b>    | Lucro Bruto sobre Vendas  |
| <b>LED</b>    | Lista de Eventos de Demanda   |
| <b>LGV</b>    | Lucro Global sobre Vendas   |
| <b>LT</b>     | Intervalo Mínimo entre Eventos de Reposição/ <i>Leadtime</i>          |
| <b>MA</b>     | <i>Moving Average</i>   |
| <b>MAE</b>    | <i>Mean Absolute Error</i>  |
| <b>MAPE</b>   | <i>Mean Absolute Percentage Error</i>                                 |

## LISTA DE ABREVIATURAS (continuação)

|               |   |
|---------------|---|
| <b>MIT</b>    | <i>Massachusetts Institute of Technology</i>                |
| <b>MLP</b>    | <i>Multiple Layer Perceptron</i>                            |
| <b>MM</b>     | Média Móvel   |
| <b>MMFI</b>   | Margem sobre Montante Financeiro Investido                  |
| <b>MMQ</b>    | Método dos Mínimos Quadrados                                |
| <b>MSE</b>    | <i>Mean-squared Error</i>                                   |
| <b>PA</b>     | <i>Pool</i> de Atributos                                    |
| <b>PE</b>     | <i>Percentage Error</i>                                     |
| <b>PIR</b>    | Penalização Individual do Intervalo mínimo entre Reposições |
| <b>PNSA</b>   | Percentual de Nível de Serviço Individual Apurado           |
| <b>PNSGA</b>  | Percentual de Nível de Serviço Global Apurado               |
| <b>PNSE</b>   | Percentual de Nível de Serviço Individual Exigido           |
| <b>PNSGME</b> | Percentual de Nível de Serviço Global Mínimo Exigido        |
| <b>PRE</b>    | Política de Reposição de Estoques                           |
| <b>PRV</b>    | Problema de Roteamento de Veículos                          |
| <b>QOR</b>    | Quantidade de Ocorrências de Ruptura                        |
| <b>RBF</b>    | Função de Base Radial                                       |
| <b>RFG</b>    | Resultado Financeiro Global                                 |
| <b>RG</b>     | Ruptura Global  |
| <b>RE</b>     | Ruptura de Estoque  |
| <b>RI</b>     | Penalização por Ruptura Individual                          |
| <b>RNA</b>    | Rede Neural Artificial                                      |
| <b>RNA-H</b>  | Rede Neural Artificial Híbrida com Série de Fourier         |
| <b>RV</b>     | Ruptura de Venda  |
| <b>SA</b>     | <i>Simulated Annealing</i>                                  |
| <b>SC</b>     | <i>Supply Chain</i>   |
| <b>SCM</b>    | <i>Supply Chain Management</i>                              |
| <b>SE</b>     | Suavização Exponencial                                      |
| <b>SR</b>     | Solução de Reposição  |
| <b>SS</b>     | <i>Scatter Search</i>                                       |
| <b>ST</b>     | Série Temporal  |

## LISTA DE ABREVIATURAS (continuação)

|            |                                     |
|------------|-------------------------------------|
| <b>TS</b>  | <i>Tabu Search</i>                  |
| <b>TSH</b> | Heurística <i>two-step hybrid</i>   |
| <b>UM</b>  | Unidade Monetária                   |
| <b>VNS</b> | <i>Variable Neighborhood Search</i> |

## SUMÁRIO

|   |    |
|---|----|
| 1 Introdução .....  | 18 |
| 2 Fundamentação Teórica.....  | 21 |
| 2.1 Gerenciamento da Cadeia de Suprimentos.....   | 21 |
| 2.2 Problemas relacionados a Estoques: Níveis de Estoque, Ruptura<br>de Venda e Ruptura de Estoque..... | 22 |
| 2.3 Efeito Chicote .....  | 27 |
| 2.4 Previsão de Demandas .....  | 27 |
| 2.4.1 Tipos de Previsão .....   | 29 |
| 2.4.2 Métodos Previsores .....  | 31 |
| 2.4.2.1 Séries Temporais e Análise de Regressão .....   | 32 |
| 2.4.2.2 Média Móvel.....  | 33 |
| 2.4.2.3 Autoregressive Integrated Moving Average Model.....   | 33 |
| 2.4.2.4 Redes Neurais Artificiais .....   | 34 |
| 2.4.2.5 Suavização Exponencial .....  | 35 |
| 2.4.3 Considerações sobre modelos de previsão .....   | 42 |
| 2.5 Simulação.....  | 43 |
| 2.5.1 Estratégias de Modelagem e Variáveis de Estado .....  | 43 |
| 2.5.2 Servidor .....  | 44 |
| 2.5.3 Eventos.....  | 45 |
| 2.5.4 Relógio de Simulação.....   | 46 |
| 2.5.5 Contadores Estatísticos e Indicadores de Desempenho .....   | 46 |

|   |    |
|---|----|
| 2.5.6 Distribuições de Probabilidade, Tipos de Simulação e Cenários Alternativos..... | 47 |
| 2.5.7 Projeto de Simulação e Simulador Computacional.....                             | 48 |
| 2.5.8 Vantagens e Desvantagens do uso de Simulação .....                              | 52 |
| 2.6 Otimização Combinatória .....   | 53 |
| 2.7 Metaheurísticas .....   | 55 |
| 2.7.1 Metaheurística <i>Guided Local Search</i> .....                                 | 57 |
| 2.8 Otimização da Simulação .....   | 60 |
| 3 Revisão Bibliográfica.....  | 63 |
| 3.1 Métodos Previsores e Previsão de Demanda.....                                     | 63 |
| 3.2 Otimização de Níveis de Estoque.....  | 67 |
| 3.3 Otimização da Simulação .....   | 70 |
| 4 Metodologia.....  | 73 |
| 4.1 Provedor dos dados.....   | 73 |
| 4.2 Problema de Otimização de Níveis de Estoque .....                                 | 74 |
| 4.3 Disposição dos Dados Históricos .....   | 75 |
| 4.4 Ajustes e Preparação dos Dados Observados .....                                   | 77 |
| 4.5 Objetivos do trabalho.....  | 77 |
| 4.5.1 Objetivo Geral.....   | 78 |
| 4.5.2 Módulo de Previsão de Vendas .....  | 79 |
| 4.5.3 Codificação da Solução do Problema.....   | 83 |
| 4.5.4 Gerador de Política de Reposição Inicial.....                                   | 86 |

|         |   |     |
|---------|---|-----|
| 4.5.4.1 | Determinação da Atual Política de Reposição de Estoques ....                    | 86  |
| 4.5.4.2 | Geração de Políticas de Reposição de Estoque para Demandas<br>Previstas .....   | 88  |
| 4.5.5   | Simulador.....  | 89  |
| 4.5.5.1 | Parâmetros do Simulador.....  | 92  |
| 4.5.6   | Processo de Otimização de Níveis de Estoques .....                              | 93  |
| 4.5.6.1 | Modelagem Matemática do Problema e Função Objetivo.....                         | 94  |
| 4.5.6.2 | Parâmetros do Otimizador.....   | 102 |
| 4.5.7   | Codificação do Problema no Modelo da Metaheurística Guided<br>Local Search..... | 106 |
| 4.5.8   | Estratégias de Geração de Vizinhança.....                                       | 114 |
| 4.5.8.1 | Estratégia de Divisão do Evento com Maior Reposição .....                       | 115 |
| 4.5.8.2 | Estratégia de Remoção Aleatória de Evento de Reposição ...                      | 117 |
| 4.5.8.3 | Estratégia de Variação Uniforme na Quantidade Reposta.....                      | 118 |
| 4.5.8.4 | Estratégia de Variação Singular na Quantidade Reposta .....                     | 120 |
| 4.5.8.5 | Estratégia de Inserção Aleatória de Evento de Reposição ....                    | 121 |
| 4.5.8.6 | Estratégia de Distribuição Uniforme da Quantidade Reposta                       | 123 |
| 4.5.8.7 | Estratégia de Distribuição Local da Quantidade Reposta .....                    | 124 |
| 4.5.9   | Parâmetros Gerais da Ferramenta .....   | 126 |
| 4.5.10  | Estrutura Geral do Algoritmo Implementado.....                                  | 127 |
| 5       | Experimentos, Resultados e Validação .....                                      | 130 |
| 5.1     | Previsor de Demandas .....  | 130 |
| 5.2     | Validação do Simulador e Gerador de Política de Reposição<br>Inicial.....       | 136 |
| 5.2.1   | Simulação Baseada em Demandas Observadas .....                                  | 137 |

|   |     |
|---|-----|
| 5.2.2 Simulação Baseada em Demandas Previstas.....                                  | 137 |
| 5.3 Otimizador de Níveis Estoques .....   | 138 |
| 5.3.1 Experimento 1 - Demanda Diária Constante .....                                | 143 |
| 5.3.2 Experimento 2 - Demanda Cíclica Constante.....                                | 146 |
| 5.3.3 Experimento 3 - Demandas Diária Constante e Cíclica<br>Constante.....         | 148 |
| 5.3.4 Experimento 4 - Demandas Previstas e Reposição para<br>Atendimento Total..... | 149 |
| 5.3.5 Experimento 5 - Demandas Previstas Reduzidas.....                             | 152 |
| 5.3.6 Experimento 6 - Demandas Previstas com Redução do Lucro<br>Unitário.....      | 155 |
| 5.3.7 Experimento 7 - Demandas Previstas com Relaxamento das<br>Restrições .....    | 157 |
| 5.3.8 Experimento 8 - Problema Completo da Rede Varejista .....                     | 159 |
| 5.4 Resumo sobre os Experimentos.....   | 162 |
| 5.5 Plataforma de Desenvolvimento e de Condução de Experimentos .....               | 163 |
| 6 Conclusões.....   | 164 |
| BIBLIOGRAFIA .....  | 167 |

## 1 Introdução

Quando um consumidor entra em uma loja ou supermercado, ele busca um ou mais itens dos quais necessita, sejam eles produtos alimentícios, de limpeza, eletrodomésticos, bebidas, utensílios, entre diversos outros. É esperado que, ao sair do local de compras, todas as demandas deste consumidor tenham sido supridas. Para que isto ocorra, diversos processos são executados e controles são verificados. Desde a produção do item, na planta fabril, onde todos os insumos e matérias-primas necessárias devem ser supridas, passando pelos meios de distribuição, como redes atacadistas ou centrais de distribuição, chegando ao comércio varejista, onde o consumidor final terá acesso aos produtos.

Os diversos componentes desta grande cadeia, chamada Cadeia de Suprimentos (CS), traduzida do inglês, *Supply Chain* (SC), precisam trabalhar alinhados para seu correto funcionamento. Dentro desta idéia, o Gerenciamento da Cadeia de Suprimentos (GCS), do termo em inglês *Supply Chain Management* (SCM), trata de cuidar dos processos e dos componentes nos diversos níveis do sistema.

A necessidade de manutenção de estoques de produtos está presente em vários componentes de uma CS. Esta característica pode gerar custos elevados, visto que, quanto maior o estoque, maior o montante financeiro investido nos próprios produtos e em espaço físico para estocagem (HILLIER; LIEBERMAN, 2001). Desta forma, a utilização de níveis apropriados de estoque é imprescindível para a viabilidade econômica das empresas componentes da CS e, conseqüentemente, da própria cadeia. Tendo menores custos é possível acirrar a concorrência e disputar e conquistar um número cada vez maior de consumidores. Isto significa dizer que, desde sua produção até a aquisição por parte do consumidor final, é preciso atentar para a melhor política de estoques possível. Segundo Ballou (BALLOU, 1998), o custo total envolvido na estocagem de um produto dentro de toda a Cadeia de Suprimentos representa entre 20% e 40% do seu valor final. Sabendo disto, qualquer melhoria obtida neste índice pode representar uma

economia de milhares, até mesmo milhões, em termos monetários, para os componentes da Cadeia de Suprimentos e para o consumidor final.

A dificuldade em tratar do problema envolvido na reposição de estoques de produtos é justamente definir quando as reposições ocorrerão e quantas unidades devem ser repostas. Considerando o caso específico de uma rede varejista que conta com centenas de pontos de venda que comercializam milhares de produtos, o problema toma uma dimensão onde encontrar a solução exata para o problema torna-se inviável com o uso de métodos exatos. Para resolver este problema, é necessária a utilização de um método aproximativo que seja capaz de encontrar soluções boas o suficiente para que sejam empregadas.

Este trabalho tem como Objetivo Geral propor um modelo para otimização de níveis de estoque de uma rede varejista, considerando as demandas pelos diversos produtos oferecidos em seus diversos pontos de venda, de forma a atender às necessidades dos consumidores e fazendo um balanceamento entre os custos de estocagem e os lucros obtidos com as vendas. Para atingir este objetivo, alguns passos intermediários, denominados Objetivos Específicos, devem ser cumpridos. Tais objetivos são:

- a) desenvolver um módulo para obtenção de previsões de demanda através do uso do modelo de Suavização Exponencial com Sazonalidade Multiplicativa. Ter uma idéia razoável das demandas dos produtos é o primeiro passo para evitar excessos ou faltas de produtos em estoque;
- b) desenvolver um módulo de Simulação Discreta Determinística capaz de reproduzir o comportamento do sistema de estocagem da rede varejista, visando avaliar o comportamento do sistema de estocagem com base em uma política de reposição de estoques e uma previsão de demandas. Este módulo também deve permitir a geração de cenários alternativos, diferentes do observado no sistema real, através do emprego de parâmetros específicos;
- c) desenvolver um módulo otimizador baseado na metaheurística *Guided Local Search*, capaz de sugerir diferentes políticas para reposição de estoques dos produtos através do emprego de diferentes estratégias. Este

módulo também deve ser capaz de avaliar a qualidade das políticas de reposição sugeridas;

- d) desenvolver um módulo capaz de gerar políticas de reposição iniciais viáveis, permitindo que estas sejam utilizadas pelo módulo otimizador como ponto inicial de busca por políticas de melhor qualidade.

Estes módulos integrados compõem a ferramenta criada durante o desenvolvimento deste trabalho.

Durante a fase de experimentação, os resultados obtidos com o uso da ferramenta desenvolvida buscarão demonstrar que ela é capaz de prever as demandas dos produtos segundo o comportamento observado em períodos anteriores. Ainda, o processo de otimização, com o auxílio do módulo de simulação, deverá ser capaz de sugerir e avaliar a qualidade de novas políticas de reposição. Espera-se que as políticas de reposição sugeridas pelo otimizador atinjam resultados superiores aos obtidos com as políticas de reposição iniciais.

Este trabalho está dividido da seguinte forma: após a Introdução, capítulo 1, é apresentada a Fundamentação Teórica, capítulo 2, trazendo os conceitos relacionados ao trabalho. No capítulo 3 é feita a Revisão Bibliográfica, seguida da Metodologia a ser aplicada, no capítulo 4. Os Experimentos, Resultados e Validação se encontram no capítulo 5. No capítulo 6 são apresentadas as conclusões obtidas durante o desenvolvimento do trabalho.

## **2 Fundamentação Teórica**

Neste capítulo serão apresentados os conceitos necessários para o desenvolvimento do presente trabalho, bem como para um melhor entendimento por parte do leitor.

### **2.1 Gerenciamento da Cadeia de Suprimentos**

Cadeia de Suprimentos é um conjunto de entidades e processos que engloba todos os esforços envolvidos nas atividades empresariais visando criar valor na forma de produtos ou serviços (ou ambos) para o consumidor final. É também uma forma integrada de planejar e controlar o fluxo das mercadorias, desde o primeiro fornecedor até o consumidor final, envolvendo todas as organizações participantes da CS.

Dentro deste contexto, o papel do Gerenciamento da Cadeia de Suprimentos (GCS) é justamente o de controlar todos os processos, organizações, pessoas, bens e serviços envolvidos na Cadeia de Suprimentos. Algumas atividades envolvidas no GCS são o Gerenciamento da Oferta e da Demanda, Gerenciamento de Insumos e Matérias-primas, Gerenciamento de Processos de Manufatura, Controle de Estoques e Pedidos e Logística de Materiais (CHOPRA; MEINDL, 2008).

Tais conceitos são relativamente novos. Com início nos anos 70, as idéias a respeito de CS e GCS vêm evoluindo desde então. A motivação para isto gira em torno de maiores exigências por parte dos consumidores, que necessitam de rápidas respostas em relação à redução de custos e atendimento de suas demandas. Empresas focadas nestes aspectos buscam constante redução de custos para

oferecer bens e serviços de qualidade com preços mais baixos, acirrando a concorrência, uma vez que, por estarem em um mesmo nicho de mercado, devem ser competitivas entre si ou estarão obrigadas ao encerramento de suas atividades.

Levando estes aspectos em consideração, integrar as diversas empresas que fazem parte de uma mesma cadeia é benéfico para todos. Portanto, planejar e controlar os processos e componentes de forma conjunta dá condições às empresas de planejar sua produção, diminuindo as chances de atrasos em entregas. Por exemplo, considere uma cadeia com cinco empresas, onde o produto final de uma é matéria-prima em outra. Se a primeira empresa atrasar suas entregas, é bem possível que a última também tenha problemas com atrasos. Se a demanda da última empresa da CS aumentar repentinamente, os integrantes anteriores da CS poderão não estar preparados para atender a esta nova realidade, possivelmente comprometendo a produção da última e afetando a entrega para o comprador.

## **2.2 Problemas relacionados a Estoques: Níveis de Estoque, Ruptura de Venda e Ruptura de Estoque**

Diversos custos estão envolvidos na manutenção de estoques: aluguel ou imobilização de capital em instalações prediais e sua manutenção, instalações físicas como prateleiras, segurança, custos administrativos, o próprio material estocado, seja ele um produto acabado, em processo de produção (estocagem intermediária de produtos não acabados), e até mesmo as matérias-primas envolvidas no processo. Outra questão relevante é o extravio, danificação ou roubo de mercadorias ou insumos que, por fim, transformam-se em custos. No caso de produtos perecíveis, também podem ser consideradas perdas pela ultrapassagem do prazo de validade.

Diante deste cenário, fica evidente a importância do correto gerenciamento dos estoques dentro das organizações. Com a adoção de elevados níveis de

estoque, mais espaço é necessário para armazenamento e maiores são as chances de danos e roubos de mercadorias. No caso de um nível de estoque muito acima da demanda pelo produto, maior o risco de perda por vencimento. Assim, diminuir os níveis de estoque significa reduzir custos, objetivo este almejado por todas as organizações. Dentro deste contexto, o conceito de estoque *Just-in-time* (JIT) busca maior eficácia na manutenção de estoques (CHING, 1999), uma vez que estes são mantidos em níveis que atendam estritamente à demanda necessária, fornecendo os itens no momento exato em que são necessários (HILLIER; LIEBERMAN, 2001). A filosofia JIT visa atender à demanda instantaneamente, com qualidade e sem desperdícios. Ele possibilita a produção eficaz em termos de custo, assim como o fornecimento da quantidade exata de itens que se faz necessária, no momento e local corretos, utilizando o mínimo de recursos (CHING, 1999). Esta seria a situação ideal em redes de varejo, contudo, dificilmente se tem total certeza sobre a demanda de cada produto. Existe ainda o problema relacionado ao *leadtime*, que é o tempo decorrido entre a colocação do pedido junto ao fornecedor e a entrega do mesmo, no local solicitado. Os itens vendidos nas lojas de uma rede varejista não têm entrega imediata por parte de seus fornecedores, como presume o JIT.

O problema de Redução de Níveis de Estoque vem sendo estudado há muito tempo. Segundo Lenard e Roy (LENARD; ROY, 1995) o estudo do controle de estoques teve início em 1913 com Ford Harris, quando este propôs o modelo de Lote Econômico, que afirma que a quantidade ótima a ser produzida é aquela que possui o menor custo de obtenção (ou de pedido) e estocagem, simultaneamente. Desde então, diversas pesquisas e trabalhos na área têm dado especial atenção a melhorias nas questões envolvidas, buscando sempre redução de custos e manutenção do atendimento às demandas do mercado. Um apanhado de trabalhos relacionados será feito no Capítulo 3, Revisão Bibliográfica.

O gerenciamento de estoques é um problema bastante complexo em função de suas características como logística de materiais, sazonalidade, necessidade de uma previsão adequada das demandas de venda, fatores externos como cenário econômico, poder aquisitivo da população, concorrência, clima, entre outras. Algumas das características citadas são previsíveis, mas não de forma exata. Muitas vezes o que se tem são métodos para previsão que se aproximam da realidade com um grau de confiabilidade aceitável para uso.

Através da utilização de métodos de previsão é possível obter informações sobre eventos futuros. Diversos métodos estimam valores futuros com base em dados observados no passado. Como já mencionado, existem fatores externos, fora do alcance da organização, que não podem ser controlados e, por vezes, nem são conhecidos. Um exemplo de fator externo conhecido, mas que não pode ser controlado é o clima. Como exemplo disso, pode-se citar um típico produto que sofre variações em função do clima, o sorvete. A venda de sorvetes sabidamente aumenta no verão e diminui no inverno por uma característica de consumo do produto. É possível utilizar esta informação para auxiliar na previsão de vendas, já que o clima é regido pelas estações do ano. Mas o que acontecerá se ocorrer um inverno atípico, com muitos dias quentes? Neste tipo de situação, a previsão baseada em estatística será menos precisa. Por causa desta característica, neste exemplo, pode-se afirmar que os métodos de previsão não são exatos. Não seria possível, então, baseado nas medições obtidas nas últimas décadas, prever, com certa margem de acerto, quando ocorrerão estações atípicas, considerando que existem ciclos característicos no clima? É possível verificar que diversos fatores estão envolvidos na previsão de vendas de sorvetes, levando em conta apenas o clima e suas certezas e incertezas. Existem ainda diversos outros fatores, previamente citados, que não foram comentados neste exemplo específico, mas é possível ter uma idéia da complexidade envolvida em tentar prever a venda de itens no setor varejista.

O exemplo recém citado pode ser utilizado também para demonstrar a necessidade de considerar a sazonalidade nas previsões, não necessariamente ligada a fatores climáticos. Existem épocas no ano em que determinados produtos tem maior demanda como Páscoa, Natal e outras datas comemorativas. O que vale para as estações do ano também vale para estes períodos. Pode-se dizer que a sazonalidade relacionada ao sorvete está diretamente ligada às estações do ano.

Outro importante fator a ser levado em conta em uma rede varejista é a localização do ponto de venda. Uma previsão de demanda geral, em alto nível, considerando os volumes totais de venda para toda a organização pode ser importante para análise de resultados da empresa como um todo, mas não é a mais adequada no que se refere à distribuição de estoques. Existem diversos pontos de venda em diferentes cidades e regiões, cada qual com uma característica de consumo, muitas vezes determinada por costumes e pelo poder aquisitivo da

população que habita seus arredores. Assim, a previsão de demanda de um mesmo produto poderá ser uma para determinada loja, e outra, completamente diferente, para outra loja, localizada em outra região. Para exemplificar esta situação, imagine uma garrafa de alguma bebida importada, com anos de envelhecimento, de alto valor monetário. Certamente ela será vendida com freqüência muito menor em uma loja localizada em um bairro onde os moradores tenham menor poder aquisitivo, do que em outra, onde o poder aquisitivo é consideravelmente mais elevado. Se a previsão for feita para a empresa como um todo, como saber quantas unidades de cada produto serão necessárias em cada ponto de venda? Dividir uniformemente certamente levará a um nível de acerto menor, basta pensar no exemplo da bebida importada, recém apresentado. Com isso, demonstra-se a necessidade de fazer a previsão de demanda levando-se em consideração o fator de localização.

É fundamental que, na manutenção dos estoques, o atendimento às demandas dos clientes seja considerado. Suprir o cliente com o produto correto e na quantidade adequada é primordial. Não suprir a necessidade do cliente significa não converter uma venda em lucro, na melhor das hipóteses, uma vez que este não é o único problema. Caso não seja possível atender à demanda de um consumidor em um item específico, ele possivelmente procurará outro local para efetuar esta compra. Também é possível que isso leve o consumidor a desistir de efetuar todas suas compras (não apenas daquele item indisponível) e procurar o concorrente para tal, fazendo com que todos os produtos em sua lista de compras não sejam vendidos e, conseqüentemente, não sejam revertidos em lucro. Em uma loja de varejo, a variedade de itens vendidos e as suas quantidades são elevadas, o que pode fazer com que a perda da venda de um ou outro item seja insignificante. Contudo, ainda é um ponto importante a ser considerado.

O problema da falta ou indisponibilidade de itens leva ainda a outra conseqüência, o desgaste na imagem da empresa. É possível que a insatisfação gerada pela falta de produtos diminua a confiança do consumidor na empresa ou até mesmo faça com que ele não frequente mais o local. A questão da insatisfação e da perda de confiança é subjetiva e difícil de ser medida.

Se um item está indisponível significa que todas as unidades, até então em estoque, foram vendidas e agora o estoque está zerado. Quando isso ocorre diz-se

que o produto encontra-se em Ruptura de Estoque (RE). A consequência da Ruptura de Estoque é a Ruptura de Venda (RV), uma vez que, se não há produto disponível, não há venda. Existem outros motivos para a ocorrência da Ruptura de Venda como concorrência, promoções de produtos semelhantes dentro da mesma loja, posicionamento dos produtos nas gôndolas, entre outros. Neste trabalho apenas a Ruptura de Venda motivada pela Ruptura de Estoque será tratada. Desta forma, de agora em diante, esta informação ficará implícita.

Os problemas apontados andam em direções opostas: para minimizar os custos de estocagem procura-se diminuir os níveis de armazenamento de produtos; para não incorrer na Ruptura de Venda, é necessário manter determinados níveis de estoque com margens de segurança. A partir destas afirmações, alguns questionamentos podem ser feitos:

- a) Como manter os níveis de estoque de forma a não incorrer na Ruptura de Venda sem ter custos desnecessários de armazenamento?
- b) Qual o nível ideal de estoque de cada produto, em cada local de venda, alcançando um equilíbrio entre atendimento das demandas geradas pelos consumidores, convertendo vendas em lucros, e o possível não atendimento das mesmas (ou parte delas), para não incorrer nos custos de armazenamento?
- c) É possível diminuir os intervalos entre reposições de estoque nos pontos de venda a um custo razoável (relativo à reposição), sendo este menor que o custo de armazenamento, que justifique a diminuição dos níveis de estoque nas lojas? Ainda relacionado à frequência de reabastecimento, qual o intervalo mínimo de tempo que os fornecedores necessitam para repor os produtos nos pontos de venda?

### 2.3 Efeito Chicote

O Efeito Chicote é o resultado da discrepância entre a demanda real e a prevista, unida à intenção das empresas em alinharem suas ofertas à demanda real, sem deixar de atendê-la. Por não possuírem a informação precisa de seus consumidores, as empresas buscam se proteger e garantir o estoque para uma possível variação nesta demanda, alterando seus volumes de pedido para cima (COELHO *et al*, 2007). A Previsão de Demandas pode ocorrer nos diversos níveis da Cadeia de Suprimentos, desde o fabricante, passando pelos canais de distribuição, até o ponto de venda no varejo, porém, quanto mais distante do ponto de venda ao consumidor final, maior será a discrepância entre a demanda prevista e a demanda real. Para Warburton (WARBURTON, 2004), as ordens de compra dos vendedores para os seus fornecedores tendem a ter uma variação maior do que a demanda do consumidor que iniciou o processo, o que caracteriza o efeito chicote.

Por causa deste fenômeno, prever demandas a partir de dados coletados no nível mais próximo do consumidor final pode ser considerada uma estratégia adequada, se não a melhor, de estimar as vendas de uma empresa ou organização.

### 2.4 Previsão de Demandas

A demanda por um produto é o número de unidades que precisarão ser retiradas do estoque para algum uso (venda, por exemplo) durante um período específico (HILLIER; LIEBERMAN, 2001). Segundo Kotler, (KOTLER, 1998), a Previsão de Vendas de uma empresa é o nível esperado de vendas em determinado período, baseado no plano de marketing escolhido e no ambiente de marketing

assumido. Tal previsão impacta em diversos setores de uma empresa como Finanças, Comercial, Produção e Recursos Humanos.

Prever demandas é uma atividade importante para auxiliar no planejamento das organizações. Especificamente no escopo do presente trabalho, a Previsão de Demanda por produtos no varejo, ou Previsão de Vendas, é vital para que haja uma medida que possibilite o planejamento e manutenção de estoques de produtos. Sem uma previsão adequada é possível incorrer em dois problemas: a) falta de produtos para atender às necessidades dos consumidores e b) manutenção de altos níveis de estoque sem necessidade, fazendo com que os custos da organização aumentem. Segundo Corrêa (CORRÊA, 2001), previsões ruins levam as empresas a tomar decisões ruins, o que compromete a sua competitividade. Diversos fatores podem influenciar na demanda de determinado item. Em função disso, a tarefa de prever com exatidão a demanda de produtos torna-se bastante complexa.

Dar atenção ao atendimento das necessidades dos clientes é tão importante quanto ficar atento aos custos de manutenção dos estoques. Diferentemente de setores especializados, onde existem poucos fornecedores de determinado produto, ou até mesmo um único, no setor varejista, quando um cliente não encontra o produto desejado, ele se dirigirá ao local mais próximo que possa ter o produto em questão disponível para compra. Salienta-se mais uma vez que isto poderá influenciar a confiança do consumidor, fazendo com que este não retorne mais, causando prejuízos para a organização. O ideal é encontrar o balanço entre atendimento às demandas, que presume manutenção de estoques de segurança, e baixos níveis de estoque, buscando a minimização de custos. Espera-se, com isso, obter o melhor resultado financeiro possível para a empresa.

### 2.4.1 Tipos de Previsão

As previsões podem ser classificadas, primeiramente, em previsões de curto, médio e longo prazo. Previsões de longo prazo dão uma idéia geral sobre o direcionamento da organização e têm especial atenção do alto escalão da empresa (nível estratégico). As de médio prazo têm como objetivo auxiliar na formulação dos planos de produção e são utilizadas principalmente por tomadores de decisão no nível intermediário (nível tático). Já as previsões de curto prazo são utilizadas pelas gerências de baixo nível (nível operacional), fornecendo subsídios para a formulação de estratégias e decisões para o futuro imediato (HANKE; REITSCH, 1981; BUFFA; SARIN, 1987). Em termos de tempo, estas três classificações podem variar em função de especificidades do problema e do cenário em que se encontram. Previsões de curto prazo podem variar de três a doze meses, as de médio prazo de seis meses a dois anos, enquanto que as de longo prazo podem ir desde dois até cinco anos.

Na mesma linha de pensamento, previsões podem ser classificadas de acordo com a sua abrangência: micro-previsões e macro-previsões. Enquanto a alta diretoria se preocupa em prever o total de produtos vendidos, tendo em vista o resultado financeiro global da empresa, os gerentes das filiais da mesma organização empresarial estão preocupados em prever suas vendas com o objetivo de planejar os pedidos junto a seus fornecedores. A macro-previsão é mais abrangente e se preocupa com números sumarizados ou totalizados, enquanto que a micro-previsão se preocupa em detalhar os números, firmando, desta forma, uma relação hierárquica entre elas (HANKE; REITSCH, 1981).

Previsões também podem ser classificadas em qualitativas ou quantitativas. As qualitativas são feitas com base em conhecimento especialista, de gerentes e cargos afins, ou seja, pessoas que conhecem o problema em questão, conhecimento este adquirido em experiências passadas. A técnica qualitativa mais conhecida e utilizada é o método Delphi (MOREIRA, 1999). Outros métodos qualitativos que podem ser citados são Pesquisa de Mercado, Painel de Consenso,

onde executivos e membros da força de vendas da organização dão opiniões sobre seu sentimento em relação às vendas futuras, e a Analogia Histórica, para o caso de novos produtos (SLACK *et al*, 2002). Já as previsões quantitativas descartam totalmente o conhecimento especialista, são procedimentos automatizados que utilizam dados históricos para produzir resultados (HANKE; REITSCH, 1981).

Makridakis e colaboradores (MAKRIDAKIS *et al*, 1998) sugerem ainda outra classificação, válida apenas para previsões quantitativas, são os modelos explanatórios e modelos de séries temporais.

Os modelos explanatórios assumem que a variável ou fenômeno a ser previsto possui uma relação explanatória com uma ou mais variáveis independentes. Como exemplo pode-se citar o preço de combustíveis fósseis. Neste caso, as variáveis independentes envolvidas podem ser dadas pelos indicadores econômicos mundiais e nacionais, níveis de produção de petróleo, importações, exportações, dentre outras. É importante considerar também uma variável de erro dentro deste modelo, uma vez que um limitado número de variáveis independentes é utilizado e todos os demais fatores que influenciam o preço de combustíveis estão sendo desconsiderados (a variável de erro tem o objetivo de reproduzir efeitos aleatórios do sistema). Assume-se que a relação entre a variável dependente e as independentes não irá mudar com o passar do tempo, sendo possível utilizar tal relação para prever valores futuros. Neste tipo de modelo o maior problema é determinar quais variáveis são adequadas para prever valores futuros de um sistema e, uma vez identificadas, é necessário identificar qual a forma de relação entre elas. Modelos explanatórios podem ser utilizados para previsões em diversos outros sistemas.

Já os modelos baseados em séries temporais não tentam encontrar uma relação entre o fenômeno ou sistema observado com outras variáveis, mas procuram entender o seu padrão de comportamento, através da análise de uma série de observações do passado. Uma vez que o comportamento do sistema é conhecido, ele é utilizado para prever valores futuros. Para exemplificar, é possível utilizar a recém citada variável “preço de combustíveis fósseis”, utilizada no exemplo do modelo explanatório. Contudo, um modelo previsor baseado em séries temporais utilizaria observações de seus próprios valores no passado, em intervalos

constantes (semanas, meses, trimestres, etc). A seção 2.4.2.1 trará, oportunamente, um maior detalhamento sobre séries temporais.

## **2.4.2 Métodos Previsores**

Alguns métodos quantitativos foram pesquisados, tendo sido adotado para uso neste trabalho o método por Suavização Exponencial (SE) com Sazonalidade Multiplicativa. Trata-se de uma técnica que considera sazonalidade e tendência, aspectos muito importantes na previsão de demandas por produtos no varejo. Outra motivação para o uso deste método é que ele permite, na forma como foi desenvolvido em virtude do contexto do presente trabalho, que diferentes parâmetros sejam calibrados para diferentes comportamentos de demanda, dependendo do produto em questão. Isto é feito através de um método iterativo que verifica a qualidade da previsão de demanda, segundo proposto por vários autores. Ainda, a SE é uma forma relativamente simples de efetuar previsões, diferentemente de outros métodos, onde há uma complexidade muito maior na técnica. A SE traz uma boa relação custo/benefício no que tange ao esforço de criação do modelo e ao desenvolvimento de um programa de computador que possa ser executado para obtenção de resultados.

Nesta seção será apresentado o método de previsão por Suavização Exponencial e conceitos relacionados, fundamentais para seu entendimento. Outros métodos previsores quantitativos serão brevemente descritos.

### 2.4.2.1 Séries Temporais e Análise de Regressão

Uma Série Temporal (ST) é uma sequência de pontos (dados) coletados em sucessivos momentos do tempo, tipicamente separados por intervalos distribuídos uniformemente. Uma ST é naturalmente ordenada de forma cronológica, sendo esta a sua principal característica: sempre existirão medições de um fenômeno qualquer em função do tempo. O tempo é uma variável independente que pode ser medido em anos, meses, semanas, dias, ou até mesmo em horas, sendo geralmente denotada por  $X$ . Já a medição a ser registrada, que varia a cada observação, é a variável dependente, geralmente denotada por  $Y$ . Medições diárias de temperatura, valores de fechamento diário de ações nas bolsas de valores, quantidade de veículos que transitam em uma estrada em intervalos de uma hora, quantidade de unidades vendidas de determinado produto dentro de um mês, são alguns exemplos de grandezas que podem ser descritas por de Séries Temporais.

A Análise das Séries Temporais, também chamada de Análise de Regressão, pode ser utilizada para identificação de padrões de comportamento, tendências e mudanças dentro do fenômeno observado. Tal comportamento, referente a períodos anteriores, pode então ser utilizado na Previsão de Séries Temporais, olhando adiante no horizonte de tempo, fornecendo assim uma maneira de prever eventos futuros para o fenômeno em questão. No contexto de organizações, por exemplo, do ramo varejista, existem diversas aplicações para Séries Temporais, entre as quais o comportamento de vendas, o atendimento de demandas, o controle de estoques, o comportamento de rupturas, dentre outras. A previsão de séries temporais não é uma resposta certa para o comportamento futuro de grandezas de interesse, mas é uma ferramenta valiosa para predição, ajudando a reduzir erros em previsões (HANKE; REITSCH, 1981).

### 2.4.2.2 Média Móvel

A Média Móvel (MM), do inglês *Moving Average* (MA), é caracterizada por utilizar as últimas  $q$  ocorrências de uma Série Temporal no cálculo de uma média que representará a previsão para o período imediatamente posterior. Este método pode ser utilizado como uma forma bastante simplificada de previsão (HANKE; REITSCH, 1981).

Estabelecer o cálculo da MM com base em poucas observações anteriores não permite, por exemplo, que a sazonalidade seja considerada. Além disso, ela pode ser utilizada apenas para previsões de curto prazo, uma vez que somente observações recentes do fenômeno em questão podem ser utilizadas. Por exemplo, é possível prever a demanda de determinado produto para o mês atual, através do cálculo da média de demanda dos três meses anteriores. A previsão para o mês seguinte não pode ser feita antes de se conhecer a demanda por este mesmo produto no presente mês (HANKE; REITSCH, 1981).

### 2.4.2.3 Autoregressive Integrated Moving Average Model

*Autoregressive Integrated Moving Average Model* (ARIMA) é um método generalizado baseado em Séries Temporais. Ele pode ser usado para se obter um melhor entendimento do fenômeno em questão e para previsão de valores futuros de uma ST.

Também conhecido como Método Box-Jenkins, nome este originado a partir de seus criadores, George Box e Gwilym Jenkins, ele se popularizou no início da década de 70 (MAKRIDAKIS; *et al*, 1998). Este modelo é composto por três partes

distintas e, geralmente, se faz referência a ele como  $ARIMA(p, d, q)$ . As três partes do modelo são:

$AR(p)$ : parte autoregressiva de ordem  $p$ ;

$I(d)$ : diferenciação de grau  $d$ ;

$MA(q)$ : parte referente à média móvel de ordem  $q$ .

O ARIMA é uma combinação do modelo autoregressivo (AR) com o modelo de média móvel (MA, *Moving Average*). Além disso, este método possui um componente de diferenciação (I). Ele é responsável por estabilizar os dados (tornar a série temporal estacionária).

Este modelo é dito generalizado, pois qualquer uma das suas três partes pode não ser usada, bastando, para isso, zerar o referido parâmetro. Maiores detalhes sobre como valorar adequadamente estes parâmetros podem ser obtidos em (HANKE; REITSCH, 1981; MAKRIDAKIS *et al*, 1998).

#### 2.4.2.4 Redes Neurais Artificiais

Uma Rede Neural Artificial (RNA) é um sistema computacional baseado em ligações. Diversos nós simples são interligados tendo em vista a formação de uma rede. Esta técnica se inspira no funcionamento do cérebro de organismos inteligentes, que utiliza uma quantidade consideravelmente grande de neurônios (equivalentes aos nós, pequenas unidades processadoras) interligados como uma rede. Seu surgimento ocorreu na década de 1940 no *Massachusetts Institute of Technology* (MIT) e trata-se de uma técnica relacionada à área de Inteligência Artificial (IA). Há uma vasta gama de aplicações para RNA, alguns exemplos são reconhecimento de padrões, análise e processamento de sinais, análise de imagens

e de voz, controle de processos e aproximação de funções (robótica), dentre outras (LOESCH, 1996).

No que tange à previsão de demandas, é possível utilizar uma RNA para prever séries temporais. Segundo Portugal e Fernandes (PORTUGAL; FERNANDES, 1996), uma RNA tem alguns pontos em comum com os métodos previsores clássicos baseados em séries temporais, porém são tratados com nomenclaturas diferentes em cada um dos métodos. Por exemplo, as variáveis dependentes e independentes do modelo baseado em séries temporais são equivalentes aos sinais de entrada e saída dos neurônios. Outro exemplo, agora em relação aos modelos ARIMA e de Suavização Exponencial, são os fatores de sazonalidade, ciclo e tendência. Em uma RNA estes fatores também podem ser contemplados no modelo utilizando neurônios especializados nestas características, equivalentes aos modelos citados.

#### **2.4.2.5 Suavização Exponencial**

O método de previsão por Suavização Exponencial, ou *Exponential Smoothing* (ES), é uma técnica recursiva aplicada a Séries Temporais. Ele difere da Média Móvel pelo fato de impor diferentes pesos aos valores observados na ST para o cálculo da previsão. Seu uso é indicado para previsões de curto prazo (HANKE; REITSCH, 1981; MAKRIDAKIS *et al*, 1998).

A SE é um procedimento para revisão contínua durante a previsão, privilegiando observações mais recentes de maneira exponencial, sendo que, quanto mais distante do período atual, menor o peso dado ao valor da observação.

Os pesos utilizados são:

- $A$ : para a observação mais recente  $Y_t$ ;  
 $A(1 - A)$ : para a observação anterior  $Y_{t-1}$ ;  
 $A(1 - A)^2$ : para a observação anterior  $Y_{t-2}$ .

Serão utilizados tantos pesos quantos forem os valores utilizados.

De forma geral, dada uma série de observações de uma variável  $Y$  qualquer, a equação (2.1) representa o sistema de pesos e, conseqüentemente, a Suavização Exponencial propriamente dita.

$$F_t = AY_t + (1 - A)F_{t-1}, \quad (2.1)$$

onde:

- $F_t$ : é o valor previsto suavizado exponencialmente no período  $t$ ;  
 $A$ : é a constante de suavização ( $0 \leq A \leq 1$ );  
 $Y_t$ : é o valor observado na Série Temporal no período  $t$ ;  
 $F_{t-1}$ : é o valor previsto suavizado exponencialmente no período  $t-1$ .

$F_t$  pode ser considerada como uma combinação linear de todas as observações anteriores com um fator ponderador que decresce geometricamente com o passar do tempo, sendo a constante  $A$  a responsável por isso. Quanto maior for o valor de  $A$  ( $0 \leq A \leq 1$ ), mais rapidamente os valores do passado perdem significância na previsão  $F_t$ , aumentando a velocidade de resposta a mudanças em períodos mais recentes (HANKE; REITSCH, 1981; MAKRIDAKIS *et al*, 1998).

O valor dado à constante de suavização  $A$  é um fator crítico para a utilização deste método de previsão. Em geral, seu valor é obtido através de um método

iterativo que minimiza a soma dos erros obtidos entre os valores previstos e os valores observados elevados ao quadrado, conforme a equação (2.2). Este método é conhecido como Método dos Mínimos Quadrados (MMQ).

$$S = \sum_{i=1}^n (F_t - Y_t)^2, \quad (2.2)$$

onde:

$F_t$ : é o valor previsto para o período  $t$ ,

$Y_t$ : é o valor observado no período  $t$ .

O valor de  $A$  que produzir o menor valor para  $S$ , através do uso da equação (2.2), deve ser utilizado para geração das previsões.

Dentro do método de suavização exponencial também é possível inserir o Fator de Tendência. Para tanto é necessário ajustar a equação (2.1), chegando-se à equação (2.5), chamada de Método Linear de dois Parâmetros de Holt (HANKE; REITSCH, 1981; MAKRIDAKIS *et al*, 1998). Para que seja obtida a expressão ajustada à Tendência, equação (2.5), é necessário ajustar a Série de Suavização Exponencial, equação (2.3), inserindo a Tendência Estimada, equação (2.4), e conduzir a previsão de  $m$  períodos adiante, equação (2.5).

$$L_t = AY_t + (1 - A)(L_{t-1} + T_{t-1}), \quad (2.3)$$

$$T_t = B(L_t - L_{t-1}) + (1 - B)T_{t-1}, \quad (2.4)$$

$$F_{t+m} = L_t + mT_t, \quad (2.5)$$

onde:

- $L_t$ : nível estimado da série temporal no período  $t$ ;
- $A$ : constante de suavização ( $0 \leq A \leq 1$ );
- $Y_t$ : valor observado na Série Temporal no período  $t$ ;
- $L_{t-1}$ : nível estimado da série temporal no período  $t-1$ ;
- $B$ : constante de suavização da tendência ( $0 \leq B \leq 1$ );
- $T_t$ : valor estimado de tendência no período  $t$ ;
- $T_{t-1}$ : valor estimado de tendência no período  $t-1$ ;
- $m$ : quantidade de períodos a avançar no futuro;
- $F_{t+m}$ : previsão para  $m$  períodos no futuro.

A equação (2.5) difere da equação original de suavização exponencial (2.1) pela adição do termo de tendência do período anterior  $T_t$ . Este termo, por sua vez, é obtido através da diferença entre dois valores sucessivos de previsão utilizando a suavização, conforme equação (2.4). O cálculo do termo de tendência segue a idéia de suavização de valores de acordo com sua idade, através da utilização do termo ponderador  $B$ . A equação (2.5) é utilizada para estimar a previsão em  $m$  períodos adiante no tempo.

Outra importante característica que pode ser levada em conta na geração de previsões utilizando SE é a Sazonalidade. Para tanto, é necessário adaptar novamente a equação de suavização, utilizando agora o Modelo Linear e Sazonal de Três Parâmetros de Winter (HANKE; REITSCH, 1981; MAKRIDAKIS *et al*, 1998). Este método foi baseado no método de Holt, adicionando o fator de Sazonalidade, sendo descrito pelas equações (2.6) a (2.9). Na literatura, este método baseado em três componentes, nível, tendência e sazonalidade, é comumente denominado Método de Holt-Winters (HANKE; REITSCH, 1981; MAKRIDAKIS *et al*, 1998).

$$S_t = B \frac{Y_t}{L_t} + (1 - B)S_{t-s} \quad , \quad (2.6)$$

$$T_t = C(L_t - L_{t-1}) + (1 - C)T_{t-1} \quad , \quad (2.7)$$

$$L_t = A \frac{Y_t}{S_{t-s}} + (1 - A)(L_{t-1} + T_{t-1}) \quad , \quad (2.8)$$

$$F_{t+m} = (L_t + mT_t)S_{t-s+m} \quad , \quad (2.9)$$

onde:

- $L_t$ : nível estimado da série temporal no período  $t$ ;
- $A$ : constante de suavização ( $0 \leq A \leq 1$ );
- $Y_t$ : valor observado na Série Temporal no período  $t$ ;
- $F_{t-1}$ : valor estimado da série temporal no período  $t-1$ ;
- $B$ : constante de suavização de sazonalidade ( $0 \leq B \leq 1$ );
- $S_t$ : valor estimado da sazonalidade no período  $t$ ;
- $S_{t-s}$ : valor estimado da sazonalidade no período  $t-s$ ;
- $C$ : constante de suavização de tendência ( $0 \leq C \leq 1$ );
- $T_t$ : valor estimado de tendência no período  $t$ ;
- $T_{t-1}$ : valor estimado de tendência no período  $t-1$ ;
- $m$ : quantidade de períodos a avançar no futuro;
- $s$ : comprimento do ciclo sazonal;
- $F_{t+m}$ : previsão para  $m$  períodos no futuro.

A equação (2.6) expressa o fator sazonal como um valor indexado ao invés de um valor absoluto. Isto ocorre para que ele possa ser utilizado na equação (2.9) com o operador de multiplicação. A esta forma de tratamento dá-se o nome de Sazonalidade Multiplicativa. Existe ainda a possibilidade de utilizar a SE com Sazonalidade Aditiva. Neste trabalho apenas a SE com sazonalidade multiplicativa

será empregada, já que é a mais comumente utilizada e apresenta, geralmente, menores erros ou desvios (MAKRIDAKIS *et al*, 1998). O fator de tendência da equação (2.7) é o mesmo da equação (2.4). A equação (2.8) é responsável pela determinação do nível ou valor base da série. Já a equação (2.9) é utilizada para estimar ou prever o valor da série temporal  $m$  períodos adiante no tempo.

Com a inserção dos fatores de tendência e sazonalidade no modelo de previsão por suavização exponencial, surge novamente a situação onde é necessário calibrar os termos ponderadores  $A$ ,  $B$  e  $C$ . Isto deve ser feito através do mesmo método iterativo que minimiza a soma dos erros obtidos pela diferença quadrática entre os valores previstos e os valores observados, de acordo com a equação (2.2). Os valores de  $A$ ,  $B$  e  $C$  que produzirem o menor valor para a equação (2.2) serão os mais adequados.

A SE utiliza valores observados no passado para gerar previsões. Existe aqui um problema relacionado à geração do primeiro valor de previsão, visto que as observações necessárias estão fora dos limites da ST. Em função disso, é necessário utilizar um método de inicialização para o método previsor. Uma das técnicas empregadas é a utilização de uma média dos valores observados nos períodos mais recentes da ST (HANKE; REITSCH, 1981).

Três indicadores foram selecionados para verificar a adequação do modelo de previsão utilizando SE. O primeiro, Erro Médio Absoluto ou *Mean Absolute Error* (MAE), definido pela equação (2.10), mede a distância média entre os valores obtidos pelo previsor e os valores observado, na mesma unidade dos valores observados (HANKE; REITSCH, 1981; MAKRIDAKIS *et al*, 1998).

$$MAE = \frac{\sum_{t=1}^n |F_t - Y_t|}{n} . \quad (2.10)$$

O segundo indicador é o Erro Médio Quadrático ou *Mean-squared Error* (MSE), dado pela equação (2.11). Ele também mede a distância média entre os

valores previstos e observados, porém não na mesma unidade que os valores observados (HANKE; REITSCH, 1981; MAKRIDAKIS *et al*, 1998).

$$MSE = \frac{\sum_{t=1}^n (F_t - Y_t)^2}{n} . \quad (2.11)$$

O terceiro indicador é o Erro Percentual Médio Absoluto, ou *Mean Absolute Percentage Error* (MAPE). Primeiro é necessário calcular o Erro Percentual (EP) ou *Percentage Error* (PE), dado pela equação (2.12). Em seguida, o MAPE é efetivamente calculado, segundo a equação (2.13) (HANKE; REITSCH, 1981; MAKRIDAKIS *et al*, 1998).

$$PE_t = \frac{F_t - Y_t}{Y_t} , \quad (2.12)$$

$$MAPE = \frac{\sum_{t=1}^n |PE_t|}{n} . \quad (2.13)$$

Para os três indicadores, MAE, MSE e MAPE, os termos que compõem as equações são:

- $F_t$ : valor previsto (obtido com o método) para o período  $t$ ;
- $Y_t$ : valor observado na série temporal no período  $t$ ;
- $n$ : número de observações/valores previstos.

O indicador MAPE foi adotado neste trabalho para avaliar a adequação do modelo predictor, uma vez que ele possibilita a avaliação dos erros através de uma medida relativa à magnitude dos valores observados.

Makridakis e colaboradores (MAKRIDAKIS *et al*, 1998) afirmam que a melhor forma de avaliar um modelo previsor é compará-lo com outros. Os autores compararam onze métodos de previsão utilizando seis indicadores de qualidade, dentre eles o MAE, MSE e MAPE. Todos os indicadores apontaram para a SE com sazonalidade multiplicativa como sendo o método mais apropriado para previsões. Com base nisso, tomou-se a decisão de utilizar tal método para o processo de previsão de demandas no presente trabalho.

### **2.4.3 Considerações sobre modelos de previsão**

Os métodos apresentados na seção 2.4.2 consideram, basicamente, valores observados no passado para a predição de valores futuros, sejam eles relativos ao próprio fenômeno, que é o caso das séries temporais, ou de variáveis independentes, a exemplo da RNA. Existe uma vasta gama de outros fatores que podem influenciar as previsões e que não são explicados por estes modelos, além da natureza aleatória (imprevisível) presente em situações onde se faz necessário o uso de modelos previsores.

Por mais preciso que possa ser o método, ocorrerão situações de imprecisão nas previsões, basta pensar no exemplo de produtos que deixam de ser fabricados em determinado período. Uma previsão feita com base em dados do passado tentará reproduzir este comportamento de demanda para períodos futuros. Contudo, no caso de produtos descontinuados, sua venda poderá passar para zero de um dia para o outro. Esta situação pode ser considerada durante o processo de previsão, levando em conta as decisões da empresa fabricante, que poderão ser conhecidas com antecedência. Neste trabalho não se tem conhecimento sobre este tipo de decisão, logo, não foi possível considerar este aspecto para a construção da ferramenta de previsão.

## 2.5 Simulação

Simulação é uma forma de reproduzir (imitar) um sistema (subsistema, processo), seja ele físico ou abstrato. Primeiramente deve-se observar o comportamento do sistema que se deseja simular, tendo como objetivo entender seu funcionamento para que suas principais características possam ser corretamente representadas dentro de um modelo lógico/matemático. Para modelos simples, é possível utilizar métodos matemáticos para a simulação, como álgebra, teoria das probabilidades ou cálculo diferencial. Para sistemas mais complexos, pode ser necessário traduzir tal modelo em um programa de computador e, possivelmente, simplificar sua modelagem. No mundo real, boa parte dos sistemas existentes são complexos o bastante para justificar o uso de computadores em conjunto com técnicas de simulação para reproduzir seus comportamentos (LAW; KELTON, 2000).

### 2.5.1 Estratégias de Modelagem e Variáveis de Estado

Com o objetivo de modelar os sistemas existentes no mundo real, podem ser utilizados dois tipos de estratégias: modelagem discreta ou modelagem contínua. Com relação aos modelos de simulação, este mesmo critério de divisão pode ser empregado, uma vez que tenta-se reproduzir tais sistemas (LAW; KELTON, 2000).

Sistemas discretos são caracterizados por apresentarem mudanças nas variáveis de estado do sistema (conjunto de variáveis que descrevem o sistema) em determinados instantes no tempo. O atendimento de clientes em um caixa de supermercado é um exemplo deste tipo sistema. Um exemplo de variável estado do sistema, neste mesmo exemplo, é a quantidade de clientes na fila, aguardando pelo atendimento. Pode-se, por exemplo, a cada minuto, verificar a quantidade de

clientes aguardando na fila. É possível verificar que a variável de interesse muda, possivelmente, a cada minuto, com a chegada ou saída de clientes da fila. Outro exemplo de sistema discreto que pode ser citado é o de estocagem de um produto em um depósito. Neste caso, a variável que descreve o sistema é o nível de estoque do produto. Medições do nível de estoque podem ser verificadas ao final do expediente, já que no decorrer do dia podem ser retiradas ou repostas algumas unidades do produto em questão.

Os sistemas contínuos são caracterizados por terem suas variáveis de estado alteradas continuamente no tempo. Como exemplo, pode-se citar um avião, onde variáveis de estado como posição, velocidade, nível de combustível e altitude podem variar continuamente em relação ao tempo. Em termos de simulação computacional, o que geralmente ocorre é a discretização dos sistemas contínuos. No exemplo do avião, as variáveis de estado variam continuamente, porém elas podem ser medidas em instantes discretos, por exemplo, a cada segundo. O computador é uma máquina que processa operações sequencialmente, logo, simular um sistema contínuo pode ser bastante complexo. O que se pode fazer é determinar um intervalo suficientemente pequeno para aproximar o sistema discreto do contínuo. Quanto menor for o intervalo de verificação das variáveis de estado, mais próximo se estará de uma simulação contínua. Por exemplo, é possível reduzir o intervalo de verificação do estado de um segundo para um décimo, um centésimo ou um milésimo de segundo.

### **2.5.2 Servidor**

Em um simulador existe um componente do sistema denominado servidor. Ele é responsável pelo funcionamento do sistema, ou seja, executar o processo envolvido. Utilizando o exemplo dos clientes na fila do caixa de supermercado, a mudança da variável “quantidade de clientes na fila do caixa” ocorre quando algum

cliente entra na fila ou quando o primeiro da fila passa a ser atendido pelo operador de caixa. Especificamente quando o primeiro cliente da fila entra em operação no caixa, passando suas compras, efetuando o pagamento, até o momento imediatamente anterior ao que ele deixa o caixa com os produtos adquiridos, diz-se que o cliente está em serviço e, durante este intervalo de tempo, nenhum outro cliente poderá utilizar o caixa. Neste exemplo, o caixa (operador e equipamentos) é o servidor, um recurso necessário e limitado dentro do sistema. Em um modelo de simulação com apenas um servidor, quando um cliente entra em serviço, nenhum outro poderá fazer o mesmo, já que o servidor pode atender apenas um cliente por vez. Se um novo caixa fosse colocado em operação, dois clientes poderiam ser atendidos paralelamente. Neste caso existiriam dois servidores.

### **2.5.3 Eventos**

Outro importante componente utilizado em uma ferramenta de simulação é denominado evento. Qualquer acontecimento que provoque mudança nas variáveis de estado do sistema é chamado de evento (LAW; KELTON, 2000). Retornando ao exemplo do nível de estoque de um produto em um depósito, a entrega de um pedido do produto é um evento que altera o estado do sistema, aumentando o nível de estoque. Outro evento ocorre quando um consumidor compra uma ou mais unidades do produto, retirando-as do estoque, fazendo com que o nível de estoque diminua. Quando um evento acontece, uma rotina de evento específica é executada, sendo ela a responsável por atualizar o estado do sistema.

#### **2.5.4 Relógio de Simulação**

O comportamento do sistema é regido pela ocorrência de eventos com o decorrer do tempo dentro de uma simulação. Isto remete a outro conceito importante, o relógio de simulação. Sua função é controlar o avanço do tempo e reger o funcionamento do simulador. No exemplo da fila do caixa de supermercado é possível determinar que o relógio avançará em intervalos constantes de tempo. Assim, transcorrido cada intervalo de tempo, as variáveis de estado do sistema poderão sofrer mudanças e eventos podem ocorrer, por exemplo, clientes chegando na fila, clientes entrando em serviço e clientes terminando de serem servidos e deixando o sistema. Outra forma utilizada para fazer a simulação avançar no tempo é através do avanço até o próximo evento. Neste caso, os instantes entre os eventos não são importantes, o simulador se concentra apenas nos instantes de tempo em que os eventos realmente ocorrem. Conforme exposto anteriormente, o sistema pode ser modelado de diferentes formas e cabe a quem o modela verificar qual a melhor forma para executar esta tarefa. Existe uma forte relação entre o relógio de simulação e a ocorrência dos eventos.

#### **2.5.5 Contadores Estatísticos e Indicadores de Desempenho**

Dentro de um simulador, além das variáveis de estado, existem os contadores estatísticos. Estes contadores são responsáveis por manter informações estatísticas de interesse sobre o sistema em questão ao longo da simulação. No exemplo do sistema de estoque, exemplos de contadores estatísticos podem ser a demanda média diária, o intervalo médio de reposições, o custo de reposição, o custo de manutenção de estoque ou a quantidade de reposições de um produto em um mês.

Estes contadores são atualizados ou contabilizados dentro das rotinas de eventos (LAW; KELTON, 2000). A escolha dos contadores estatísticos depende do sistema em estudo e do que exatamente se pretende obter como informação, através do exercício de simulação. A decisão sobre quais contadores serão utilizados no simulador fica a cargo de quem modela o sistema.

No presente trabalho será utilizado um simulador discreto determinístico. Por esta razão, o termo “Contadores Estatísticos” será substituído por “Indicadores de Desempenho”, uma vez que o simulador não irá contabilizar estatísticas.

#### **2.5.6 Distribuições de Probabilidade, Tipos de Simulação e Cenários Alternativos**

O exemplo do caixa de supermercado, citado anteriormente, representa um sistema de uma fila onde pessoas permanecem aguardando pelo atendimento do caixa. Este tipo de sistema, denominado Sistema de Filas, é de grande interesse da teoria de Simulação (LAW; KELTON, 2000). Dentro deste conceito, podem ser citados outros exemplos como filas de bancos, atendimento a motoristas em um pedágio, uma pista de aeroporto onde existem aviões para decolarem e outros para pousarem, dentre diversos outros exemplos.

Ao falar genericamente em um sistema de filas, seu comportamento poderá ser determinado com base na sua observação. Serão conhecidos horários de pico de utilização e horários de baixa utilização. Este comportamento das filas é dado ou regido por uma distribuição de probabilidade. Com os dados coletados sobre chegadas de clientes, bem como o tempo gasto para cada operação (atendimento), é possível identificar a distribuição de probabilidade que melhor representa seu comportamento. A descrição de um sistema real via simulação computacional pode fazer uso de uma distribuição de probabilidade, ou mais de uma, dependendo do número de eventos regidos por funções desta natureza. Com estas informações, o

simulador poderá operar imitando o comportamento do sistema real observado. Isso não significa que o simulador pode prever o futuro, mas que ele reproduz seu comportamento de forma aleatória. Um simulador com esta característica leva o nome de simulador estocástico, ou seja, ocorrerão eventos aleatórios descritos com base em distribuições de probabilidade.

Há ainda outro modelo de simulador, denominado determinístico. Ele não faz uso de fatores estocásticos (aleatórios) e pode ser utilizado para simular sistemas onde eventos e variáveis de estado são regidos por dados determinísticos, de forma que, para um conjunto conhecido de dados de entrada, tem-se sempre um único resultado de saída. Um exemplo de aplicação deste modelo pode ser encontrado em sistemas de reposição de mercadorias: dado um conjunto de demandas previstas de determinado produto para cada dia dos próximos seis meses, e um conjunto (ou programação) de reposição de estoque para o mesmo período, quanto desta demanda será atendida? Qual será o lucro obtido? Qual será o custo da operação? Em um simulador determinístico, se as mesmas entradas foram inseridas e o simulador for executado diversas vezes, em todas elas será obtido o mesmo resultado, já que não existem fatores estocásticos. Em um simulador estocástico, não necessariamente tem-se a mesma resposta em cada execução, justamente devido à sua natureza aleatória.

### **2.5.7 Projeto de Simulação e Simulador Computacional**

Law e Kelton (LAW; KELTON, 2000) sugerem uma sequência de passos para a criação de um projeto de simulação. Um diagrama desta sequência poder ser visto na figura 2.1.

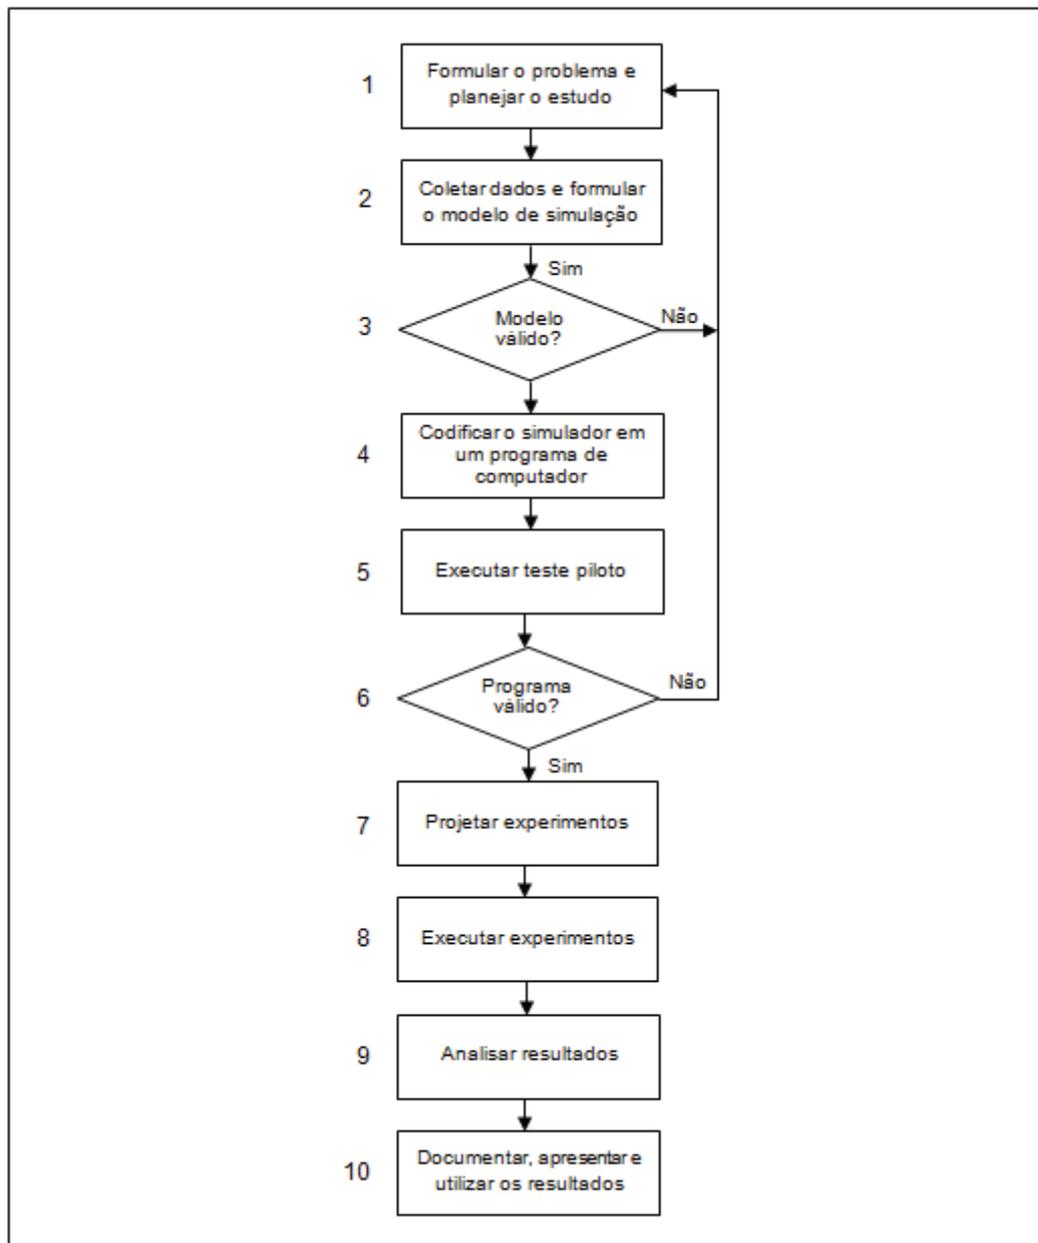


Figura 2.1 – Passos para a criação de um projeto de simulação.  
Fonte: Adaptado de (LAW; KELTON, 2000)

- 1) Formular o problema e planejar o estudo: etapa inicial para estabelecimento do objetivo principal do projeto, definição de indicadores para avaliação do desempenho de cenários alternativos, escopo do modelo e artefatos computacionais que serão utilizados;
- 2) Coletar dados e formular o modelo de simulação: observar o sistema em estudo para definição das distribuições de probabilidade a serem utilizadas e definir procedimentos operacionais;

- 3) Modelo válido: verificar a validade conceitual do modelo junto a pessoas com conhecimentos profundos no assunto;
- 4) Codificar o simulador em um programa de computador: transformar o modelo conceitual em um programa de computador para que possa ser executado;
- 5) Executar teste piloto: o programa é testado para comprovação de sua validade na etapa 6;
- 6) Programa válido: avalia os resultados do teste piloto para verificar se o programa codificado reproduz o comportamento do sistema real;
- 7) Projetar experimentos: definir tempo de execução e número de diferentes rodadas do simulador utilizando diferentes sementes para geração de números aleatórios. Definir cenários alternativos;
- 8) Executar experimentos: obter resultados dos experimentos para avaliação na etapa 9;
- 9) Analisar resultados: verificar o desempenho do sistema nos diferentes cenários simulados e, se for o caso, escolher o mais apropriado de acordo com os objetivos do estudo;
- 10) Documentar, apresentar e utilizar os resultados: documentar, dentre outros, o programa desenvolvido e os resultados obtidos, apresentar o modelo e promover discussão a seu respeito, utilizar os resultados obtidos em processos de tomada de decisão.

Ainda segundo Law e Kelton (LAW; KELTON, 2000), a estrutura básica de um simulador computacional segue o fluxograma apresentado na figura 2.2.

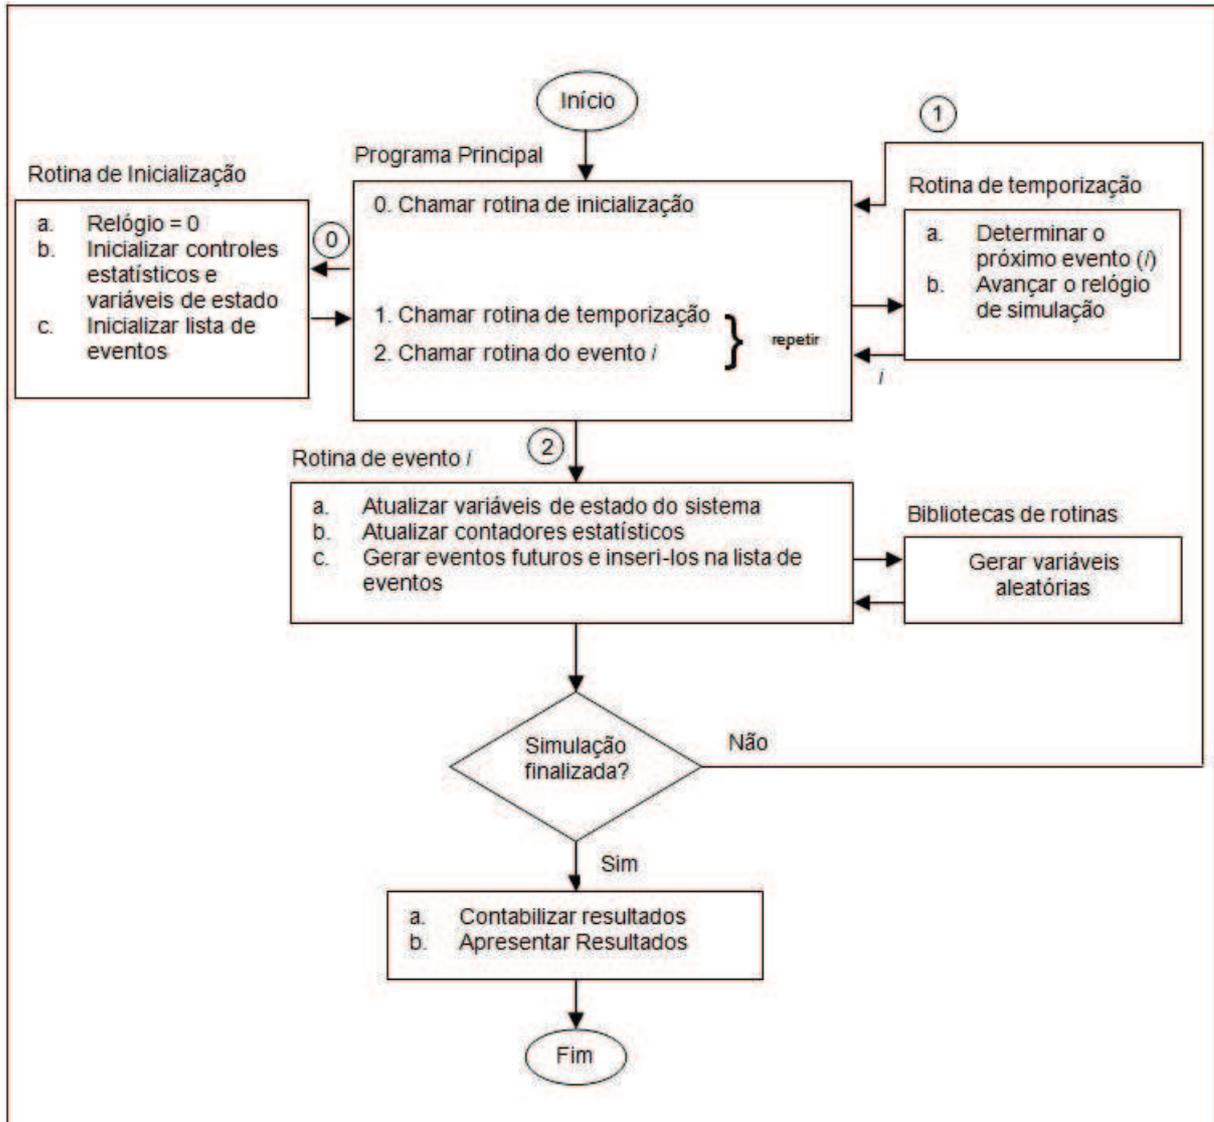


Figura 2.2 – Fluxograma de um simulador.  
Fonte: Adaptado de (LAW; KELTON, 2000).

A simulação inicia pelo programa principal no instante 0 (zero) com a chamada da rotina que irá inicializar as variáveis de estado, os contadores estatísticos e a lista de eventos. O relógio é inicializado com zero. Em seguida as rotinas de temporização e rotinas de eventos (1 e 2, respectivamente) serão chamadas repetidamente até que a simulação atinja a condição de parada. A rotina de temporização cuida do avanço do relógio, seja com intervalos fixos de tempo ou pelo avanço até o próximo evento. As rotinas de evento *i* são responsáveis por controlar as variáveis de estado e contabilizar os contadores estatísticos da simulação. Cada evento poderá ter uma rotina própria e tratará de variáveis específicas. As bibliotecas de rotinas são também utilizadas na geração de variáveis

aleatórias. Ao final serão contabilizados e apresentados os resultados obtidos com a simulação.

### **2.5.8 Vantagens e Desvantagens do uso de Simulação**

Segundo Pedgen e colaboradores (PEDGEN *et al*, 1995), Simulação é um processo de projetar um modelo de um sistema real e conduzir experimentos com o mesmo, objetivando entender seu comportamento e/ou avaliar estratégias para sua operação.

Para Banks (BANKS, 1998), as principais vantagens obtidas pela utilização da simulação, são:

- a) possibilidade de explorar o sistema real com modificações de políticas, procedimentos, operações ou métodos, com custo relativamente baixo e sem interferir no sistema real;
- b) domínio sobre o tempo, já que, no caso de fenômenos que ocorrem muito lentamente, o tempo de simulação pode ser reduzido.

Law e Kelton (LAW; KELTON, 2000) indicam ainda outras vantagens:

- a) possibilidade de estudar sistemas complexos, contendo elementos estocásticos, que não podem ser descritos matematicamente e resolvidos analiticamente;
- b) melhor controle sobre as condições do experimento em relação ao sistema real, uma vez que é possível alterar seus parâmetros e avaliá-lo, fornecendo subsídios aos tomadores de decisão;
- c) experimentação de diferentes alternativas, diferente das condições reais de operação do sistema.

Law e Kelton (LAW; KELTON, 2000) indicam, por outro lado, algumas desvantagens no uso desta técnica, a saber:

- a) modelos de simulação devem ser executados várias vezes para averiguação de seu desempenho, uma vez que têm natureza estocástica;
- b) o modelo, criado a partir da observação do fenômeno ou sistema no mundo real, deve ser validado, a fim de garantir que seus resultados sejam compatíveis e aplicáveis;
- c) os dados de entrada precisam ser corretamente inseridos no modelo;
- d) a simulação não otimiza o fenômeno ou sistema, apenas testa as alternativas que o analista que a utiliza quer averiguar.

Há diversas aplicações para simuladores, além daquelas já citadas em exemplos anteriores. Um exemplo bastante conhecido é o simulador de vôo, que pode reproduzir condições climáticas, panes e outras situações, sendo largamente utilizado na formação de pilotos. Outros exemplos a serem citados são simuladores financeiros, simuladores de linhas de produção, simuladores para avaliação de sistemas de atendimento como *call centers*, hospitais, restaurantes, aeroportos, estradas, sistemas de sinalização de vias, gerenciamento de cadeias de suprimentos, além do anteriormente mencionado sistema de gerenciamento de estoques. Esta lista é bastante extensa, não ficando limitada apenas aos exemplos comentados.

## **2.6 Otimização Combinatória**

Muitos problemas de importância prática e teórica se preocupam com a escolha da melhor configuração ou conjunto de parâmetros possível para alcançar

determinado objetivo. A Otimização Combinatória estuda problemas de otimização que possuem um conjunto finito de possíveis soluções, chamado de espaço de soluções (PAPADIMITRIOU; STEIGLITZ, 1998). É um ramo da Ciência da Computação e da Matemática Aplicada (TAHA, 1997).

Em um problema de otimização, busca-se a obtenção de uma solução para um problema. Através de uma medida de qualidade é possível medir o quão boa uma solução é. Pode-se buscar a maximização ou minimização desta medida, dependendo do problema tratado e do objetivo a ser alcançado. Em geral, é difícil determinar o quão próxima a solução encontrada está da melhor solução possível, visto que, em muitos casos, esta “melhor solução possível” é desconhecida. Desta forma, busca-se encontrar uma solução que não necessariamente é a melhor possível dentre todas as existentes, mas é boa o suficiente para que possa ser aplicada. Dado um conjunto de variáveis envolvidas em determinado problema, avaliamos as possíveis soluções para tal problema através da Função Objetivo (FO). Também conhecida como função de *fitness*, a FO é responsável por medir, em termos numéricos, a qualidade de uma solução. Ela faz isso a partir de valores associados a cada variável do problema em questão. Há também um conjunto de restrições que devem ser satisfeitas. O resultado para um problema de otimização será o maior valor obtido através da FO, para um problema de maximização, ou o menor, para um problema de minimização, sem que as restrições sejam violadas.

Em muitos problemas de Otimização Combinatória ocorre o fenômeno da Explosão Combinatória. Este fenômeno se caracteriza pela demasiada quantidade de possíveis soluções dentro do espaço de busca. Isto torna inviável a solução de tais problemas através do uso de Métodos Analíticos (também chamados de Métodos Exatos ou Exaustivos), uma vez que o tempo necessário para análise e resolução deles é demasiadamente alto. Alguns exemplos de problemas que apresentam explosão combinatória são o Problema de Roteamento de Veículos (PRV), o Problema da Mochila, o Teorema das Quatro Cores e o Problema de Otimização de Níveis de Estoque, sendo este último um dos focos deste trabalho. Na literatura, o problema de Otimização de Níveis de Estoque é classificado como *NP-Hard* (BOCTOR, 2010; FAVARETTO *et al*, 2001).

Um maior detalhamento sobre a Explosão Combinatória envolvida no problema de Otimização de Níveis de Estoque será dado na seção 4.2.

Uma alternativa para encontrar respostas para problemas deste tipo é a utilização de Métodos Aproximativos, dentre os quais destacam-se as Metaheurísticas.

## 2.7 Metaheurísticas

Metaheurísticas podem ser definidas como procedimentos ou estratégias computacionais que buscam soluções para um problema, atuando como um conjunto de regras de mais alto nível que regem heurísticas. Segundo Aurélio (FERREIRA, 1999), heurísticas são “um conjunto de regras e métodos que conduzem à descoberta, à invenção e à resolução de problemas” ou ainda “metodologia ou algoritmo para resolver problemas por métodos que, embora não rigorosos, refletem o conhecimento humano e permitem obter uma solução satisfatória”. Ainda, segundo Glover e Kochenberger (GLOVER; KOCHENBERGER, 2003), metaheurísticas são métodos de solução que realizam a interação entre procedimentos de melhora em ótimos locais e estratégias de mais alto nível, buscando criar um processo capaz de escapar destes ótimos locais, além de executar buscas robustas em todo o espaço de soluções do problema. Ao processo de exploração de partes específicas do espaço de soluções dá-se o nome de intensificação. Já ao processo de exploração de diferentes partes do espaço de soluções, dá-se o nome de diversificação.

Segundo a literatura, as Metaheurísticas podem ser classificadas de diferentes formas (GLOVER; KOCHENBERGER, 2003). Uma classificação propõe a sua divisão em metaheurísticas de Busca Populacional e de Busca por Trajetória. Os Métodos Populacionais trabalham com um conjunto de soluções por vez. A este conjunto é dado o nome de “População de Soluções”. Alguns exemplos de

metaheurísticas Populacionais são Algoritmos Genéticos (AG), *Scatter Search* (SS) e *Ant Colony Optimization* (ACO). Já os métodos de Busca por Trajetória trabalham com apenas uma solução por vez. Como exemplo deste tipo de metaheurística pode-se citar *Tabu Search* (TS), *Guided Local Search* (GLS), *Simulated Annealing* (SA) e *Variable Neighborhood Search* (VNS).

Os procedimentos até agora citados aplicam uma busca iterativa, onde, a partir de uma solução inicial  $S_0$  (ou uma população inicial de soluções, no caso dos métodos populacionais), pequenas modificações são feitas sobre ela para se obter novas soluções ou soluções vizinhas. Cada uma destas soluções obtidas pelo método é chamada de Solução Candidata e leva a uma resposta para o problema sendo analisado. A qualidade das soluções é avaliada através de uma Função Objetivo. A cada iteração, busca-se obter uma solução melhor que a anterior. Este procedimento é repetido até que se atinja um critério de parada. A solução  $S_0$  pode ser uma solução já conhecida ou então ser gerada de forma aleatória, sendo importante observar que ela deve ser viável. Para que uma solução seja viável, é necessário que ela satisfaça o conjunto de restrições impostas pelo problema em questão. Soluções candidatas que não satisfaçam a tais restrições podem ser descartadas ou corrigidas de modo a satisfazerem às restrições do problema. A solução ótima encontrada pela metaheurística é chamada de  $S^*$ .

Metaheurísticas podem ser aplicadas em problemas de otimização combinatória, sendo uma alternativa viável quando o método exato não pode ser utilizado. Elas não necessariamente irão encontrar a melhor solução possível, mas podem encontrar uma solução viável e de boa qualidade. Em geral, os problemas que necessitam da aplicação de metaheurísticas são de difícil solução, podendo ser sua solução ótima desconhecida.

Há uma vasta gama de problemas onde as metaheurísticas podem ser aplicadas. No setor produtivo, analisando linhas de produção e buscando aumentar a sua eficácia, na engenharia de tráfego, seja ele terrestre ou aéreo, nos sistemas de transporte, buscando um trajeto menor, de custo inferior ou que necessite de um tempo menor para ser completado, em sistemas de distribuição e estocagem de bens, buscando a forma ideal de armazenar produtos em vista de suas demandas e custos envolvidos, dentre outros.

### 2.7.1 Metaheurística *Guided Local Search*

Para o desenvolvimento da ferramenta computacional utilizada neste trabalho, foi utilizada a metaheurística *Guided Local Search* (GLS) para o processo de otimização. Proposta por Christos Voudouris (VOUDOURIS, 1997), esta metaheurística baseia-se em um método de Busca Local e utiliza penalidades para escapar de ótimos locais e platôs. Partindo de uma solução inicial  $S_0$ , soluções vizinhas são geradas a partir de movimentos. Estas novas soluções são obtidas com pequenas modificações na solução inicial. Este processo é executado até que uma condição de parada seja alcançada.

Para aplicar o GLS é necessário definir os atributos do problema. Os atributos são os componentes da solução. A cada atributo é associado um custo e uma penalidade. Por exemplo, em um problema de otimização de níveis de estoque, os atributos do problema podem ser as políticas de reposição de cada produto.

Além da Função Objetivo, utilizada para avaliação (*fitness*) das soluções geradas, existe uma Função Objetivo Aumentada (FOA). Ela é usada para modificar o comportamento da FO. A FOA, também denotada por  $h(s)$ , é definida pela equação (2.14) (VOUDOURIS, 1997; VOUDOURIS, TSANG, 1999). Ela pode ser uma redução em relação à FO, no caso de problemas de maximização, ou um aumento, em problemas de minimização. Isto será definido através da atribuição do valor do parâmetro  $\lambda$ . Em problemas de maximização,  $\lambda$  deve ser negativo, já em problemas de minimização,  $\lambda$  deve ter valor positivo.

$$h(s) = g(s) + \lambda \cdot \sum_{l=1}^u p_l \cdot I_l(s) , \quad (2.14)$$

onde:

- $g(s)$ : função objetivo original;
- $\lambda$ : coeficiente de intensificação (mais alto torna a busca mais diversa, mais baixo torna a busca mais intensa);
- $I_l$ : função indicadora do atributo  $l$  (1 se o atributo  $l$  é usado na solução  $s$ , 0 caso contrário);
- $p_l$ : penalidade do atributo  $l$ ;
- $l$ : indexador dos atributos;
- $u$ : total de atributos do problema;
- $s$ : solução candidata.

A penalidade de cada atributo  $l$  inicia em zero e é incrementada durante a execução da metaheurística. Isto ocorre apenas quando a Utilidade de cada atributo, calculada com base na equação (2.15), atinge um valor de Utilidade Máxima. O valor da utilidade máxima depende do problema abordado, devendo ser adequadamente calibrado. A este mecanismo dá-se o nome de penalidade seletiva.

A geração de soluções vizinhas é feita com base na FOA. Ela inclui as penalidades de cada atributo no valor da FO. Isso tende a penalizar as soluções de forma proporcional às penalidades dos atributos que a compõem. A penalização fará com que o resultado da avaliação da FOA seja sempre pior que o da FO e permitirá que soluções com menos penalizações, ou seja, com atributos menos penalizados, se destaquem com a obtenção de bons resultados (VOUDOURIS, 1997; VOUDOURIS, TSANG, 1999).

O cálculo da utilidade de cada atributo  $l$ , componente da solução  $s$ , é dada pela equação (2.15).

$$util_l(s) = I_l(s) \frac{c_l}{1 + p_l}, \quad (2.15)$$

onde:

$I_l(s)$ : função indicadora do atributo  $l$  (1 se atributo  $l$  é usado na solução  $s$ , 0 caso contrário);

$c_l$ : custo relacionado ao atributo  $l$ ;

$p_l$ : valor atual da penalidade do atributo  $l$ ;

$l$ : indexador dos atributos;

$s$ : solução candidata.

Se um atributo  $l$  é penalizado muitas vezes, seu valor de utilidade diminui, fazendo com que cada vez menos ele atinja a Utilidade Máxima e diversifique as escolhas, permitindo que outros atributos sejam usados e penalizados. As penalidades são aplicadas com uma frequência proporcional aos seus custos. Atributos de alto custo são penalizados mais frequentemente que aqueles de baixo custo. O método pressupõe que a exploração pode ser feita apenas com base nas características de custo de ótimos locais já encontrados, uma vez que somente as características de ótimos locais são penalizadas.

A estrutura básica do algoritmo GLS é apresentada na figura 2.3.

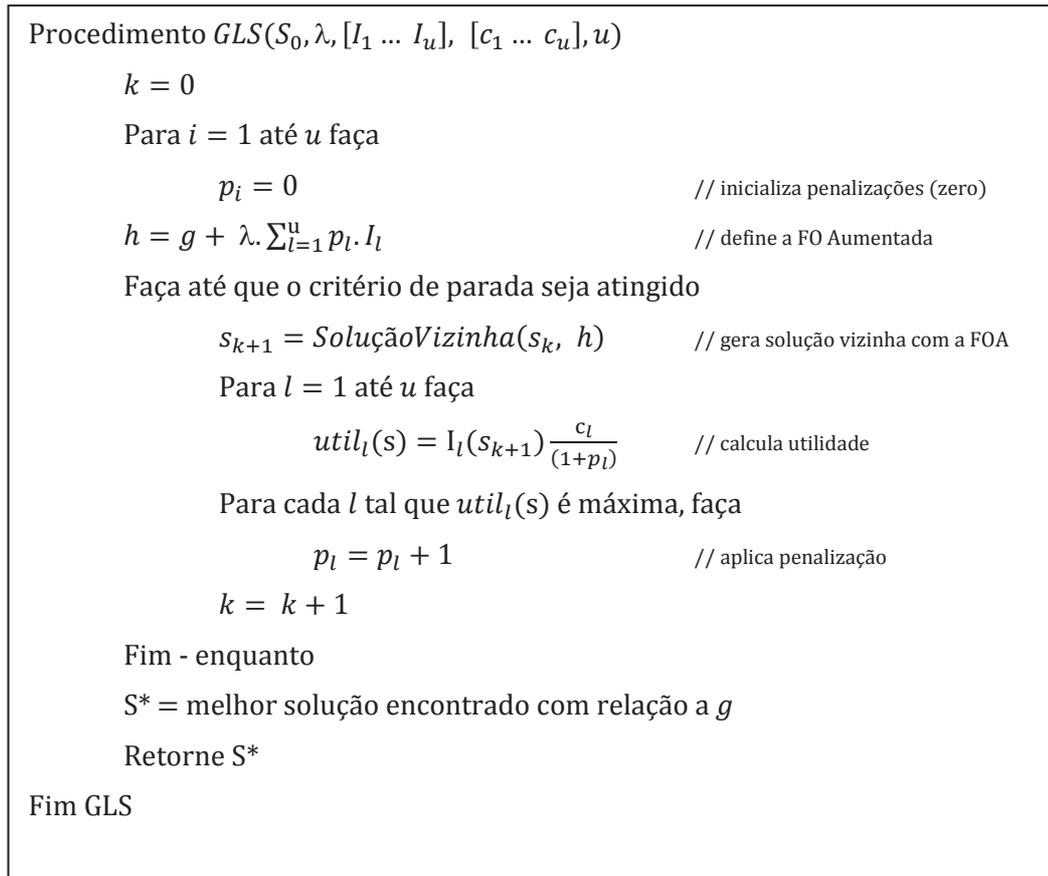


Figura 2.3 – Esquema geral do algoritmo *Guided Local Search* (GLS).  
 Fonte: Adaptado de (VOUDOURIS, 1997)

## 2.8 Otimização da Simulação

A Simulação busca entender o comportamento de fenômenos, que podem ser observados, a fim de reproduzi-los em um ambiente computacional. Esta técnica, contudo, não busca alternativas à solução de problemas, tampouco à resposta a que se chega. Um analista pode simular uma quantidade relativamente pequena de alternativas (ou cenários) utilizando simulação e escolher a que aparentemente tem o melhor desempenho para aplicá-la no mundo real (LAW; MCCOMAS, 2002). Os cenários gerados pelo analista serão baseados em sua experiência e seu sentimento. Mas e se um cenário que não tenha sido avaliado, ou simulado, tiver uma resposta melhor para o problema?

Conforme exposto na seção 2.7, existem métodos de solução de problemas de otimização que podem ser utilizados para solucionar problemas caracterizados pela Explosão Combinatória, buscando soluções ótimas ou próximas do ótimo. Isto pode ser feito através de sucessivas tentativas, guiadas por algoritmos heurísticos, buscando diferentes respostas para um mesmo problema e comparando-as. A maior resposta (em um problema de maximização) ou a menor resposta (em um problema de minimização), avaliada através de uma FO, encontrada pelo algoritmo de otimização, que não viole o conjunto de restrições do problema, será dada como a melhor alternativa.

A combinação de Simulação e Otimização trás a possibilidade de simular um sistema ou fenômeno observado e otimizá-lo. Através da tentativa de uso de diferentes cenários, isto é, diferentes parâmetros para a simulação, é viável enumerar uma grande quantidade de possíveis cenários e suas peculiaridades. Esta enumeração é automatizada e pode revelar soluções não cogitadas pelo analista. O uso acoplado de simulação e otimização para solução de problemas tem se mostrado eficiente e seu uso tem se intensificado nos últimos anos (DANIEL; RAJENDRAN, 2005; SOUZA; FILHO, 2009; MELE *et al*, 2006; JOINES *et al*, 2002).

O esquema de funcionamento da Otimização da Simulação é apresentado na figura 2.4. O Otimizador escolhe um conjunto de valores para os parâmetros de entrada e usa as respostas geradas pelo modelo de Simulação para decidir sobre a solução experimental seguinte. O processo de otimização, neste caso, busca pelos melhores valores de parametrização para a simulação (SOUZA; FILHO, 2009). Trata-se de um processo iterativo e interativo, onde as saídas de um componente servem de entrada para o outro, sucessivamente.

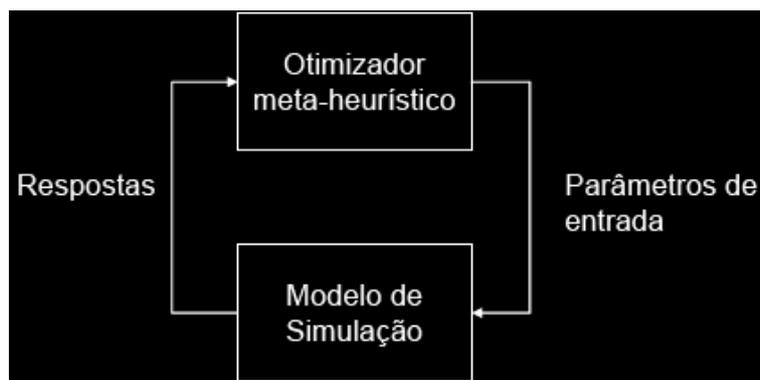


Figura 2.4 – Esquema de funcionamento da Otimização da Simulação.  
Fonte: Adaptado de (SOUZA; FILHO, 2009)

Law e McComas, (LAW; MCCOMAS, 2002) definem Otimização da Simulação como sendo a experimentação de uma sequência de diferentes configurações de um sistema, de forma a simular diferentes cenários, visando a obtenção de uma solução ótima ou próxima do ótimo. Para Ólafsson e Kim (ÓLAFSSON; KIM, 2002), uma avaliação única de desempenho, em geral, não é suficiente. Um processo mais exploratório pode ser necessário, utilizando a idéia de Otimização da Simulação.

### **3 Revisão Bibliográfica**

Neste capítulo será feito um apanhado sobre trabalhos publicados no meio científico relacionados à Previsão de Demanda e Otimização de Níveis de Estoque, assuntos estes abordados no presente trabalho. Também serão vistos trabalhos que fazem uso de Otimização da Simulação, outra técnica utilizada na construção da ferramenta computacional deste trabalho.

A idéia em abranger estes temas através de trabalhos já publicados é a de apresentar a utilização dos métodos e técnicas por outros autores em problemas semelhantes. Além disso, este capítulo dará maior visibilidade ao leitor acerca de diferentes formas existentes para resolução de tais problemas.

#### **3.1 Métodos Previsores e Previsão de Demanda**

Coelho (COELHO, 2008) propôs a utilização de modelagem de demanda através da análise de séries temporais e utilização do método de suavização exponencial para geração de previsões de demanda. Em seu trabalho ele aplica o método em três casos reais, a saber: 1) Consumo industrial de energia elétrica no estado de Santa Catarina, Brasil; 2) Vendas de cortadores de cantos de gramados e; 3) Produção de gás no Canadá. Associado ao método de previsão de demandas, Coelho utilizou gráficos de controle combinados Sheawhart-CUSUM para acompanhamento das previsões, a fim de identificar valores muito distantes dos dados observados. Tais gráficos impõem limites inferiores e superiores para os dados. Tal controle foi utilizado para que, no caso da observação de grandes discrepâncias, o modelo de previsão fosse estimado novamente. Também é possível que ocorra a necessidade de estimar novamente o modelo em função da mudança

de comportamento dos fenômenos conforme o passar do tempo. Os resultados obtidos por Coelho mostraram que o modelo de previsão por suavização exponencial, complementado pelo acompanhamento através do uso de gráficos de controle, são perfeitamente aplicáveis aos três casos estudados.

Wei e Shio (WEI; SHIO, 2009) utilizaram o método de suavização exponencial para prever vendas de *commodities* da agro-indústria (frutas e vegetais). O método desenvolvido considerava os fatores de tendência e sazonalidade. Um simulador foi usado em conjunto com o método predictor, ficando este responsável pelo ajuste dos parâmetros utilizados no método predictor. Com o uso das ferramentas desenvolvidas, os autores conseguiram obter sucesso no objetivo do trabalho, que tratava justamente de previsão de vendas, com bom nível de assertividade, especialmente nas previsões de curto prazo.

Werner e Ribeiro (WERNER; RIBEIRO, 2003) aplicaram a metodologia Box-Jenkins para previsão de demanda com relação a atendimentos de assistência técnica de computadores pessoais. Em seu trabalho, após estudar a situação de negócio da empresa, verificou-se que os atendimentos aos clientes possuíam características de tendência e sazonalidade distintas, de acordo com o segmento de mercado em que se encaixavam, logo, foram classificados em três segmentos: contratos, garantia e clientes avulsos. A análise das séries temporais foi então segmentada da mesma forma, visando reproduzir com maior fidelidade a situação da empresa. Através da análise de gráficos e testes estatísticos, verificou-se que os modelos mais apropriados para aplicação seriam:

- a) AR(1) para o segmento de contratos, o mais simples dos modelos utilizados no trabalho. Seu uso foi adotado após a verificação de que os dados da série temporal variam muito pouco em função do tempo na análise da ST;
- b) ARIMA(2, 1, 0) para o segmento garantia, modelo este um pouco mais complexo que o primeiro. Esta ST se mostrou mais dependente do tempo, uma vez que as alterações de mercado e os acordos de assistência firmados se refletem de forma gradativa para a empresa;
- c) SARIMA(0, 1, 0)(0, 1, 1)<sub>12</sub> (SARIMA representa o modelo *Seasonal* ARIMA, a variante sazonal do modelo Box-Jenkins). Este último modelo foi

o mais complexo dentro do estudo, necessitando de uso de diferenciação e sazonalidade, visto que os dados apresentavam características sazonais, ou seja, dentro dos doze meses do ano, características de cada mês se repetiam ano após ano.

O estudo destas séries temporais permitiu um melhor entendimento, por parte da empresa, em relação às demandas de seus clientes, e serviu como subsídio para tomada de decisões no que se refere a investimentos na empresa e à expansão da equipe de técnicos para atendimento.

Bacci (BACCI, 2007) combinou três métodos para prever a demanda de café no Brasil. Os métodos utilizados foram ARIMA, Dupla Suavização Exponencial e Análise de Tendência Quadrática. As previsões de demanda foram feitas, individualmente, utilizando cada um dos métodos. Posteriormente, os três métodos foram combinados, utilizando uma média aritmética simples. Foram realizados experimentos com o método combinado para geração de demandas por ano, entre 2000 e 2006. Os resultados obtidos pelos autores mostraram uma diferença entre os dados previstos e os observados que variou entre -3,45% e 3,37%. Comparando o método combinado com cada um dos seus componentes, individualmente, o método combinado apresentou o menor desvio padrão, ou seja, uma menor variabilidade.

Peixoto e Pinto (PEIXOTO; PINTO, 2006) desenvolveram um estudo dentro de uma empresa do setor siderúrgico que fabrica arames de aço, com mais de quatro mil produtos finais, utilizando cerca de seiscentos diferentes tipos de matérias-primas. O objetivo dos autores era criar e estudar diferentes cenários com relação a quanto de cada uma destas matérias-primas deveria ser comprada e armazenada para atender às necessidades de produção, evitando rupturas de estoque e minimizando os custos totais de armazenagem. Foram considerados os níveis de serviço e suas flutuações, oscilações observadas no histórico de demandas, prazos de entrega de matérias-primas por parte dos fornecedores (reabastecimento) e estoques de segurança. Segundo os autores, o horizonte de previsão deve ser de curto prazo, em função de variações de mercado e processos envolvidos no segmento do setor produtivo onde a empresa se encontra. A ferramenta desenvolvida utiliza um simulador baseado em distribuições de probabilidade, distribuições estas obtidas a partir da análise de dados históricos de

estoque e demanda, valores de estoque inicial, além de alguns parâmetros, que permitem ao tomador de decisões a geração de diferentes cenários. Dentre os parâmetros estão a priorização de compra entre os diferentes insumos, alteração da quantidade de compra individual de insumos, mesmo que o previsor de vendas não indique tal necessidade, limite máximo de aquisição individual de insumos, mesmo que o previsor de vendas indique necessidade maior, volume máximo de aquisição, considerando todos os itens do pedido e aumento dos estoques de segurança, simulando atrasos na entrega dos insumos. Com base nos dados de entrada, algumas saídas são fornecidas, criando assim os diferentes cenários. As mais interessantes são: Quantidade de Estoque Inicial no mês, Quantidade de Estoque de Segurança, Previsão Mínima, Média e Máxima simulada, Sugestão de Pedido para o período e Estoque Final.

Odan (ODAN, 2010), em seu trabalho, utilizou Redes Neurais Artificiais na previsão de demanda de sistemas de abastecimento de água. Foram utilizadas quatro redes durante a pesquisa, uma RNA Perceptron de Múltiplas Camadas (RNA MLP, do inglês *Multiple Layer Perceptron*), uma Rede Neural Dinâmica (RNA DAN2, do inglês *Dynamic Artificial Neural Network*), além de duas redes híbridas, associando Séries de Fourier com as redes já citadas, RNA MLP e DAN2, sendo estas redes híbridas denominadas RNA-H e DAN2-H, respectivamente. A partir de dados observados, foram determinados os fatores de correlação com fatores meteorológicos como temperatura, umidade relativa do ar e ocorrência de chuvas. Em suas conclusões, o autor aponta, como melhor alternativa para previsão das demandas em questão, a utilização das Redes Neurais Dinâmicas (DAN2 e DAN2-H), uma vez que estas, ao contrário das redes neurais de múltiplas camadas, não necessitam do processo de tentativa e erro para determinação da melhor arquitetura para os dados fornecidos ao modelo.

Sacha (SACHA, 2008) utilizou redes neurais artificiais em seu trabalho para prever as demandas por equipamentos de infra-estrutura de telecomunicações. Ele ressalta que prever demandas neste setor de mercado é um grande desafio em função do grande número de variáveis envolvidas e pela crescente concorrência e competitividade existente no mercado. Em síntese, o autor desenvolveu 15 modelos utilizando redes de Múltiplas Camadas (RNA MLP) e 36 modelos utilizando redes de Função de Base Radial (RNA RBF) para previsão de demandas considerando cinco

variáveis: Percentual de Assinantes que utilizam planos do tipo pós-pago, Número de assinantes da tecnologia GSM, Total de Estações Rádio Base no Brasil, considerando todas as operadoras de telefonia móvel no País, Total de TRX (transceptores GSM) fornecidos pela empresa em estudo, além do Rendimento Médio Mensal da população brasileira (baseado em dados do IBGE). Os resultados obtidos indicaram que as redes MLP apresentaram melhores resultados quando comparadas às redes RBF. Além disso, foram observados ganhos quando os resultados obtidos em seu modelo predictor foram comparados com os dados de previsão que atualmente são utilizados pela organização estudada durante sua pesquisa.

### **3.2 Otimização de Níveis de Estoque**

Coelho (COELHO, 2008), já citado anteriormente na seção 3.1, aplicou o modelo de controle de estoques do jornaleiro em seu trabalho, quando analisando o terceiro caso real (produção de gás pelo Canadá) em sua dissertação. Este modelo baseia-se na idéia de que o jornaleiro precisa comprar, no início do dia, uma quantidade suficiente para atender a todas as demandas, mas não superior a elas, pois, no dia seguinte, o jornal não terá mais qualquer valor. Assim, as previsões geradas pelo método da suavização exponencial serviram de entrada para o modelo de controle de estoque. Este, por sua vez, assumiu as informações de demanda para suprir o estoque de forma determinística. Trata-se de um modelo bastante simples, que não considera qualquer característica estocástica. Como saída, Coelho obteve os valores ótimos de volume de estoques a serem mantidos.

Joines e colaboradores (JOINES *et al*, 2002) propuseram uma abordagem para analisar os custos envolvidos na estocagem de produtos através do indicador *Gross Margin Return On Investment* (GMROI), que representa uma medida de

desempenho da empresa, um indicador de razão entre o Lucro Bruto e o Custo Médio de Estocagem, conforme a equação (3.1).

$$GMROI = \frac{\textit{Lucro Bruto}}{\textit{Custo Médio de Estocagem}} \quad (3.1)$$

Em suas conclusões, os autores indicam que é possível aumentar o GMROI em cerca de 90% com a diminuição do atendimento de demandas de clientes (nível de serviço) de 95% para 92%. Apesar de parecer contraditório no primeiro instante, tal resultado foi possível pois houve uma redução nos níveis de estoque e consequente redução do Custo Médio de estocagem. O Lucro Bruto também foi reduzido em função do não atendimento de algumas demandas dos consumidores, mas foi consideravelmente menor do que a redução dos custos. Em seu trabalho, os autores utilizaram Algoritmos Genéticos para tratar este problema, buscando o melhor conjunto de parâmetros para um simulador já existente, cujos detalhes serão dados na seção 3.3.

Rodriguez e Vecchiatti (RODRIGUEZ; VECCHIETTI, 2010) propuseram um modelo de otimização multi-objetivo para pedidos de materiais, estocagem e entrega de mercadorias com demanda sazonal dentro de uma cadeia de suprimentos. Dois modelos, utilizando uma abordagem não-linear, foram desenvolvidos para resolução do problema. O primeiro considerava aspectos do planejamento de aquisições, como tamanho do lote de compra (uma vez que, quanto maior o lote, maior o desconto obtido) e os custos envolvidos em estocagem (uma vez que, quanto maior o pedido, maior o custo de estocagem). Estes dois aspectos andam em direções contrárias pois, se existe uma redução de gasto por um dos aspectos, existirá um aumento por parte do outro. O segundo modelo contemplava o aspecto das entregas parciais do pedido. Em função da demanda sazonal, entregas parciais mal dimensionadas podem acarretar grandes prejuízos para a empresa. Os resultados do trabalho ajudaram a empresa a identificar que era necessário ter diferentes fornecedores para atender às suas demandas de materiais e à imposição de cláusulas contratuais para fornecimento, uma vez que a sazonalidade existente no caso estudado era bastante presente, com grandes variações em função do tempo.

Isto tudo visava prover maior segurança no que se refere ao atendimento de suas demandas.

Radhakrishnan e colaboradores (RADHAKRISHNAN *et al*, 2009) propuseram uma abordagem para otimização de níveis de estoque dentro da cadeia de suprimentos através da utilização de Algoritmos Genéticos. A cadeia de suprimentos onde o processo de otimização foi aplicado continha três componentes: a) a fábrica, b) o centro de distribuição 1 e c) o centro de distribuição 2. Eles eram, nesta ordem, interdependentes. O trabalho tem como objetivo encontrar o valor ótimo para os custos de estocagem, para a cadeia de suprimentos como um todo, de modo a garantir o atendimento mínimo de demandas. Tais demandas foram previamente geradas em cada um dos três componentes. Com o auxílio da ferramenta MATLAB, os autores desenvolveram e avaliaram o método proposto. Apesar de não quantificar os resultados em suas conclusões, os autores afirmam ter obtido bons resultados com a ferramenta por eles construída.

Mele e colaboradores (MELE *et al*, 2006) também fizeram uso de Algoritmos Genéticos para a otimização em uma cadeia de suprimentos. O objetivo do otimizador era maximizar a lucratividade obtida na CS como um todo. Isto foi feito através da escolha da parametrização ideal para um simulador que representava a CS (este simulador será descrito na seção 3.3). Com base nos resultados obtidos com o uso do simulador, uma função objetivo avaliava o lucro total obtido com esta configuração.

Giglio e colaboradores (GIGLIO *et al*, 2008) desenvolveram um trabalho que se propôs a minimizar os custos de estocagem, produção e não atendimento de demandas de um sistema do tipo *Hybrid Inventory-Production* (HIP). O modelo HIP consiste em um estoque de entrada (matérias-primas), um processo de produção ou transformação, e um estoque final, onde os produtos fabricados serão novamente estocados. Apesar de estes dois estoques pertencerem a uma mesma empresa, é possível entendê-los como componentes de uma cadeia de suprimentos de dois níveis. A demanda pelos produtos fabricados pela empresa é regida pelas solicitações de seus clientes, logo, tem uma característica estocástica. Duas propostas de solução foram desenvolvidas para o processo de otimização, que considera tanto os esforços para produção dos bens quanto os dois distintos níveis

de estoque. A primeira proposta faz uso de Programação Matemática Não-Linear Inteira Mista. A segunda utiliza Programação Linear. Para que esta última pudesse ser utilizada, algumas simplificações precisaram ser efetuadas no modelo. Em suas conclusões, os autores ressaltam a contribuição que o trabalho trouxe pela proposição dos modelos que, apesar de estarem dentro de uma mesma empresa nos experimentos feitos, eles podem ser aplicados a cadeias de suprimento com diferentes níveis de estoque.

Boctor (BOCTOR, 2010) propôs o uso de três diferentes heurísticas para tratar de um problema de escalonamento de reposição de estoques de produtos com demanda constante e ciclos de reposição conhecidos. A proposta do autor foi a de encontrar soluções que minimizassem o espaço físico necessário para estocagem de um conjunto de produtos através do uso de uma heurística chamada de *two-step hybrid* (TSH) e da metaheurística *Simulated Annealing*. O autor ainda comparou os métodos propostos por ele com um terceiro, de outro autor. Em suas conclusões, o autor aponta a heurística TSH como a melhor, tanto em termos de resultados quanto em rapidez para obtenção de soluções ótimas.

### **3.3 Otimização da Simulação**

Souza e Filho (SOUZA; FILHO, 2009) propuseram um modelo de Simulação computacional para auxiliar na avaliação de desempenho e estudo de cenários de uma cadeia de suprimentos que produz um combustível especial. Um modelo de simulação foi desenvolvido reproduzindo a situação atual do sistema. Tal modelo foi construído de forma a permitir mudanças em seus parâmetros. A partir daí foram feitas algumas variações para estudar novas configurações e cenários alternativos. Contudo, a quantidade de combinações possíveis dos parâmetros do modelo para simulação era tão grande que inviabilizava a análise de todas as possibilidades de configuração do sistema. Em função disto, a metodologia foi complementada com o

desenvolvimento e utilização de uma ferramenta que automatiza as alterações dos parâmetros e busca pelas melhores soluções, caracterizando a Otimização da Simulação. O otimizador/metaheurística utilizado pelos autores é um módulo do *software* comercial Arena, chamado OptQuest. Este otimizador utiliza uma abordagem evolucionária, gerando populações de possíveis soluções, buscando a escolha do melhor conjunto de parâmetros para o modelo de Simulação. Em seu texto, os autores não especificam exatamente qual é a metaheurística utilizada. Os resultados obtidos pelos autores se mostraram coerentes, possibilitando análises de cenários e configurações alternativas para a cadeia de suprimento, permitindo fazer inferências sobre as melhores alternativas frente aos cenários que a cadeia de suprimento em questão pode vir a enfrentar.

Daniel e Rajendran (DANIEL; RAJENDRAN, 2005) propuseram um método para avaliação de desempenho de uma cadeia de suprimentos de apenas um produto. Tal método visa otimizar os níveis de estoque, minimizando os custos de estocagem e aqueles decorrentes da falta de produto, na CS como um todo. A minimização dos custos de estocagem e por falta de produtos é feita através da utilização de um AG. Em seguida, os valores de níveis de estoques gerados pelo AG são submetidos a uma simulação, que considera diversas características inerentes à CS, visando avaliar os resultados produzidos frente aos possíveis cenários que a CS pode apresentar. Para fins de validação da solução proposta, os autores compararam os resultados obtidos com o AG com resultados de uma solução determinística, isto é, que varre todo o espaço amostral de possíveis soluções para o problema. A solução encontrada pelo AG não difere significativamente da solução ótima obtida pelo método determinístico.

Mele e colaboradores (MELE *et al*, 2006) também propuseram a utilização de otimização da simulação em seu trabalho. O AG integrado à solução proposta buscava a maximização da lucratividade na cadeia de suprimentos, através da escolha da parametrização ideal para um simulador de eventos discretos, que era responsável por representar o comportamento da CS estudada. A estratégia de executar sucessivas tentativas dirigidas, através da criação de diversos cenários, automatiza a tarefa de tomadores de decisão em tentar gerar tais cenários de forma manual, sendo esta a principal contribuição do trabalho, enfatizada pelos autores em suas conclusões.

Cabe nesta seção citar novamente o trabalho de Joines e colaboradores (JOINES *et al*, 2002) onde foi proposta uma abordagem semelhante às já expostas. Em seu trabalho eles utilizam um simulador chamado *Sourcing Simulator* para analisar vendas no varejo. Através da utilização de um otimizador metaheurístico, construído a partir dos conceitos de AG, eles buscam a otimização do indicador GMROI. O otimizador altera os parâmetros de entrada do simulador para geração de diferentes cenários. Em geral busca-se aumentar a lucratividade com maior volume de vendas, mas neste caso foi mostrado que o desempenho ótimo da empresa não pode se basear apenas em lucros, a questão dos custos envolvidos para obtenção do lucro máximo também precisa ser analisada. Esta configuração de sistema foi obtida através da avaliação de diferentes cenários, todos criados pelo processo de otimização.

## **4 Metodologia**

Neste capítulo será apresentada a metodologia adotada para solução do problema de otimização de níveis de estoque. Será dada uma descrição sobre a rede varejista, sobre o problema envolvido, os objetivos do trabalho, geral e específicos, a organização e disponibilidade dos dados para utilização e análise, bem como um detalhamento do modelo utilizado para solução do problema.

### **4.1 Provedor dos dados**

No presente trabalho será analisado o caso de uma rede varejista que atua em alguns estados do território Brasileiro. Esta rede comercializa produtos alimentícios, utilidades domésticas e bazar, eletro-eletrônicos, brinquedos, bebidas, produtos de higiene e limpeza, vestuário, dentre outros.

A amostra de dados disponível se refere às quantidades vendidas e reposições de estoques, observados durante um período de aproximadamente dois anos. No total são 317 lojas e 2.236 produtos. A utilização de dados reais é de grande valia, visto que eles descrevem o comportamento das demandas. Já os custos de estocagem e reposição, além dos lucros obtidos por item vendido são hipotéticos. Isto não compromete a validade da ferramenta, uma vez que são utilizados para medida de desempenho. Custos e lucros por item podem facilmente ser alterados para que a ferramenta seja utilizada num contexto fiel à realidade da organização em questão.

## 4.2 Problema de Otimização de Níveis de Estoque

O problema de otimização de níveis de estoque, tratado neste trabalho, possui algumas peculiaridades que o levam a apresentar a característica conhecida como Explosão Combinatória, exposta na seção 2.6. Dada a quantidade de pontos de venda, a quantidade de itens comercializados, as diversas possibilidades para repor os estoques, ou seja, quantas unidades de cada produto devem ser reabastecidas em cada local e com que frequência, as demandas estocásticas e outras peculiaridades envolvidas, o problema apresenta-se na identificação da melhor forma de gerenciar e distribuir os estoques de produtos, visando atingir o melhor resultado possível para a empresa. Em outras palavras, busca-se determinar qual é o melhor arranjo dentre todas as possíveis combinações de quantidade de cada produto que deve ser estocado em cada ponto de venda e quando estas reposições devem ocorrer. O problema também pode ser descrito pela indicação de até que ponto compensa pagar os custos de estocagem para atendimento da totalidade da demanda de cada um dos produtos em cada um dos pontos de venda. A enumeração de todas as possíveis soluções para o problema é bastante alta, não sendo possível solucioná-lo de forma analítica. Trata-se de um problema de complexidade computacional *NP-hard* (BOCTOR, 2010; FAVARETTO *et al*, 2001).

São diversas as possíveis soluções para o problema em questão. Dentro deste conjunto de soluções, existem aquelas que podem não respeitar as possíveis restrições envolvidas no problema, ou seja, são soluções ineficazes ou não viáveis. Dentro do conjunto das demais soluções, viáveis, existe uma solução ótima e, para encontrá-la, seria necessário avaliar cada uma das soluções deste conjunto segundo um critério de avaliação estabelecido. Apesar da tecnologia hoje disponível, encontrar a melhor solução de forma exata exigiria esforço computacional excessivo e inviável de ser implementado. Faz-se necessária, assim, a utilização de métodos não exatos para encontrar uma solução. Tal solução pode não ser a melhor existente, mas será suficientemente boa para ser aplicada.

### 4.3 Disposição dos Dados Históricos

Um histórico de dados incluindo vendas e níveis de estoque de cerca de dois anos está disponível para utilização. Esta extensão de dados possibilita a identificação de sazonalidade e tendências nas séries temporais de demanda por produtos que apresentem tais características.

A disposição dos dados é bastante detalhada, conforme exemplo da figura 4.1. Para cada ponto de venda e cada produto tem-se a informação de nível de estoque e venda, com frequência diária. É importante esclarecer que o valor contido na coluna “Estoque” não representa o número de unidades repostas, mas sim quantas unidades estão fisicamente presentes no estoque.

Teoricamente existem dados para todas as possíveis combinações entre produtos, locais e dias. Quando determinado local não dispõe de certos produtos para venda, isto indica que tais produtos não fazem parte do *Mix* de Produtos da loja. Este tipo de situação é comum, de certa forma. Isto não significa que o produto não foi vendido naquele dia em determinada loja, mas sim que ele não é oferecido.

Na figura 4.1 a situação de um produto não pertencer ao *mix* da loja é exemplificada.

| Local | Produto | Data       | Estoque | Venda |
|-------|---------|------------|---------|-------|
| L1    | P1      | 01/01/2008 | 10      | 8     |
| L1    | P2      | 01/01/2008 | ...     | ...   |
| L1    | P4      | 01/01/2008 | 50      | 33    |
| L1    | ...     | 01/01/2008 | ...     | ...   |
| L1    | Pj      | 01/01/2008 | 56      | 38    |
| ...   | ...     | ...        | ...     | ...   |
| Li    | Pj      | 31/12/2008 | 48      | 13    |

← Produto 3 não faz parte do *Mix* da Loja 1

Figura 4.1 – Disposição dos dados e exemplo de produto não pertencente ao *mix* da loja.  
Fonte: Autor.

Uma limitação em relação aos dados disponíveis é de que o histórico de cerca de dois anos não existe para todos os produtos. É o caso de produtos descontinuados e lançamentos. Tal limitação afeta o processo de previsão de demandas. Esta questão será detalhada na seção 4.5.2, que aborda o módulo previsor de demandas.

Além da tabela com os dados de venda e estoque, existe ainda o Cadastro de Produtos. Neste cadastro estão contidas informações relevantes de cada produto. Tais informações são apresentadas na tabela 4.1.

Tabela 4.1 – Cadastro de Produtos.

| <b>Coluna</b>                 | <b>Descrição</b>  |
|-------------------------------|---|
| Código                        | Código do produto.  |
| Descrição                     | Descrição do produto.   |
| Categoria                     | Nível de classificação ou agrupamento de produtos.  |
| Custo Estocagem Dia           | Valor monetário que indica quanto custa manter uma unidade do produto em estoque, durante um dia. Valor hipotético.   |
| Custo Unitário de Reposição   | Valor monetário que indica quanto custa repor uma unidade do produto. Valor hipotético.   |
| Custo Lote de Reposição       | Valor monetário que indica quanto custa repor um lote inteiro do produto (exemplo, frete). Valor hipotético.  |
| Lucro Unitário                | Valor monetário que indica o lucro bruto por unidade vendida. Valor hipotético.   |
| Intervalo Mínimo de Reposição | Quantidade mínima de dias entre duas reposições consecutivas. Está relacionado à capacidade de produção e entrega por parte dos fornecedores. Valor hipotético. |

Fonte: Autor.

#### **4.4 Ajustes e Preparação dos Dados Observados**

A primeira fase do desenvolvimento do presente trabalho foi a análise dos dados coletados. Foram verificados alguns problemas nesta amostra. Para corrigir tais problemas, alguns procedimentos automatizados foram criados. Os ajustes efetuados compreendem:

- a) inserção de períodos omitidos para alguns produtos e/ou lojas onde existiam falhas na uniformidade cronológica dos dados, isto é, nem sempre havia o intervalo de um dia entre duas observações, característica esta necessária em uma ST;
- b) correção de baixas indevidas de estoque, isto é, situações onde o estoque do dia posterior não refletia o estoque do dia anterior menos a quantidade de unidades vendidas e;
- c) correção de níveis de estoque zerados, ou seja, erros de coleta já que não é possível ter um estoque físico negativo.

#### **4.5 Objetivos do trabalho**

Para alcançar o Objetivo Geral, um conjunto de atividades intermediárias precisou ser executada. Estas atividades, denominadas Objetivos Específicos, serão descritas nas seções 4.5.1 a 4.5.10.

### 4.5.1 Objetivo Geral

O presente trabalho tem como objetivo principal a criação de uma ferramenta para otimização dos níveis de estoque de uma rede varejista, ou seja, encontrar uma forma de repor o estoque de cada produto em cada loja da rede, buscando o equilíbrio entre atendimento de demandas e os custos de armazenagem e reposição envolvidos. Através do desenvolvimento e utilização de um modelo de otimização, será buscada a maximização dos resultados da rede varejista como um todo, segundo um critério de avaliação. O modelo de otimização e o critério de avaliação e seus componentes serão detalhadamente descritos na seção 4.5.6.1.

A figura 4.2 apresenta a modularização da ferramenta computacional criada durante o desenvolvimento do presente trabalho e a forma como cada módulo interage com os demais. A ferramenta é composta por quatro módulos: um previsor de demandas, um gerador de política inicial de reposição de estoques, um simulador e um otimizador.

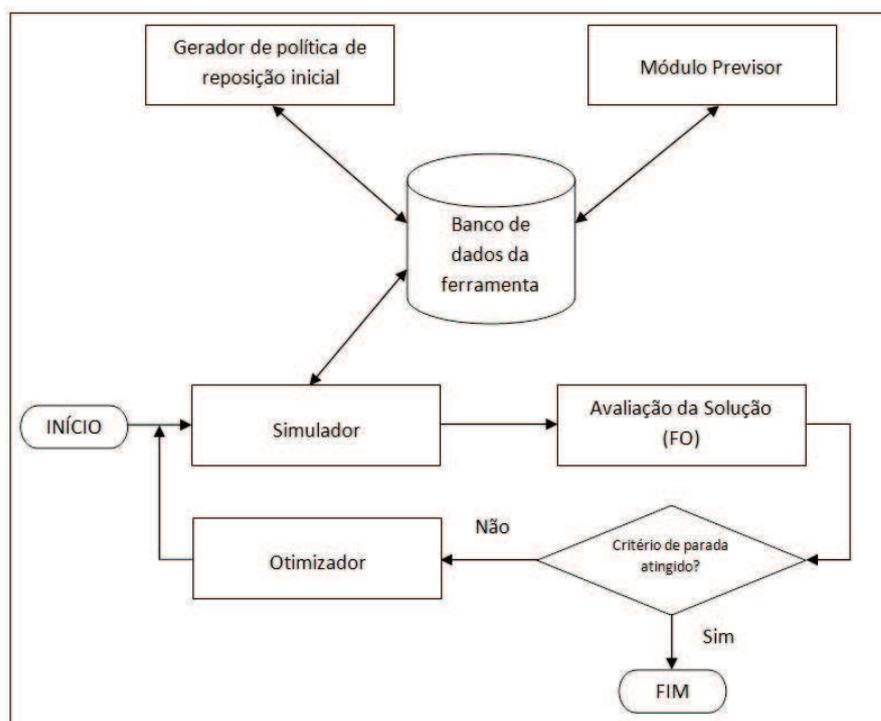


Figura 4.2 – Diagrama geral da ferramenta desenvolvida.  
Fonte: Autor

#### 4.5.2 Módulo de Previsão de Vendas

Projetar o futuro é o primeiro passo em busca do objetivo de controlar eficientemente os níveis de estoque. É necessário saber, ou pelo menos ter uma medida confiável, da quantidade de unidades de cada produto que será requerida em determinado horizonte de tempo, em cada um dos pontos de venda. O módulo responsável por esta função é o previsor. Este nome será utilizado para referenciar o módulo de previsão de vendas.

Dentre os modelos de previsão de demanda pesquisados, o método Holt-Winters foi selecionado para ser utilizado neste trabalho. Trata-se de um modelo de Suavização Exponencial com Sazonalidade Multiplicativa que considera também o fator de tendência. A escolha foi baseada na relação custo/benefício para desenvolver o método, ou seja, o custo (ou esforço) de desenvolvimento do módulo e os possíveis benefícios obtidos com a utilização da técnica. Cabe salientar que o objetivo principal deste trabalho é propor e desenvolver uma ferramenta para otimização de níveis de estoque de uma rede varejista, com base em uma previsão de demandas. O módulo previsor se faz necessário para a completude do trabalho, de modo a conferir maior robustez à ferramenta computacional desenvolvida.

Durante o processo de previsão, deve ser considerado o fator de localização do ponto de venda, já que um mesmo produto pode apresentar diferentes comportamentos de demanda em locais distintos. A SE não trata desta questão. Por esta razão, para um mesmo item, serão geradas tantas previsões quantos forem os locais em que ele é vendido. A intenção com esta individualização da previsão de demanda por loja é justamente considerar a diferenciação de consumo entre localidades distintas, buscando maior acerto nas previsões. Desta forma, diferentes fatores, como poder aquisitivo das diferentes regiões de atuação da rede e hábitos de consumo local, podem ser suprimidos do modelo de previsão, já que a técnica utilizada baseia-se em dados de vendas de períodos anteriores das próprias lojas, simplificando assim a condução do processo de previsão. Considerar os produtos de forma individualizada em relação às lojas é algo semelhante a considerar a rede

varejista com uma única loja, porém com centenas de milhares de produtos, cada qual apresentando um diferente comportamento em relação às suas demandas.

A SE requer a definição de três parâmetros de suavização,  $A$ ,  $B$  e  $C$ , que são utilizados nos componentes de nível, tendência e sazonalidade. Escolher apropriadamente o valor destes três parâmetros é fundamental para obtenção de previsões condizentes com o comportamento da ST. Lembrando, o método indica que os valores para  $A$ ,  $B$  e  $C$  que produzirem o menor valor para o somatório dos erros observados ao quadrado, segundo a equação (2.2), devem ser utilizados para condução do processo de previsão. Na relação a seguir, alguns problemas encontrados no processo de previsão de demandas (no contexto deste trabalho) serão listados:

- a) O volume de produtos e locais é bastante grande dentro da amostra de dados utilizada neste trabalho. Testar diversas alternativas de combinações para os três parâmetros para mais de 2.000 produtos em quase 700 de lojas levaria a uma situação onde um grande tempo seria necessário para encontrar os melhores valores de  $A$ ,  $B$  e  $C$ ;
- b) Nem todos os produtos possuem um histórico longo o suficiente (dois anos) para avaliação. Esta questão é bastante importante, uma vez que o período de um ano foi considerado como ciclo sazonal, ou seja, dentro de um ano é possível observar a sazonalidade ocasionada por datas comemorativas, estações do ano, dentre outros. Ainda, produtos recentemente lançados podem não possuir histórico longo;
- c) O módulo predictor precisa ser genérico o suficiente para que possa ser aplicado a uma vasta gama de diferentes produtos com diferentes comportamentos, porém precisa estar apoiado em métricas que permitam verificar a reprodução do comportamento das séries temporais observadas.

Optou-se então por definir o valor dos parâmetros do modelo com base na categoria de produtos. Conforme apresentado na tabela 4.1, cada produto pertence a uma categoria e entende-se que estes produtos tenham características e comportamentos semelhantes. Então, para prever as demandas dos produtos de uma mesma categoria, foram utilizados os mesmos valores para  $A$ ,  $B$  e  $C$ . Desta

forma, para cada produto dentro de cada categoria, foram apurados os montantes de venda. O produto possuidor do maior volume de vendas dentro da categoria, nos dois anos observados, foi escolhido como base para geração dos três parâmetros segundo o método dos mínimos quadrados, equação (2.2). Foi então desenvolvido um processo automatizado para avaliação dos possíveis valores de  $A$ ,  $B$  e  $C$ . Cada um dos parâmetros varia de 0,05 até 0,95, incrementados de 0,05 em 0,05. Isto gera 6.859 ( $19^3$ ) possíveis combinações para  $A$ ,  $B$  e  $C$ , para cada categoria, dezenove no total. Este valor é significativamente menor caso fossem avaliados os mais de 2.000 produtos comercializados em mais de 300 lojas.

O processo de previsão pode ser resumido em três passos:

1. selecionar um produto por categoria que tenha dois anos de dados e seja possuidor do maior volume de vendas observado;
2. selecionar os parâmetros  $A$ ,  $B$  e  $C$  que minimizam  $S$ , segundo a equação (2.2), para os produtos selecionados no passo 1;
3. conduzir o processo de previsão de demandas para cada produto, em cada loja, considerando os valores de  $A$ ,  $B$  e  $C$  de sua categoria, definidos no passo 2.

As previsões de demanda obtidas com o previsor foram assumidas como satisfatórias e foram utilizadas no módulo de simulação. A idéia é que cada um dos componentes integrantes da ferramenta computacional desenvolvida possa ser utilizado independentemente, tornando tal ferramenta modulável. Esta modularização foi feita tendo em mente que o otimizador (e também o simulador, pois trabalham em conjunto) possam ser utilizados sobre dados de demanda prevista gerados por qualquer outra ferramenta. Vale lembrar que o objetivo deste trabalho é a otimização dos níveis de estoque de uma rede varejista e não a previsão de demandas. Ela é necessária no trabalho pois não haveria grande valor em otimizar os níveis de estoque de dados observados, uma vez que eles já ocorreram e não podem ser alterados. Contudo, com base em previsões de demanda, ou seja, acontecimentos futuros, pode ser sugerida e aplicada uma política de reposição de estoques que apresente bons resultados.

Um modelo previsor que utilize SE necessita de um método de inicialização. No presente trabalho, a inicialização da previsão foi feita a partir da média das cinco observações do final do primeiro ano de dados.

Uma observação importante a ser feita neste ponto é de que as previsões de demanda estão sendo feitas com base em dados coletados no ponto mais próximo do consumidor final. Na seção 2.3 foi visto que, quanto mais próxima a previsão de demanda for do comportamento observado do consumidor final, menor será a distorção provocada pelo Efeito Chicote.

O módulo previsor terá como saída a Lista de Eventos de Demanda (LED) motivadas por venda. Para cada produto em cada loja existirá uma LED, conforme exemplificado na tabela 4.2.

Tabela 4.2 – Exemplo de saída do módulo previsor com a Lista de Eventos de Demanda.

| <b>Local</b> | <b>Produto</b> | <b>Data</b> | <b>Unidades Vendidas</b> |
|--------------|----------------|-------------|--------------------------|
| L1           | P1             | 01/01/2010  | 150                      |
| L1           | P1             | 01/11/2010  | 168                      |
| ...          | ...            | ...         | ...                      |
| L1           | P1             | 31/12/2010  | 133                      |

Fonte: Autor

No exemplo contido na tabela 4.2 tem-se a previsão diária de demanda pelo produto P1 na loja L1, ou seja, quantas unidades do produto serão demandas naquele local na referida data. Cada linha da tabela representa um evento de demanda.

### 4.5.3 Codificação da Solução do Problema

Para representar as reposições de estoque de um produto em uma loja, foi criada uma estrutura chamada de Política de Reposição de Estoques (PRE). A PRE é uma lista ou conjunto de eventos de reposição ( $er$ ). Cada um destes eventos traz três informações, a data em que ele ocorre, a quantidade de unidades do produto que são repostas e o intervalo de dias desde a última reposição, ou seja, quantos dias existem entre duas reposições consecutivas. A exceção a esta regra ocorre para a primeira reposição, ela sempre terá o valor zero, uma vez que não é possível calcular o número de dias desde a reposição anterior, visto que ela está em um instante de tempo fora dos limites dos dados observados. A tabela 4.3 traz um exemplo de PRE.

Tabela 4.3 – Política de Reposição de Estoques (PRE).

| <b>Data</b> | <b>Qtd. Unidades Repostas</b> | <b>Intervalo Reposição Anterior</b> |
|-------------|-------------------------------|-------------------------------------|
| 01/02/2010  | 150                           | 0                                   |
| 27/02/2010  | 168                           | 26                                  |
| ...         | ...                           | ...                                 |
| 02/01/2011  | 133                           | 6                                   |

Fonte: Autor

A PRE de um produto  $k$  ( $PRE_k$ ) pode ser definida matematicamente pelo conjunto (4.1).

$$PRE_k = \{er_1, er_2, \dots, er_{m_k}\} \quad , \quad (4.1)$$

onde:

$m_k$ : total de eventos de reposição do produto  $k$  em  $PRE_k$ .

O tamanho de  $PRE_k$  é variável, é possível que um produto tenha 20 eventos de reposição em um ano, outro tenha 25, 50, 80 e assim por diante. O intervalo de reposição também é variável, não há regra que imponha um valor fixo para este intervalo. A única restrição é que este intervalo não pode ser inferior ao intervalo mínimo entre reposições do produto, informação esta constante do cadastro de produtos, definido na tabela 4.1.

É importante salientar que a tabela 4.3 representa a PRE de apenas um produto em um local, contudo, uma rede varejista é composta por diversas lojas que vendem diversos produtos, logo, será necessário ter uma PRE para cada produto vendido em cada uma das lojas. Ao conjunto de todas as PREs necessárias na rede varejista dá-se o nome de Solução de Reposição (SR). A SR pode ser definida como um conjunto de PREs, uma para cada produto em cada loja, conforme o conjunto (4.2).

$$SR = \{PRE_1, PRE_2, \dots, PRE_j\} \quad , \quad (4.2)$$

onde:

$j$ : quantidade de PREs na solução.

Para exemplificar, a figura 4.3 representa a solução para o problema considerando uma rede varejista hipotética que contém duas lojas e três produtos. Neste exemplo, a solução completa é composta por seis PREs.

| <b>Loja A</b>    |                        |                              |
|------------------|------------------------|------------------------------|
| <b>Produto 1</b> |                        |                              |
| Data             | Qtd. Unidades Repostas | Intervalo Reposição Anterior |
| 01/02/2010       | 150                    | 0                            |
| 27/02/2010       | 168                    | 26                           |
| ...              | ...                    | ...                          |
| 02/01/2011       | 133                    | 6                            |
| <b>Produto 2</b> |                        |                              |
| Data             | Qtd. Unidades Repostas | Intervalo Reposição Anterior |
| 05/02/2010       | 330                    | 0                            |
| 25/02/2010       | 360                    | 20                           |
| ...              | ...                    | ...                          |
| 22/12/2010       | 300                    | 10                           |
| <b>Produto 3</b> |                        |                              |
| Data             | Qtd. Unidades Repostas | Intervalo Reposição Anterior |
| 01/03/2010       | 80                     | 0                            |
| 20/03/2010       | 70                     | 19                           |
| ...              | ...                    | ...                          |
| 31/12/2010       | 110                    | 15                           |
| <b>Loja B</b>    |                        |                              |
| <b>Produto 1</b> |                        |                              |
| Data             | Qtd. Unidades Repostas | Intervalo Reposição Anterior |
| 10/02/2010       | 850                    | 0                            |
| 26/02/2010       | 1.200                  | 16                           |
| ...              | ...                    | ...                          |
| 02/01/2011       | 750                    | 8                            |
| <b>Produto 2</b> |                        |                              |
| Data             | Qtd. Unidades Repostas | Intervalo Reposição Anterior |
| 15/03/2010       | 120                    | 0                            |
| 26/04/2010       | 110                    | 11                           |
| ...              | ...                    | ...                          |
| 29/12/2010       | 130                    | 15                           |
| <b>Produto 3</b> |                        |                              |
| Data             | Qtd. Unidades Repostas | Intervalo Reposição Anterior |
| 28/02/2010       | 30                     | 0                            |
| 23/03/2010       | 20                     | 23                           |
| ...              | ...                    | ...                          |
| 30/12/2010       | 12                     | 12                           |

Figura 4.3 – Solução para o problema de Reposição de Estoques.  
Fonte: Autor.

Uma PRE, específica de um produto em uma loja, não poderá ser utilizada para outro produto e/ou outra loja. Na verdade, uma PRE não tem influência sobre outros produtos em outras lojas. A razão para isto é o fato de que as demandas para diferentes produtos podem ser bastante diferentes.

#### **4.5.4 Gerador de Política de Reposição Inicial**

Em geral, a utilização de metaheurísticas para solução de problemas de otimização sempre parte de uma solução inicial válida  $S_0$ . Dentro do contexto deste trabalho existem duas formas para obter  $S_0$ . A primeira é com base na forma de reposição observada no sistema de estocagem da rede varejista, enquanto que a segunda baseia-se nos dados obtidos com o módulo previsor.

##### **4.5.4.1 Determinação da Atual Política de Reposição de Estoques**

Os dados observados utilizados neste trabalho representam as quantidades vendidas e os níveis de estoque, por local e por produto, no final do dia, conforme apontado na tabela da figura 4.1. Não existe, explicitamente, a informação sobre reposição dos estoques. Com isso, torna-se necessária a criação de um processo automatizado para verificação dos reabastecimentos. Isto pode ser facilmente feito comparando os níveis de estoque em ordem cronológica. Para exemplificar esta

situação, considere a tabela 4.4. Nela tem-se a informação sobre vendas e volumes de estoque. Para fins de simplificação, considere ainda que os dados são relativos a um único produto para apenas um local.

Tabela 4.4 – Avaliação dos dados para verificação de reposição do estoque.

| Data       | Qtd. Estoque | Qtd. Venda |
|------------|--------------|------------|
| 01/02/2010 | 150          | 15         |
| 02/02/2010 | 135          | 12         |
| 03/02/2010 | 123          | 17         |
| 04/02/2010 | 106          | 13         |
| 05/02/2010 | 93           | 18         |
| 06/02/2010 | 75           | 25         |
| 07/02/2010 | 50           | 14         |
| 08/02/2010 | 180          | 13         |

Fonte: Autor

Com a ordenação cronológica, os valores de quantidade em estoque são monotonicamente decrescentes até que uma reposição aconteça. No exemplo dado na tabela 4.4, houve um evento de reposição *er* no dia 08/02/2010. Se ele não ocorresse, a quantidade em estoque no referido dia seria 36. Assim, pode-se concluir que, na ocorrência do aumento da quantidade estocada de um produto, a quantidade repostada pode ser calculada segundo a equação (4.1).

$$\text{Reposição} = NE_t - NE_{t-1} + V_{t-1} \quad , \quad (4.1)$$

onde:

$NE_t$ : nível de estoque no tempo  $t$ , onde houve a reposição;

$NE_{t-1}$ : nível de estoque imediatamente anterior ao tempo  $t$ ;

$V_{t-1}$ : quantidade de unidades vendidas em  $t - 1$ .

No exemplo da tabela 4.4, a quantidade reposta foi de 144 unidades do produto.

Saber como ocorreram as reposições de estoque nos dados observados é de suma importância pois atestará a validade do módulo simulador, provando que ele atende plenamente à sua função e reproduz fielmente o sistema observado. Esta é a primeira estratégia aplicada para geração de solução inicial para o problema.

#### **4.5.4.2 Geração de Políticas de Reposição de Estoque para Demandas Previstas**

A segunda forma de se obter a solução inicial para o problema tratado neste trabalho está focada em encontrar uma solução de reposição utilizando as informações de demanda geradas pelo módulo previsor. A razão de se criar uma forma diferenciada para as demandas previstas parte do princípio de que existe uma diferença entre os dados observados e os previstos. Com a aplicação de metaheurísticas, a tendência é de que, quanto melhor for a solução inicial inserida no método, melhor será o resultado obtido. A solução inicial  $S_0$  obtida pelo método apresentado na seção 4.5.4.1 pode não atender satisfatoriamente às demandas previstas ou ser uma solução muito pobre. Esta poderia ser uma solução inicial de baixa qualidade ou até mesmo não factível.

Para evitar esta situação, foi criado um procedimento de geração de uma nova  $S_0$  para a execução do otimizador com os dados obtidos com o módulo previsor. Tal procedimento apura o total de unidades necessárias para atender a todo o período onde as demandas foram previstas. Cria-se então uma PRE para cada produto em cada loja contendo apenas um evento de reposição no primeiro dia da série temporal de demanda prevista. Este método garante a factibilidade da solução inicial, visto que o estoque iniciará com uma quantidade igual ao total da demanda em todo o período.

#### 4.5.5 Simulador

Visando analisar diferentes realidades para o sistema em estudo, a ferramenta desenvolvida contém um módulo que irá simular o comportamento do sistema observado. Trata-se de um simulador discreto determinístico, uma vez que trabalha com observações discretas do sistema (o total de unidades vendidas e os níveis de estoque são sempre observados no final de cada data, para cada produto em cada loja) e faz uso de previsões de demanda e reposições de estoque pré-determinadas, ao invés de utilizar distribuições de probabilidade para reproduzir o comportamento do sistema.

Com base em uma política de reabastecimento, ou seja, em que dias e com quantas unidades de cada produto as lojas têm seus estoques repostos, além das previsões de demanda, oriundas do módulo previsor, o simulador verificará como o sistema se comporta. A ferramenta pode conduzir simulações para qualquer extensão de tempo, sendo este um dos parâmetros do simulador. Os experimentos realizados no desenvolvimento do trabalho sempre utilizam o período de um ano. Quando o simulador é executado, ele fornece alguns resultados. A relação a seguir apresenta os indicadores de desempenho obtidos ao final da execução da simulação (saídas):

- a) Lucro Bruto, obtido a partir do Lucro Unitário do Cadastro de Produtos e da Quantidade de Unidades Vendidas;
- b) Quantidade de Unidades Vendidas, apurada confrontando as demandas e os níveis de estoque obtidos com a solução de reposição proposta;
- c) Gasto Efetivo de Estocagem, calculado a partir da quantidade de unidades remanescentes em estoque de cada produto, ao final de cada dia;
- d) Estoque Médio, Mínimo e Máximo;

- e) Quantidade de Ocorrências de Rupturas de Estoque, que representa quantas vezes algum produto deixou de ser vendido por falta de unidades em estoque;
- f) Demandas não supridas, representando quantas unidades de cada produto deixaram de ser vendidas por indisponibilidade de estoque;
- g) Percentual de Nível de Serviço, ou seja, qual o percentual do total de demandas previstas foi atendido;
- h) Intervalos de Reposição, representando o número de dias entre intervalos consecutivos e utilizado para possível penalização da FO quando a respectiva restrição for violada.

Para obtenção destes indicadores (exceto o Percentual de Nível de Serviço), deve-se entender que o simulador irá tratar as entidades envolvidas (Data, Local e Produto) como pertencentes a um espaço tridimensional, onde é possível encontrar todos os cruzamentos envolvendo tais entidades. A figura 4.4 exemplifica a forma de obtenção da Quantidade Vendida por Produto e Local ao longo do tempo. Da mesma forma como se enxerga este espaço tridimensional para a quantidade vendida, existirão outros, equivalentes, que tratam das demais saídas, listadas anteriormente.

Dado um Local e um Produto, por exemplo, L7 e P4 (conforme indicado na figura 4.4), e considerando uma variação no eixo do Tempo, todos os valores dos blocos de cruzamento, para esta combinação Local e Produto, são somados. Imaginando que os valores ali contidos representam a Quantidade Vendida, a soma destes valores fornece o total vendido no período entre D1 e D4.

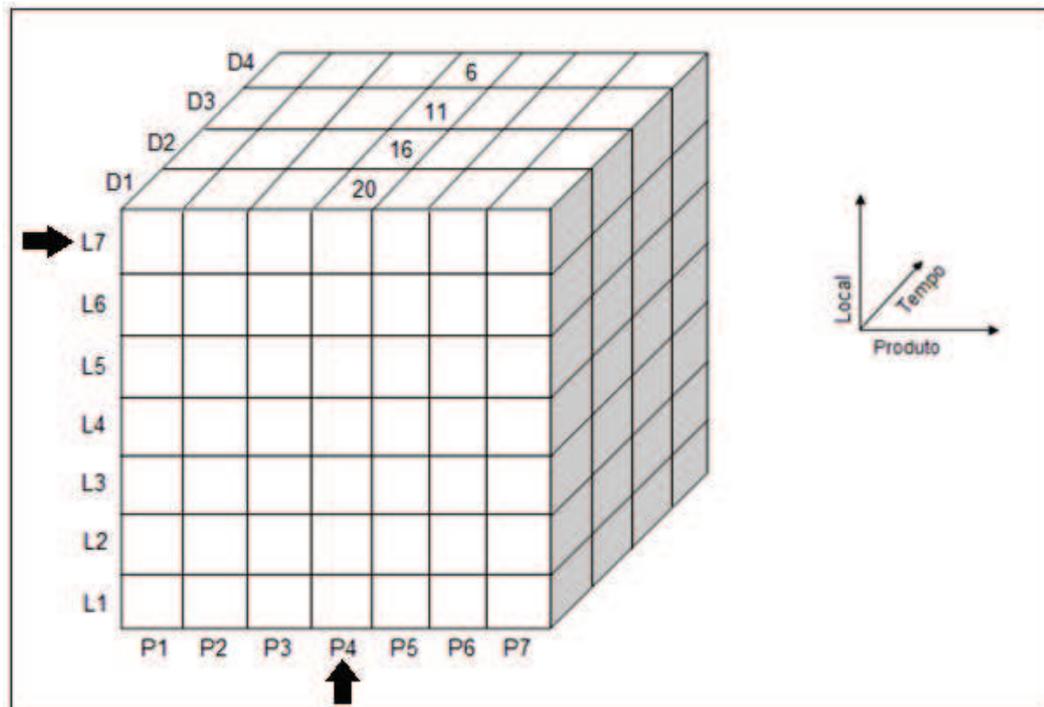


Figura 4.4 – Espaço tridimensional que representa as entidades envolvidas no simulador.  
Fonte: Autor.

Neste exemplo, foram fixados valores para os eixos de Local e Produto e variou-se o eixo Tempo para obtenção do total de unidades vendidas no período. De forma análoga, é possível fixar quaisquer dois eixos e variar um deles, ou fixar um eixo e variar dois deles, possibilitando a obtenção de valores totais diversos, de acordo com a informação que deseja-se obter.

Além da SR e das previsões de demanda, outros parâmetros inseridos no modelo possibilitam que seu comportamento seja modificado. Isto permite a criação de cenários alternativos à realidade em que o sistema opera, possibilitando a quem utiliza a ferramenta investigar possíveis mudanças no sistema real sem ter que efetivamente alterá-lo, trazendo uma série de benefícios ao usuário. A relação completa dos parâmetros do Simulador é apresentada na seção 4.5.5.1.

A figura 4.5 apresenta resumidamente o funcionamento do simulador, com suas entradas e saídas.

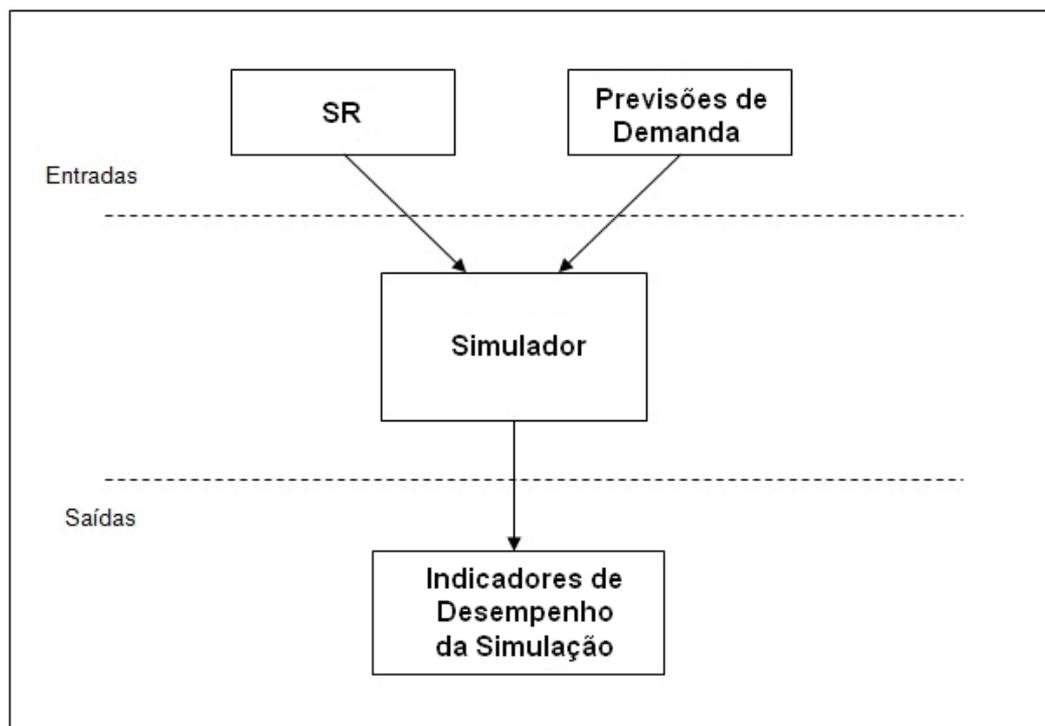


Figura 4.5 – Funcionamento do Simulador.  
Fonte: Autor.

A SR e as previsões de demanda (LEDs da seção 4.5.2) são utilizadas como entradas do Simulador. Com isso, ele irá reproduzir o funcionamento do sistema, avançando o relógio de simulação de um em um dia, agindo sobre os eventos de retirada de itens do estoque com base nas demandas previstas (LEDs) e reposição de produtos no estoque (SR), além de contabilizar os indicadores de desempenho do problema em questão. No final do processo, estes indicadores ficam disponíveis para o módulo Otimizador.

#### 4.5.5.1 Parâmetros do Simulador

Com o intuito de dar mais liberdade ao usuário da ferramenta desenvolvida, o módulo de simulação conta com alguns parâmetros. Eles têm a função de alterar o

comportamento do modelo ou os dados que servem de entrada para o mesmo. Torna-se assim possível conduzir experimentos diversos, criando e simulando situações diferentes do observado no sistema real.

A tabela 4.5 contém a lista de parâmetros do simulador.

Tabela 4.5 – Parâmetros do Simulador.

| <b>Parâmetro</b>      | <b>Objetivo esperado ou Função</b>  |
|-----------------------|---|
| Política de Reposição | Forma de repor os estoques de cada produto em cada loja, ou seja, quando os produtos serão repostos em cada loja e com qual quantidade.                           |
| Previsões de Demanda  | Informações oriundas do módulo Previsor, que indicam a quantidade de produtos necessários para atender às demandas diárias de cada local.                         |
| Período de Simulação  | Indica quanto tempo o sistema será simulado. O valor sugerido para este parâmetro é 12 meses. No entanto o controle de eventos irá ocorrer com frequência diária. |

Fonte: Autor

#### 4.5.6 Processo de Otimização de Níveis de Estoques

O processo de otimização de níveis de estoques buscará, por formas de reposição de estoque, maximizar os resultados da empresa. Isto será feito através do emprego de uma metaheurística. Uma série de aspectos são considerados para avaliar a qualidade das soluções candidatas. Estes indicadores serão detalhados na seção 4.5.6.1, onde é apresentada a Função Objetivo.

O módulo otimizador é responsável por sugerir diferentes políticas de reposição de estoque para os produtos vendidos em cada loja. Busca-se com isso encontrar políticas de reposição melhores que a inicial. Trata-se de um processo iterativo que parte de uma solução inicial  $S_0$  e avança através de pequenas modificações nas soluções encontradas ao longo do processo. Diversas soluções vizinhas são geradas a cada iteração do otimizador. A melhor solução vizinha é

então utilizada como base para geração de vizinhança na próxima iteração. A busca se encerra quando um determinado número de iterações ocorrer. Ainda, o modelo conta com algumas restrições que não podem ser violadas.

A ferramenta desenvolvida aplica a metaheurística *Guided Local Search* para conduzir o processo de otimização de reposição de estoques. Para que isso ocorra, o problema em questão deve ser codificado segundo os conceitos e estruturas utilizadas no GLS. Isso será apresentado na seção 4.5.7.

#### 4.5.6.1 Modelagem Matemática do Problema e Função Objetivo

Para facilitar a compreensão do modelo matemático por parte do leitor, primeiramente serão apresentados cada um dos seus componentes e, em seguida, a modelagem completa do problema com a definição da Função Objetivo e as restrições empregadas.

O primeiro componente do modelo é o Lucro Global sobre Vendas (*LGV*). Ele expressa o lucro total obtido com as vendas de todos os produtos e é calculado a partir da soma das parcelas  $LBV_k$ , que representam o lucro obtido com a venda de cada produto em cada loja, conforme a equação (4.2). Em geral, soluções que possuem valores mais altos para este componente tendem a ser de maior qualidade.

$$LGV = \sum_{k=1}^n LBV_k \quad , \quad (4.2)$$

onde:

$LBV_k$ : Lucro Bruto sobre Vendas do produto  $k$ .

O próximo componente é o Custo Global de Estocagem ( $CGE$ ), dado pela equação (4.3). Ele representa o gasto total com estocagem e reposição dos produtos (excluído o valor da mercadoria). Ele é obtido através da soma das parcelas  $CTE_k$ , que expressam os valores individuais de custo de estocagem. Estas parcelas são calculadas a partir do valor de “Custo Estocagem Dia”, existente no cadastro de produtos, e da quantidade de itens em estoque ao final de cada dia. Soluções com valores menores para este componente, geralmente, tendem a apresentar maior qualidade.

$$CGE = \sum_{k=1}^n CTE_k \quad , \quad (4.3)$$

onde:

$CTE_k$ : Custo Total de Estocagem do produto  $k$  (manutenção de estoque e reposições).

O Resultado Financeiro Global ( $RFG$ ), dado pela equação (4.4), é o terceiro componente da FO e representa a diferença entre o lucro global obtido ( $LGV$ ) e o total gasto com estocagem ( $CGE$ ), ou seja, representa uma medida do lucro líquido obtido. Geralmente, soluções com valores mais altos para este componente tendem a apresentar maior qualidade.

$$RFG = LGV - CGE \quad , \quad (4.4)$$

onde:

$LGV$ : Lucro Global sobre Vendas;

$CGE$ : Custo Global de Estocagem.

O quarto componente é o Percentual de Nível de Serviço Apurado de um produto  $k$  ( $PNSA_k$ ) que representa, em termos percentuais, quanto da demanda prevista para o produto  $k$  foi atendida. Ele é calculado com base na equação (4.5). Em geral, quanto mais próximo de 1 for o valor deste componente, maior será a qualidade da solução.

$$PNSA_k = \frac{DA_k}{DP_k} , \quad (4.5)$$

onde:

$DA_k$ : Demanda Atendida do produto  $k$ ;

$DP_k$ : Demanda Prevista do produto  $k$ .

O componente Percentual de Nível de Serviço Global Apurado ( $PNSGA$ ), dado pela equação (4.6), expressa, em termos percentuais, quanto da demanda prevista foi atendida. Ele funciona de forma análoga ao cálculo do  $PNSA_k$ , porém sua utilização é para avaliar a rede varejista como um todo, não apenas um produto. Soluções com valores próximos a 1 para este componente tendem a apresentar maior qualidade.

$$PNSGA = \frac{\sum_{k=1}^n DA_k}{\sum_{k=1}^n DP_k} , \quad (4.6)$$

onde:

$DA_k$ : Demanda Atendida do produto  $k$ ;

$DP_k$ : Demanda Prevista do produto  $k$ .

O componente Margem sobre Montante Financeiro Investido ( $MMFI$ ) é uma razão entre o lucro e os custos envolvidos no problema. Ele mede quanto retorno está sendo obtido para cada unidade monetária aplicada em manutenção de

estoques e é dado pela equação (4.7). Quanto maior for o  $MMFI$ , mais eficiente é a solução em termos de retorno sobre investimento.

$$MMFI = \frac{LGV}{CGE} , \quad (4.7)$$

onde:

$LGV$ : Lucro Global sobre Vendas;  
 $CGE$ : Custo Global de Estocagem.

O componente Ruptura Individual ( $RI_k$ ), leva em conta o atendimento às demandas previstas para cada produto  $k$  e serve como um termo de penalização. Ele é obtido com base na razão entre a Quantidade de Ocorrências de Ruptura do produto  $k$  ( $QOR_k$ ) e o Percentual de Nível de Serviço do mesmo produto ( $PNSA_k$ ). O  $QOR_k$  indica quantas vezes o produto deixou de ser vendido por falta de estoque. Assim quando seu  $QOR_k$  de um produto for zero, o  $PNSA_k$  respectivo será 1 (100%) e não haverá penalização. A partir do momento que o índice  $QOR_k$  de um produto passar a ter valores maiores que zero, seu  $PNSA_k$  começará a diminuir, uma vez que a totalidade da demanda não foi atingida. A função indicadora  $I(k)$  retornará 1 quando o  $PNSA_k$  ficar abaixo do Percentual de Nível de Serviço Exigido para o produto  $k$  ( $PNSE_k$ ). Assim, enquanto a demanda atendida ficar acima de um dado nível, não haverá penalização. Quando a demanda atendida for inferior à mínima exigida, ocorrerá uma penalização calculada em função de  $QOR_k$  e  $PNSA_k$ . Desta forma, para situações em que  $PNSA_k$  for inferior a  $PNSE_k$ , quanto mais ocorrências de ruptura ( $QOR_k$ ) acontecerem, maior será a penalização. De outra forma, quanto menor for a demanda atendida ( $PNSA_k$ ), maior será a penalização. Ainda, podem ser aplicados pesos diferentes para cada produto ( $w_k$ ), dependendo das exigências de atendimento de demanda. As equações (4.8) e (4.9) definem o componente  $RI$ .

$$RI_k = w_k \cdot \frac{QOR_k}{PNSA_k} \cdot I(k) \quad , \quad (4.8)$$

$$I(k) = \begin{cases} 1, & \text{se } PNSA_k < PNSE_k \\ 0, & \text{caso contrário} \end{cases} \quad , \quad (4.9)$$

onde:

$w_k$ : Peso para penalização de políticas de reposição que violem o atendimento mínimo do total de unidades demandadas do produto  $k$ ;

$QOR_k$ : Quantidade de Ocorrências de Ruptura do produto  $k$ ;

$I(k)$ : Função indicadora da violação da restrição de atendimento mínimo da demanda do produto  $k$ ;

$PNSA_k$ : Percentual de Nível de Serviço Mínimo Apurado do produto  $k$ ;

$PNSE_k$ : Percentual de Nível de Serviço Mínimo Exigido do produto  $k$ , ou seja, o percentual mínimo da demanda que deve ser atendida.

O próximo componente, Ruptura Global ( $RG$ ), é definido a partir da soma das parcelas de penalização individual  $RI_k$ , dada pela equação (4.10). Este componente também funciona como um elemento penalizador.

$$RG = \sum_{k=1}^n RI_k \quad , \quad (4.10)$$

onde:

$RI_k$ : Penalização por Ruptura Individual do produto  $k$ .

O componente a seguir também é utilizado para aplicar penalizações à FO. O Intervalo de Reposição Total ( $IRT$ ), dado pela equação (4.12), considera outra restrição do problema, os Intervalos de Reposição. Este componente é definido como a soma das parcelas  $PIR_k$  que representam a penalização individual pela violação da restrição e são calculadas com base na equação (4.11). Na seção 4.5.3 foi visto que uma PRE é um conjunto de eventos de reposição de estoque. Para cada produto  $k$ , existe uma PRE. Quando um Intervalo entre Eventos de Reposição ( $IR$ ) da PRE for maior que o intervalo mínimo ( $LT$ ) para o produto  $k$ , não haverá violação da restrição e o resultado da expressão  $LT_k - IR_{ik}$ , da equação (4.11), será negativo. Se a situação se inverter, ou seja, o  $IR$  for inferior ao  $LT$ , o valor da mesma expressão será positivo. É importante aqui destacar o uso da função max. Quando não houver violação da restrição, a função retornará zero, visto que o resultado de  $LT_k - IR_{ik}$  será negativo. Quando houver violação, o resultado da expressão será positivo, logo, maior que zero, sendo este o valor retornado pela função. A penalização será maior para violações mais graves, ou seja, quando mais distante  $IR_{ik}$  estiver de  $LT_k$ , maior será a penalização. Através do uso do ponderador  $z_k$  é possível dar maior ou menor importância a determinados produtos.

$$PIR_k = \sum_{i=1}^{m_k} z_k \cdot \max \{0, LT_k - IR_{ik}\} , \quad (4.11)$$

$$IRT = \sum_{k=1}^n PIR_k , \quad (4.12)$$

onde:

- $z_k$ : Peso para penalização de políticas de reposição que violem o intervalo mínimo de reposição do produto  $k$ ;
- $LT_k$ : Intervalo mínimo de dias entre duas reposições consecutivas do produto  $k$ ;

- $IR_{ik}$ : Quantidade de dias decorridos entre o  $i$ -ésimo evento de reposição do produto  $k$  em relação ao anterior;
- $n$ : Total de produtos;
- $m_k$ : Total de eventos de reposição do produto  $k$ .

Definidos os componentes de penalização, pode-se apresentar a FO do modelo otimizador. Ela é dada pela equação (4.13).

$$\max IES = a. \beta. RFG - b. \alpha. RG - c. \gamma. IRT + d. \omega. MMFI + e. \varphi. (PNSGA - PMSGME) \quad , \quad (4.13)$$

sujeito a:

$$PNSA_k \geq PNSE_k, \quad (4.1)$$

$$IR_{ik} \geq LT_k, \quad (4.2)$$

$$PNSGA \geq PMSGME, \quad (4.3)$$

onde:

- $RFG$ : resultado financeiro global;
- $MMFI$ : margem sobre montante financeiro investido;
- $PNSGA$ : percentual de nível de serviço global apurado;
- $PMSGME$ : percentual de nível de serviço global mínimo exigido;
- $PNSA_k$ : percentual de nível de serviço apurado do produto  $k$ ;
- $PNSE_k$ : percentual de nível de serviço mínimo exigido do produto  $k$ , ou seja, o percentual mínimo da demanda que deve ser atendido;
- $IR_{ik}$ : quantidade de dias decorridos entre a  $i$ -ésima reposição

|             |  |
|-------------|--|
|             | do produto $k$ em relação à reposição anterior;                              |
| $LT_k$ :    | intervalo mínimo de dias entre duas reposições consecutivas do produto $k$ ; |
| $RG$ :      | total de ocorrências de ruptura;   |
| $IRT$ :     | intervalo de reposição total;  |
| $a$ :       | peso atribuído ao $RFG$ ;  |
| $\beta$ :   | fator equalizador do $RFG$ ;   |
| $b$ :       | peso atribuído ao $RG$ ;   |
| $\alpha$ :  | fator equalizador do $RG$ ;  |
| $c$ :       | peso atribuído ao $IRT$ ;  |
| $\gamma$ :  | fator equalizador do $IRT$ .   |
| $d$ :       | peso atribuído ao $MMFI$ ;   |
| $\omega$ :  | fator equalizador do $MMFI$ .  |
| $e$ :       | peso atribuído ao fator contribuidor/penalizador $PNSGA - PNSGME$ ;          |
| $\varphi$ : | fator equalizador da diferença entre $PNSGA$ e $PNSGME$ .                    |

As restrições do problema visam garantir:

- que cada produto tenha, individualmente, um mínimo de demanda atendida, restrição (4.1);
- que os intervalos entre reposições não sejam inferiores ao intervalo mínimo entre reposições, exigido para cada produto, restrição (4.2) e;
- um mínimo da demanda total seja atendida, considerando todos os produtos e lojas, restrição (4.3).

O objetivo de inserir termos de penalização na FO é a de que se possa medir, em termos numéricos, que determinadas soluções, apesar de apresentarem bons resultados no que tange ao resultado financeiro ( $RFG$ ) e ao retorno sobre

investimento (MMFI), possam violar algumas restrições do problema. A violação das restrições irá penalizar, reduzir o valor da FO, tornando-as de menor qualidade.

Os termos  $\alpha$ ,  $\beta$  e  $\gamma$ ,  $\omega$  e  $\varphi$  são fatores equalizadores. O objetivo deles é ajustar a magnitude das grandezas envolvidas. Por exemplo, o componente RFG tem ordem de grandeza superior aos demais componentes. A idéia é reduzir, ou até mesmo anular, esta diferença de magnitude, uma vez que, se ela existir e for grande, a FO pode, conseqüentemente, privilegiar termos de magnitude maior, tornando aqueles de menor magnitude menos significativos. Os pesos e fatores equalizadores foram inseridos distintamente para facilitar a simulação de diferentes cenários pois, uma vez ajustados, tem-se a equiparação de magnitude dos componentes, possibilitando a condução de experimentos relativos aos pesos dos componentes da FO.

A FO foi construída de forma a considerar os diversos aspectos presentes no problema e possibilitar a análise de cenários variados. Ela permite ainda que o usuário da ferramenta escolha quais aspectos deseja considerar ou dar maior ou menor importância a qualquer um deles.

#### **4.5.6.2 Parâmetros do Otimizador**

Além do parâmetro  $\lambda$  do GLS e dos parâmetros da FO, o módulo otimizador também conta com uma série de parâmetros que podem ser ajustados de acordo com o objetivo de análise e do cenário de demanda e reposição sendo avaliado. A tabela 4.6 traz a relação completa destes parâmetros. Alguns parâmetros tratam de probabilidades de uso de diferentes estratégias de geração de vizinhança, estratégias estas que serão apresentadas oportunamente. A escolha do valor atribuído a cada um dos parâmetros pode ser feita através de experimentação. Partindo-se de valores iniciais, é possível variar os valores dos parâmetros e então

executar a ferramenta. A avaliação dos resultados obtidos a cada variação dos parâmetros indicará quais são os valores mais apropriados a serem utilizados. Sugere-se que os parâmetros sejam variados um a um, permitindo assim verificar a influência de cada um deles nos resultados.

Tabela 4.6 – Parâmetros do Otimizador.

| <b>Parâmetro</b>                                      | <b>Objetivo esperado ou Função</b>  |
|---|---|
| Número de Iterações                                   | Quantidade de iterações (ciclos) que o otimizador deve executar.  |
| Tamanho da Vizinhança                                 | Quantidade de soluções vizinhas geradas em cada iteração.   |
| Taxa de crescimento do <i>pool</i> de atributos (PA)  | Quantidade de PREs alternativas inseridas no PA a cada iteração, quando este não estiver cheio.             |
| Tamanho do <i>pool</i> de atributos (PA)              | Quantidade de PREs alternativas que cada produto e local terá no PA.  |
| Quantidade de atributos alterados em uma nova solução | Número de atributos ou PREs que serão alteradas na solução para a geração de uma solução vizinha.           |
| Probabilidade de geração de vizinhança pelo método A  | Probabilidade de geração de PRE alternativa pela estratégia da divisão da maior reposição.                  |
| Probabilidade de geração de vizinhança pelo método B  | Probabilidade de geração de PRE alternativa pela estratégia de remoção aleatória de evento de reposição.    |
| Probabilidade de geração de vizinhança pelo método C  | Probabilidade de geração de PRE alternativa pela estratégia de variação uniforme na quantidade reposta.     |
| Probabilidade de geração de vizinhança pelo método D  | Probabilidade de geração de PRE alternativa pela estratégia de variação singular na quantidade reposta.     |
| Probabilidade de geração de vizinhança pelo método E  | Probabilidade de geração de PRE alternativa pela estratégia de inserção aleatória de evento de reposição.   |
| Probabilidade de geração de vizinhança pelo método F  | Probabilidade de geração de PRE alternativa pela estratégia de distribuição uniforme da quantidade reposta. |
| Probabilidade de geração de vizinhança pelo método G  | Probabilidade de geração de PRE alternativa pela estratégia de distribuição local da quantidade reposta.    |

Fonte: Autor

Tabela 4.6 – Parâmetros do Otimizador (continuação).

| <b>Parâmetro</b>  | <b>Objetivo esperado ou Função</b>  |
|---|---|
| Variação Percentual para variação de quantidade repostas                    | Parâmetro utilizado nas estratégias de geração de vizinhança quando há necessidade de aumentar ou diminuir as quantidades repostas. |
| Quantidade de Iterações sem Melhora na FO para alteração do modo de atuação | Quantas iterações sem melhora devem ocorrer para que o algoritmo altere o modo de atuação.  |
| Quantidade de Iterações para Unificação de Soluções                         | Número de iterações para que ocorra a unificação entre a solução relaxada e a solução factível.                                     |
| Percentual de Nível de Serviço Mínimo Exigido (PNSGME)                      | Percentual mínimo do total da demanda prevista que deve ser atingido. Valores válidos são de 1% a 100%. O valor padrão é 90%        |

Fonte: Autor

Se o otimizador permanecer por um número de iterações equivalente ao parâmetro “Quantidade de Iterações sem Melhora na FO para alteração do modo de atuação” sem obter qualquer melhora nos resultados obtidos com a FO, algumas ações são tomadas na tentativa de modificar esta situação, são elas:

- a) remoção de metade dos atributos do *pool*, com base na quantidade de avaliações pela FO, ou seja, remover os que mais vezes foram avaliados;
- b) alteração do parâmetro de variação percentual da quantidade repostas, utilizado nas estratégias C e D, passando de 10% para 25%;
- c) aumento na taxa de crescimento do PA;
- d) aumento no tamanho da vizinhança, passando para 3 vezes o valor padrão;
- e) alteração dos valores das probabilidades de geração de vizinhança, fazendo com que as estratégias C, D e G ocorram mais frequentemente. A tabela 4.7 traz as probabilidades de escolha de cada uma das estratégias de geração de vizinhança, tanto para o modo regular de atuação quanto para o alternativo.

Tabela 4.7 – Probabilidades de escolha das estratégias de geração de vizinhança.

| <b>Estratégia</b> | <b>Probabilidade Modo Regular</b> | <b>Probabilidade Modo Alternativo</b> |
|-------------------|-----------------------------------|---------------------------------------|
| A                 | 15%                               | 10%                                   |
| B                 | 18%                               | 15%                                   |
| C                 | 18%                               | 25%                                   |
| D                 | 11%                               | 15%                                   |
| E                 | 18%                               | 10%                                   |
| F                 | 5%                                | 5%                                    |
| G                 | 15%                               | 20%                                   |

Fonte: Autor

A escolha dos percentuais da tabela 4.7 ocorreu por experimentação, ou seja, foram executados testes variando os valores do modo regular. A cada variação, a ferramenta era executada para obtenção de resultados. Os resultados obtidos a cada variação dos parâmetros foram comparados entre si, com o objetivo de encontrar uma linha base para a execução da ferramenta. Uma vez fixados os valores percentuais para o modo regular, estes foram variados para fixar os valores do modo alternativo.

Esta mudança no modo de atuação do algoritmo tem como objetivo possibilitar a fuga de um ótimo local, forçando uma renovação do *pool* de atributos, ou seja, atuando na diversificação da busca, criando várias novas PREs de uma forma diferente da que até então estava sendo feita. A criação de novas PREs descartará atributos pouco promissores e permitirá que outros, possivelmente promissores, ou que levem a outras porções do espaço de soluções, sejam utilizados. O algoritmo permanecerá por uma iteração no modo de atuação alternativo, voltando para o modo regular em seguida.

Durante a execução do algoritmo, a cada iteração, são controlados dois tipos de solução, uma factível e uma relaxada. A solução factível diz respeito à melhor solução encontrada durante a execução que respeita todas as restrições do problema. A solução relaxada é aquela que possui o melhor valor segundo a FO, mesmo que não respeite todas as restrições. Procura-se com isso fazer uma busca eficiente no espaço de soluções, considerando a passagem por soluções infactíveis que podem levar a soluções ótimas. Através do controle da melhor solução factível o algoritmo pode, a qualquer momento, fazer a união destas duas soluções, alterando

os atributos da solução relaxada que não respeitem as restrições por atributos equivalentes da solução factível, criando, possivelmente, uma nova solução factível melhor do que aquela até então obtida. A unificação ocorrerá sempre que o algoritmo executar uma quantidade de iterações equivalente ao parâmetro “Quantidade de Iterações para Unificação de Soluções”. Isso ocorre também quando o número máximo de iterações for alcançado, trazendo, possivelmente, uma melhora no final da execução.

#### **4.5.7 Codificação do Problema no Modelo da Metaheurística *Guided Local Search***

Para tratar o problema de otimização de níveis de estoque, foi necessário empregar algumas estruturas definidas segundo alguns conceitos, bem como alguns procedimentos específicos do GLS. Estas questões serão apresentadas nesta seção.

A metaheurística GLS utiliza como estratégia para fuga de ótimos locais o emprego de penalização para atributos que já tenham sido utilizados. Quanto mais um atributo for usado, mais penalizações ele sofrerá. Atributos penalizados irão gradativamente piorar a solução quando avaliados através da FOA, segundo a equação (2.14). Quanto mais um atributo  $i$  for utilizado, pior será o resultado da FOA quando avaliar uma solução que o empregue. Isso permite que atributos pouco penalizados e, conseqüentemente, pouco utilizados, sejam usados na geração de novas soluções.

Partindo-se de uma solução inicial  $S_0$ , as metaheurísticas geram soluções vizinhas através de pequenas modificações em  $S_0$ . Dentro do contexto deste trabalho, com base em um conjunto de PREs, componentes da SR, novas PREs serão criadas através da introdução de pequenas modificações nas PREs de  $S_0$ . O objetivo disto é verificar novas possíveis formas de reposição de estoque para cada

produto, em cada loja. Essa é uma tarefa simples, basta aplicar uma das estratégias de geração de vizinhança para cada uma das PREs. Após isso, o simulador reproduzirá o comportamento do sistema com as novas PREs, será verificado o resultado através da FO e alguns procedimentos relativos ao GLS serão executados. Este ciclo pode ser repetido diversas vezes em busca de soluções alternativas.

Ocorre que o GLS necessita utilizar atributos diversos por repetidas vezes, ou seja, uma vez que PREs sejam criadas pelas estratégias de geração de vizinhança, elas precisam ser mantidas, de alguma forma, para que possam ser utilizadas novamente no futuro. Para exemplificar, considere que a rede varejista contém apenas um produto e uma loja. A solução do problema será composta por somente uma PRE. Através das estratégias de geração de vizinhança é possível criar PREs alternativas, sendo cada uma delas um atributo do problema, porém apenas um destes atributos pode ser utilizado por vez (não há razão para utilizar duas PREs para um mesmo produto em um mesmo local na mesma solução). Esta situação é ilustrada na figura 4.6.

**Loja A**

**Produto 1**

**A**

| Data       | Qtd. Unidades Repostas | Intervalo Reposição Anterior |
|------------|------------------------|------------------------------|
| 01/02/2010 | 150                    | 0                            |
| 27/02/2010 | 168                    | 26                           |
| ...        | ...                    | ...                          |
| 02/01/2011 | 133                    | 6                            |

---

**B**

| Data       | Qtd. Unidades Repostas | Intervalo Reposição Anterior |
|------------|------------------------|------------------------------|
| 05/02/2010 | 330                    | 0                            |
| 25/02/2010 | 360                    | 20                           |
| ...        | ...                    | ...                          |
| 22/12/2010 | 300                    | 10                           |

---

**C**

| Data       | Qtd. Unidades Repostas | Intervalo Reposição Anterior |
|------------|------------------------|------------------------------|
| 01/03/2010 | 80                     | 0                            |
| 20/03/2010 | 70                     | 19                           |
| ...        | ...                    | ...                          |
| 31/12/2010 | 110                    | 15                           |

---

**D**

| Data       | Qtd. Unidades Repostas | Intervalo Reposição Anterior |
|------------|------------------------|------------------------------|
| 10/02/2010 | 850                    | 0                            |
| 26/02/2010 | 1.200                  | 16                           |
| ...        | ...                    | ...                          |
| 02/01/2011 | 750                    | 8                            |

Figura 4.6 – Atributos ou PREs alternativas para o problema com um produto e uma loja.  
Fonte: Autor.

De acordo com a figura 4.6, o otimizador tem quatro alternativas para resolver o problema da rede varejista de um único produto e uma única loja. Existem quatro PREs alternativas, chamadas de A, B, C e D. Neste contexto, a quantidade total de possíveis soluções para o problema é quatro, entretanto apenas uma PRE pode ser utilizada em uma solução. Agora, assumo que a rede continua com uma única loja mas passe a vender dois produtos. A figura 4.7 ilustra esta situação.

| <b>Loja A</b>    |             |                               |                                     |
|------------------|-------------|-------------------------------|-------------------------------------|
| <u>Produto 1</u> |             |                               |                                     |
| <b>A</b>         | <b>Data</b> | <b>Qtd. Unidades Repostas</b> | <b>Intervalo Reposição Anterior</b> |
|                  | 01/02/2010  | 150                           | 0                                   |
|                  | 27/02/2010  | 168                           | 26                                  |
|                  | ...         | ...                           | ...                                 |
|                  | 02/01/2011  | 133                           | 6                                   |
| <hr/>            |             |                               |                                     |
| <b>B</b>         | <b>Data</b> | <b>Qtd. Unidades Repostas</b> | <b>Intervalo Reposição Anterior</b> |
|                  | 05/02/2010  | 330                           | 0                                   |
|                  | 25/02/2010  | 360                           | 20                                  |
|                  | ...         | ...                           | ...                                 |
|                  | 22/12/2010  | 300                           | 10                                  |
| <hr/>            |             |                               |                                     |
| <b>C</b>         | <b>Data</b> | <b>Qtd. Unidades Repostas</b> | <b>Intervalo Reposição Anterior</b> |
|                  | 01/03/2010  | 80                            | 0                                   |
|                  | 20/03/2010  | 70                            | 19                                  |
|                  | ...         | ...                           | ...                                 |
|                  | 31/12/2010  | 110                           | 15                                  |
| <hr/>            |             |                               |                                     |
| <b>D</b>         | <b>Data</b> | <b>Qtd. Unidades Repostas</b> | <b>Intervalo Reposição Anterior</b> |
|                  | 10/02/2010  | 850                           | 0                                   |
|                  | 26/02/2010  | 1.200                         | 16                                  |
|                  | ...         | ...                           | ...                                 |
|                  | 02/01/2011  | 750                           | 8                                   |
| <hr/>            |             |                               |                                     |
| <u>Produto 2</u> |             |                               |                                     |
| <b>E</b>         | <b>Data</b> | <b>Qtd. Unidades Repostas</b> | <b>Intervalo Reposição Anterior</b> |
|                  | 01/02/2010  | 150                           | 0                                   |
|                  | 27/02/2010  | 168                           | 26                                  |
|                  | ...         | ...                           | ...                                 |
|                  | 02/01/2011  | 133                           | 6                                   |
| <hr/>            |             |                               |                                     |
| <b>F</b>         | <b>Data</b> | <b>Qtd. Unidades Repostas</b> | <b>Intervalo Reposição Anterior</b> |
|                  | 05/02/2010  | 330                           | 0                                   |
|                  | 25/02/2010  | 360                           | 20                                  |
|                  | ...         | ...                           | ...                                 |
|                  | 22/12/2010  | 300                           | 10                                  |
| <hr/>            |             |                               |                                     |
| <b>G</b>         | <b>Data</b> | <b>Qtd. Unidades Repostas</b> | <b>Intervalo Reposição Anterior</b> |
|                  | 01/03/2010  | 80                            | 0                                   |
|                  | 20/03/2010  | 70                            | 19                                  |
|                  | ...         | ...                           | ...                                 |
|                  | 31/12/2010  | 110                           | 15                                  |
| <hr/>            |             |                               |                                     |
| <b>H</b>         | <b>Data</b> | <b>Qtd. Unidades Repostas</b> | <b>Intervalo Reposição Anterior</b> |
|                  | 10/02/2010  | 850                           | 0                                   |
|                  | 26/02/2010  | 1.200                         | 16                                  |
|                  | ...         | ...                           | ...                                 |
|                  | 02/01/2011  | 750                           | 8                                   |

Figura 4.7 – Atributos ou PREs alternativas para o problema com dois produtos e uma loja.  
Fonte: Autor.

Neste segundo exemplo, contido na figura 4.7, já se pode verificar que a solução conterá duas PREs. Existem oito atributos no total, quatro para o produto 1 e outros quatro para o produto 2, porém, apenas um atributo pode ser utilizado para cada produto de cada vez, formando uma solução. Vale lembrar que os quatro atributos do produto 1 não são os mesmos do produto 2 e vice-versa, tampouco são intercambiáveis, ou seja, para o produto 1, apenas as PREs A, B, C e D são aplicáveis. O mesmo vale para o produto 2, apenas as PREs E, F, G e H são aplicáveis. O total de possíveis soluções para este cenário é 16, visto que podem ser quatro valores ou possibilidades, tomadas duas a duas, cada uma representando uma Solução de Reposição (SR).

Este problema pode ser aumentado ainda mais. Imagine que a rede cresceu, agora são duas lojas que vendem dois produtos. A figura 4.7 pode ser duplicada, criando a situação onde exista mais uma loja, com dois produtos e quatro possíveis atributos (ou PREs) para cada um delas. São 256 possíveis soluções (SR) provenientes da combinação das PREs para este cenário, visto que são quatro valores ou possibilidades, tomadas quatro a quatro.

A busca por cenários alternativos de reposição passa pela geração de novas PREs, utilizando as estratégias de geração de vizinhança, e o GLS, por sua vez, necessita manter um histórico de utilização destas PREs (atributos), que são os componentes de uma solução. Não manter este histórico tornaria o algoritmo próximo a uma busca aleatória, já que dificilmente os atributos já avaliados seriam reutilizados, não sendo possível contabilizar os custos e penalidades aplicados.

Uma estrutura que ilustra bem a solução do problema pode ser vista na tabela 4.8. Nas linhas estão os produtos e nas colunas os locais. O conteúdo de cada célula determina a PRE utilizada. Esta tabela também pode ser vista como uma matriz Produto X Loja.

Tabela 4.8 – Representação da Solução do Problema para uma loja e dois produtos.

|           |           |
|-----------|-----------|
|           | <b>L1</b> |
| <b>P1</b> | B         |
| <b>P2</b> | G         |

Fonte: Autor

No caso da tabela 4.8, a solução é composta dos atributos B e G, para os produtos P1 e P2, respectivamente. Esta é uma possível solução para a rede varejista de uma única loja e dois produtos. No caso de duas lojas e dois produtos, a representação da solução é ilustrada na tabela 4.9. A solução para o problema será a utilização do atributo B para o produto 1 na loja 1, atributo G para o produto 2 na loja 1, atributo I para o produto 1 na loja 2 e atributo O para o produto 2 na loja 2.

Tabela 4.9 – Representação da Solução do Problema para duas lojas e dois produtos.

|           | <b>L1</b> | <b>L2</b> |
|-----------|-----------|-----------|
| <b>P1</b> | B         | I         |
| <b>P2</b> | G         | O         |

Fonte: Autor

A esta forma de manter a memória de penalizações dos atributos foi dado o nome de *Pool de Atributos (PA)*. Ela funciona como um repositório de PREs alternativas. Quando é necessário testar uma nova solução para a reposição da rede, algumas PREs, de alguns produtos em algumas lojas, são alteradas. Isto faz com que a modificação na solução ocorra. Com isso, também é possível aplicar penalidades aos atributos e manter seu histórico de utilização, quesito necessário para a aplicação da metaheurística GLS. No exemplo dado na tabela 4.9, uma solução alternativa poderia ser a alteração da política do produto 1 da loja 1 para a PRE A, ficando a solução alternativa da forma exposta na tabela 4.10. A alteração foi sinalizada com “\*”.

Tabela 4.10 – Solução Alternativa do Problema para duas lojas e dois produtos.

|           | <b>L1</b> | <b>L2</b> |
|-----------|-----------|-----------|
| <b>P1</b> | *A        | I         |
| <b>P2</b> | G         | O         |

Fonte: Autor

As PREs iniciais, assim como as alternativas, geradas ao longo do processo de otimização, são inseridas no *pool* de atributos. Quando uma nova solução é requisitada, o otimizador altera alguns atributos da solução, buscando atributos (PREs) alternativos no *pool* de atributos. No exemplo da tabela 4.10, apenas um atributo foi trocado. Na prática, a quantidade de atributos que serão trocados depende do tamanho do problema. Entende-se por tamanho do problema a quantidade de demandas, ou seja, a quantidade de combinações Produto X Local sendo tratados. Por exemplo, um problema de tamanho 500 pode ser entendido como uma rede varejista de 1 loja com 500 produtos, 500 lojas com um produto, 250 lojas com 2 produtos, 20 lojas com 25 produtos ou qualquer outra combinação numérica que produza este resultado, uma vez que, do ponto de vista da otimização, o mais importante é a quantidade de combinações e não o número de produtos ou locais que estão sendo avaliados. No capítulo 5, para cada experimento realizado, será especificada a quantidade de atributos alterados na geração de soluções vizinhas bem como o tamanho do problema.

O PA conterá uma lista de tamanho limitado para cada produto em cada local, sendo este tamanho um parâmetro do otimizador. No início da execução do otimizador o PA contém apenas uma PRE para cada produto em cada local. Com a evolução de sua execução, o PA é alimentado a uma taxa específica (sendo este um parâmetro do otimizador), inserindo novas PREs nele, até que a lista fique completamente preenchida.

Existem ocasiões onde o PA é parcialmente renovado. Por exemplo, se o otimizador permanecer por um determinado número de iterações sem alcançar resultados melhores (mais um parâmetro do otimizador). Isto acontece quando as PREs no *pool* não estão conseguindo gerar resultados melhores. Neste momento, um determinado número de PREs (outro parâmetro do otimizador) é removido do PA. A escolha é feita com base no número de vezes que cada atributo já foi avaliado pela FOA, sendo removidos aqueles que mais vezes foram avaliados. A partir desta modificação, o PA passa novamente a ser alimentado com novas PREs, visto que neste momento ele não está mais cheio. Esta renovação do PA também garante que a busca por soluções não fique restrita a determinada parte do espaço de soluções. Sempre que houver espaço vago no PA, ele será alimentado a uma determinada

taxa (atributos por iteração). Quando o *pool* estiver cheio novamente, não serão mais criadas PREs até que algum espaço seja liberado.

Outro mecanismo utilizado no GLS é o critério de penalização seletiva. Ele faz uso de um custo associado a cada um dos atributos para verificar quais devem ser penalizados. Este custo será calculado com base nos elementos da FO que aplicam penalizações para cada um dos produtos, ou seja,  $CTE_k$ ,  $RI_k$  e  $PIR_k$ . A equação (4.14) apresenta a forma de cálculo do custo de cada atributo.

$$c_l = a. \beta. CTE_l + b. \alpha. RI_l + c. \gamma. PIR_l \quad , \quad (4.14)$$

onde

|            |  |
|------------|--|
| $CTE_l$ :  | custo total de estocagem do atributo $l$ ;   |
| $RI_l$ :   | penalização por ruptura individual do atributo $l$ ;                                     |
| $PIR_l$ :  | penalização por violação da restrição de intervalo mínimo de reposição do atributo $l$ ; |
| $a$ :      | peso atribuído ao $CTE_l$ ;  |
| $\beta$ :  | fator equalizador do $CTE_l$ ;   |
| $b$ :      | peso atribuído ao $RI_l$ ;   |
| $\alpha$ : | fator equalizador do $RI_l$ ;  |
| $c$ :      | peso atribuído ao $PIR_l$ ;  |
| $\gamma$ : | fator equalizador do $PIR_l$ .   |

Vale lembrar que  $c_l$  é um custo associado ao atributo  $l$ . Cada atributo está diretamente ligado a uma PRE, logo, possui os componentes  $CTE$ ,  $RI$  e  $PIR$ .

Esta forma de cálculo do custo dos atributos permite avaliar, quantitativamente, a influência negativa de cada um deles na solução completa. Atributos de alto custo são indesejados.

O valor da Utilidade Máxima, empregado na penalidade seletiva, será a metade do menor custo dos atributos utilizados na  $S_0$ . A motivação para esta escolha é a de que deve ser escolhido um valor baixo o suficiente para permitir que todos os atributos sejam penalizados e permaneçam recebendo penalizações por algumas iterações, até que o critério de penalização seletiva comece a não ter mais efeito.

A Função Objetivo Aumentada (FOA), utilizada para alterar o comportamento da FO original do problema, será modelada como uma redução em relação à FO original, dentro do contexto deste trabalho, já que se trata de um problema de maximização. Esta redução é obtida através da aplicação de um valor negativo para o parâmetro  $\lambda$ . O valor de  $\lambda$  será definido no capítulo 5, que trata dos experimentos conduzidos.

#### **4.5.8 Estratégias de Geração de Vizinhança**

Em um problema de otimização, busca-se por cenários ou soluções alternativas que apresentem, possivelmente, um melhor resultado segundo um critério de avaliação. Partindo de uma solução inicial, pequenas modificações são efetuadas nela, com o objetivo de obter novas soluções. As novas soluções, modificadas, são chamadas de soluções vizinhas. Para gerar soluções vizinhas é necessário desenvolver uma estratégia de geração de vizinhanças. A determinação dos eventos de reposição através do uso das PREs é a forma de gerar novas políticas para cada produto e, conseqüentemente, novas soluções dentro do problema abordado neste trabalho.

A geração de soluções vizinhas compreende duas etapas:

- a) geração de PREs ou atributos alternativos, utilizando as estratégias descritas nas seções 4.5.8.1 a 4.5.8.7;
- b) alteração de atributos da solução SR, gerando uma nova solução, segundo descrito nas seções 4.5.3 e 4.5.7;

A seguir serão apresentadas as sete diferentes estratégias de geração de PREs utilizadas neste trabalho. Todas elas tomam por base uma PRE e fazem uma modificação na mesma, gerando uma nova. A razão de haver sete diferentes métodos para gerar PREs alternativas é a de que uma estratégia pode contribuir para atendimento à demanda de um produto, mas não contribuir para outro. Por exemplo, pode ser necessário aumentar a reposição de um produto e reduzir a de outro. O uso de diferentes estratégias, bem como a combinação delas, visa possibilitar a determinação de soluções para diversas situações de demanda e reposição de estoques.

A decisão sobre qual estratégia utilizar fica a cargo do módulo otimizador. Em dados momentos da execução deste módulo, ele poderá alterar a forma desta escolha, privilegiando o emprego de uma ou outra estratégia.

#### **4.5.8.1 Estratégia de Divisão do Evento com Maior Reposição**

Esta estratégia analisa todos os eventos de reposição de uma PRE com o objetivo de encontrar a de maior quantidade repostas. A idéia é dividir este evento da PRE em dois. Isto faz com que o saldo em estoque diminua, reduzindo custos de estocagem. A tabela 4.11 traz uma PRE hipotética antes da modificação.

Tabela 4.11 – PRE antes da Divisão do Evento com Maior Reposição.

| # | Data       | Qtd. Unidades Repostas | Intervalo Reposição Anterior |
|---|------------|------------------------|------------------------------|
| 1 | 06/07/2011 | 1.110                  | 0                            |
| 2 | 01/08/2011 | 1.210                  | 26                           |
| 3 | 01/09/2011 | 1.090                  | 31                           |
| 4 | 01/10/2011 | 1.600                  | 30                           |
| 5 | 08/11/2011 | 900                    | 37                           |
| 6 | 01/12/2011 | 1.050                  | 23                           |

Fonte: Autor

A tabela 4.12 exibe a PRE após a divisão da maior reposição.

Tabela 4.12 – PRE após da Divisão do Evento com Maior Reposição.

| #  | Data       | Qtd. Unidades Repostas | Intervalo Reposição Anterior |
|----|------------|------------------------|------------------------------|
| 1  | 06/07/2011 | 1.110                  | 0                            |
| 2  | 01/08/2011 | 1.210                  | 26                           |
| 3  | 01/09/2011 | 1.090                  | 31                           |
| *4 | 01/10/2011 | 800                    | 30                           |
| *5 | 19/10/2011 | 800                    | 18                           |
| 6  | 08/11/2011 | 900                    | 19                           |
| 7  | 01/12/2011 | 1.050                  | 23                           |

Fonte: Autor

O evento de maior reposição na tabela 4.11 era o de número 4, com 1.600 unidades. Na política com a divisão da maior reposição, tabela 4.12, ela foi dividida em duas. Manteve-se uma reposição na data original, apenas diminuiu-se a quantidade repostas à metade da original, 800 unidades. Foi então inserida uma nova reposição logo após, ou seja, entre os eventos 4 e 6 da PRE original, na metade do tempo decorrido entre as reposições da PRE original. Com esta nova forma, 800 unidades do produto serão repostas 18 dias mais tarde, fazendo com que o gasto em estocagem diminua na proporção de 800 unidades, multiplicado por 18 dias, multiplicado pelo custo unitário para manutenção de estoque do produto em questão. Por outro lado, com uma nova reposição, a rede varejista terá de pagar mais uma vez o custo de reposição do lote. O que é bom por um ponto de vista, é

pior por outro. A FO será utilizada para avaliar a qualidade da nova PRE. As modificações na PRE resultante estão indicadas pelo caractere “\*\*”.

#### 4.5.8.2 Estratégia de Remoção Aleatória de Evento de Reposição

Esta estratégia irá remover um evento de reposição de uma PRE, de forma aleatória, segundo uma distribuição uniforme. A idéia é verificar o desempenho do sistema com um evento de reposição a menos para dado produto, em dada loja. A tabela 4.13 traz a PRE antes da remoção do evento.

Tabela 4.13 – PRE antes da Remoção Aleatória de Evento de Reposição.

| # | Data       | Qtd. Unidades Repostas | Intervalo Reposição Anterior |
|---|------------|------------------------|------------------------------|
| 1 | 02/01/2011 | 1.000                  | 0                            |
| 2 | 01/02/2011 | 1.200                  | 30                           |
| 3 | 01/03/2011 | 1.040                  | 28                           |
| 4 | 03/04/2011 | 980                    | 33                           |
| 5 | 02/05/2011 | 990                    | 29                           |
| 6 | 04/06/2011 | 1.320                  | 33                           |

Fonte: Autor

Já a tabela 4.14 exibe a PRE após a remoção da reposição.

Tabela 4.14 – PRE após a Remoção Aleatória de Evento de Reposição.

| # | Data       | Qtd. Unidades Repostas | Intervalo Reposição Anterior |
|---|------------|------------------------|------------------------------|
| 1 | 02/01/2011 | 1.000                  | 0                            |
| 2 | 01/03/2011 | 1.040                  | 58                           |
| 3 | 03/04/2011 | 980                    | 33                           |
| 4 | 02/05/2011 | 990                    | 29                           |
| 5 | 04/06/2011 | 1.320                  | 33                           |

Fonte: Autor

No exemplo dado, o segundo evento de reposição da PRE original, contida na tabela 4.13, foi removido. Na PRE resultante, tabela 4.14, apenas o intervalo de reposição foi alterado, visto que ele aumentou com a retirada de um evento de reposição.

O objetivo de remover um evento de reposição é verificar como o sistema se comporta com a redução do número de unidades repostas. Pode ser que o evento de reposição anterior ao removido já forneça a quantidade de unidades necessária para atender às demandas no período, ou ainda, mesmo que não atenda totalmente, pode atender parcialmente com um nível aceitável de ruptura. Neste último caso, obviamente, com a ocorrência de rupturas, outras variáveis de interesse, também em análise, serão afetadas. Novamente a FO será utilizada para avaliar a nova PRE.

#### 4.5.8.3 Estratégia de Variação Uniforme na Quantidade Reposta

Esta estratégia irá variar a quantidade reposta em todos os eventos de reposição da PRE. Variar significa aumentar ou diminuir. A decisão a respeito disso fica a cargo de uma variável aleatória com distribuição de Bernoulli ( $p = 0,5$ ). Desta forma, serão dadas iguais chances de aumento ou redução nas quantidades repostas. Para exemplificar, assume-se que a decisão para variação foi de aumento

nas quantidades repostas e que o percentual de aumento (parâmetro do otimizador) seja de 10%. A tabela 4.15 mostra a PRE antes da modificação.

Tabela 4.15 – PRE antes da Variação Uniforme na Quantidade Reposta.

| # | Data       | Qtd. Unidades Repostas | Intervalo Reposição Anterior |
|---|------------|------------------------|------------------------------|
| 1 | 02/01/2011 | 1.000                  | 0                            |
| 2 | 01/02/2011 | 1.200                  | 30                           |
| 3 | 01/03/2011 | 1.040                  | 28                           |
| 4 | 03/04/2011 | 980                    | 33                           |
| 5 | 02/05/2011 | 990                    | 29                           |
| 6 | 04/06/2011 | 1.320                  | 33                           |

Fonte: Autor

A tabela 4.16 apresenta a PRE após a variação uniforme nas quantidades dos eventos de reposição.

Tabela 4.16 – PRE após a Variação Uniforme na Quantidade Reposta.

| # | Data       | Qtd. Unidades Repostas | Intervalo Reposição Anterior |
|---|------------|------------------------|------------------------------|
| 1 | 02/01/2011 | 1.100                  | 0                            |
| 2 | 01/02/2011 | 1.320                  | 30                           |
| 3 | 01/03/2011 | 1.144                  | 28                           |
| 4 | 03/04/2011 | 1.078                  | 33                           |
| 5 | 02/05/2011 | 1.089                  | 29                           |
| 6 | 04/06/2011 | 1.452                  | 33                           |

Fonte: Autor

Neste caso, como pode ser observado na tabela 4.16, todos os eventos de reposição sofreram um aumento de 10%. Com relação a este percentual, ele é um parâmetro do otimizador. A relação dos parâmetros do otimizador foi apresentada na seção 4.5.6.2.

O objetivo desta estratégia é aumentar ou diminuir as quantidades de produtos repostos em todos os eventos de reposição da PRE. Ela é bastante útil em casos onde exista uma distância entre o nível da demanda e o nível de reposição, ou seja, se as quantidades repostas estiverem muito abaixo da demanda prevista,

esta estratégia poderá aumentar estas quantidades, resultando em uma redução nas rupturas. Se as quantidades repostas estiverem muito acima da demanda, esta estratégia pode reduzir a quantidade de unidades repostas, fazendo com que os custos de estocagem e reposição sejam reduzidos. A FO deve ser utilizada para avaliar a PRE gerada a fim de determinar sua qualidade.

#### 4.5.8.4 Estratégia de Variação Singular na Quantidade Reposta

Esta estratégia é semelhante à Variação Uniforme na Quantidade Reposta, porém apenas um dos eventos de reposição da PRE, escolhido aleatoriamente segundo uma distribuição uniforme, terá a sua quantidade variada, podendo esta variação ser um aumento ou redução. A decisão a respeito disso fica a cargo de uma variável aleatória segundo a distribuição de Bernoulli ( $p = 0,5$ ), dando iguais chances para aumento ou redução das quantidades. Para exemplificar, assume-se que a decisão para variação foi de redução na quantidade reposta do evento número 4 e que o percentual de redução (parâmetro do otimizador) seja de 10%. A tabela 4.17 mostra a PRE antes da redução.

Tabela 4.17 – PRE antes da Variação Singular na Quantidade Reposta.

| # | Data       | Qtd. Unidades Repostas | Intervalo Reposição Anterior |
|---|------------|------------------------|------------------------------|
| 1 | 02/01/2011 | 1.000                  | 0                            |
| 2 | 01/02/2011 | 1.200                  | 30                           |
| 3 | 01/03/2011 | 1.040                  | 28                           |
| 4 | 03/04/2011 | 980                    | 33                           |
| 5 | 02/05/2011 | 990                    | 29                           |
| 6 | 04/06/2011 | 1.320                  | 33                           |

Fonte: Autor

A tabela 4.18 exibe a PRE após a variação singular.

Tabela 4.18 – PRE após a Variação Singular na Quantidade Reposta.

| #  | Data       | Qtd. Unidades Repostas | Intervalo Reposição Anterior |
|----|------------|------------------------|------------------------------|
| 1  | 02/01/2011 | 1.000                  | 0                            |
| 2  | 01/02/2011 | 1.200                  | 30                           |
| 3  | 01/03/2011 | 1.040                  | 28                           |
| *4 | 03/04/2011 | 882                    | 33                           |
| 5  | 02/05/2011 | 990                    | 29                           |
| 6  | 04/06/2011 | 1.320                  | 33                           |

Fonte: Autor

A diferença em relação à PRE inicial, tabela 4.17, é a redução de 10% na quantidade repostada do evento quatro, tabela 4.18. Esta estratégia irá funcionar para casos onde um ajuste fino é necessário, ou seja, pontos localizados da PRE são alterados. O evento de reposição modificado está sinalizado com “\*”.

#### 4.5.8.5 Estratégia de Inserção Aleatória de Evento de Reposição

Esta estratégia funciona de forma oposta à de Remoção Aleatória de Evento de Reposição, pois um evento de reposição será criado.

A alteração começa pela escolha aleatória de um evento, segundo uma distribuição uniforme. Em seguida, será procurado o evento de reposição com a maior reposição. O maior valor de quantidade repostada será então copiado para o evento escolhido aleatoriamente. Sobre esta quantidade ainda será aplicado um percentual de aumento. Em seguida é executada a estratégia de divisão do evento com maior reposição, conforme descrito na seção 4.5.8.1, por isso o maior valor de quantidade repostada da PRE é copiado para o evento escolhido aleatoriamente e

aumentado. Assim tem-se a garantia de que o evento escolhido aleatoriamente será dividido, criando um novo evento. Um exemplo desta estratégia pode ser visto nas tabelas 4.19 e 4.20.

Tabela 4.19 – PRE antes da Inserção Aleatória de Evento de Reposição.

| # | Data       | Qtd. Unidades Repostas | Intervalo Reposição Anterior |
|---|------------|------------------------|------------------------------|
| 1 | 02/01/2011 | 1.000                  | 0                            |
| 2 | 01/02/2011 | 1.200                  | 30                           |
| 3 | 01/03/2011 | 1.040                  | 28                           |
| 4 | 02/04/2011 | 980                    | 32                           |
| 5 | 02/05/2011 | 990                    | 29                           |
| 6 | 04/06/2011 | 1.320                  | 33                           |

Fonte: Autor

Assumindo que a posição selecionada aleatoriamente para inserção tenha sido o evento 4, ele terá sua quantidade substituída pela maior quantidade repostada encontrada na PRE, acrescida de 15%. Em seguida, a divisão da maior reposição é aplicada. O resultado pode ser verificado na tabela 4.20.

Tabela 4.20 – PRE após a Inserção Aleatória de Evento de Reposição.

| #  | Data       | Qtd. Unidades Repostas | Intervalo Reposição Anterior |
|----|------------|------------------------|------------------------------|
| 1  | 02/01/2011 | 1.000                  | 0                            |
| 2  | 01/02/2011 | 1.200                  | 30                           |
| 3  | 01/03/2011 | 1.040                  | 28                           |
| *4 | 02/04/2011 | 759                    | 32                           |
| *5 | 18/04/2011 | 759                    | 16                           |
| 6  | 02/05/2011 | 990                    | 13                           |
| 7  | 04/06/2011 | 1.320                  | 33                           |

Fonte: Autor

O maior valor repostado na PRE da tabela 4.19 foi de 1.320 unidades. Foram adicionados 15%, chegando ao valor de 1.518 unidades. Este valor foi então dividido, resultando nos eventos 4 e 5, com 759 unidades cada. O evento 4 manteve sua data e o novo evento foi inserido na metade do intervalo entre os eventos 4 e 5

da PRE inicial, resultando na PRE exibida na tabela 4.20. A idéia desta estratégia é criar eventos intermediários, de modo a suprir demandas sem gerar um nível elevado de estoque, e que não sejam tratados pela estratégia de divisão da maior reposição, uma vez que não são eventos de maior reposição.

#### 4.5.8.6 Estratégia de Distribuição Uniforme da Quantidade Reposta

Esta estratégia faz uma distribuição uniforme do total repostado em uma PRE. É calculada a média da quantidade repostada em função do número de eventos de reposição. A tabela 4.21 traz um exemplo de PRE com diferentes quantidades repostadas em cada um dos eventos de reposição.

Tabela 4.21 – PRE antes da Distribuição Uniforme da Quantidade Reposta.

| # | Data       | Qtd. Unidades Repostas | Intervalo Reposição Anterior |
|---|------------|------------------------|------------------------------|
| 1 | 02/01/2011 | 830                    | 0                            |
| 2 | 01/02/2011 | 1.040                  | 30                           |
| 3 | 01/03/2011 | 1.200                  | 28                           |
| 4 | 02/04/2011 | 520                    | 32                           |
| 5 | 02/05/2011 | 995                    | 29                           |
| 6 | 04/06/2011 | 1.600                  | 33                           |

Fonte: Autor

A quantidade total repostada nesta PRE da tabela 4.21 é de 6.185 unidades. Calculando a média deste valor pelo quantidade de reposições, chega-se ao valor de 1.030,833 unidades em cada evento. O único evento que terá um valor diferente é o primeiro, visto que uma diferença de 5 unidades foi averiguada em função da divisão desconsiderar números fracionários. O ajuste sempre é feito no primeiro evento, garantindo o atendimento às demandas. A PRE gerada pela aplicação desta estratégia pode ser vista na tabela 4.22.

Tabela 4.22 – PRE após a aplicação da Distribuição Uniforme da Quantidade Reposta.

| # | Data       | Qtd. Unidades Repostas | Intervalo Reposição Anterior |
|---|------------|------------------------|------------------------------|
| 1 | 02/01/2011 | 1.035                  | 0                            |
| 2 | 01/02/2011 | 1.030                  | 30                           |
| 3 | 01/03/2011 | 1.030                  | 28                           |
| 4 | 02/04/2011 | 1.030                  | 32                           |
| 5 | 02/05/2011 | 1.030                  | 29                           |
| 6 | 04/06/2011 | 1.030                  | 33                           |

Fonte: Autor

#### 4.5.8.7 Estratégia de Distribuição Local da Quantidade Reposta

Esta estratégia faz uma distribuição localizada das quantidades repostas em uma PRE. A distribuição é dita localizada pois ela irá atuar em apenas alguns eventos de reposição. A alteração começa pela escolha aleatória de um evento, segundo uma distribuição uniforme. Em seguida, calcula-se o total de unidades repostas entre o evento selecionado aleatoriamente e aquele imediatamente anterior. A distribuição agora é feita igualmente em tantas reposições quantas forem possíveis inserir entre o evento anterior e o posterior ao selecionado, respeitando o intervalo mínimo entre reposições do produto.

Para facilitar o entendimento, a tabela 4.23 apresenta um exemplo. Assume-se que o evento selecionado aleatoriamente foi o de número 3 e o intervalo mínimo entre reposições do produto em questão é de 10 dias.

Tabela 4.23 – PRE antes da aplicação da Distribuição Local da Quantidade Reposta.

| # | Data       | Qtd. Unidades Repostas | Intervalo Reposição Anterior |
|---|------------|------------------------|------------------------------|
| 1 | 02/01/2011 | 830                    | 0                            |
| 2 | 01/02/2011 | 1.040                  | 30                           |
| 3 | 01/03/2011 | 1.200                  | 28                           |
| 4 | 02/04/2011 | 520                    | 32                           |
| 5 | 02/05/2011 | 995                    | 29                           |
| 6 | 04/06/2011 | 1.600                  | 33                           |

Fonte: Autor

O total de unidades repostas entre os eventos 2 e 3 é de 2.240 unidades. Entre os eventos 2 e 4 existem 60 dias. O intervalo mínimo entre reposições é de 10 dias, logo, serão inseridos 6 eventos entre o evento 2 e o evento 4, repondo 373 unidades do produto a cada 10 dias. A PRE resultante da aplicação desta estratégia sobre a PRE constante na tabela 4.23 pode ser verificada na tabela 4.24.

Tabela 4.24 – PRE antes da aplicação da Distribuição Local da Quantidade Reposta.

| #  | Data       | Qtd. Unidades Repostas | Intervalo Reposição Anterior |
|----|------------|------------------------|------------------------------|
| 1  | 02/01/2011 | 830                    | 0                            |
| 2  | 01/02/2011 | 373                    | 30                           |
| 3  | 11/02/2011 | 373                    | 10                           |
| 4  | 21/02/2011 | 373                    | 10                           |
| 5  | 03/03/2011 | 373                    | 10                           |
| 6  | 13/03/2011 | 373                    | 10                           |
| 7  | 23/03/2011 | 373                    | 10                           |
| 8  | 02/04/2011 | 893                    | 10                           |
| 9  | 02/05/2011 | 995                    | 29                           |
| 10 | 04/06/2011 | 1.600                  | 33                           |

Fonte: Autor

No evento oito da tabela 4.24, a quantidade repostada é de 893 unidades. Isso ocorreu pois o último evento a ser inserido por esta estratégia coincidia com uma data já existente e que já tinha 520 unidades repostadas (evento 4 da tabela 4.23).

Esta estratégia é bastante útil para produtos que possuem demanda relativamente constante e sazonal, visto que ela distribui igualmente os níveis de reposição na PRE de forma localizada, respeitando a sazonalidade, quando ocorrer.

#### 4.5.9 Parâmetros Gerais da Ferramenta

Além dos parâmetros específicos dos módulos de simulação e otimização, existe ainda um outro conjunto de parâmetros utilizado na ferramenta. O objetivo é dar mais liberdade ao usuário da ferramenta, permitindo que este modifique os dados avaliados. Torna-se assim possível conduzir experimentos diversos, criando e simulando situações diferentes do observado no sistema real.

A tabela 4.25 apresenta estes parâmetros.

Tabela 4.25 – Parâmetros Gerais da Ferramenta.

| <b>Parâmetro</b>                   | <b>Objetivo esperado ou Função</b>   |
|------------------------------------|--|
| Coeficiente Modificador de Custos  | Permite que os valores de custos dos produtos sejam alterados através da aplicação de um coeficiente. O valor padrão deste parâmetro é 1. A variação deste parâmetro irá produzir valores maiores ou menores. Apenas valores maiores que zero são válidos.   |
| Coeficiente Modificador de Demanda | Permite que as demandas previstas sejam alteradas. Em um cenário padrão, o valor deste parâmetro é 1. Para simular uma demanda maior que a prevista, seu valor deverá ser maior que 1. Para simular uma demanda menor que a prevista, seu valor deverá ser menor que 1. Apenas valores maiores que zero são válidos. |
| Coeficiente Modificador de Lucro   | Parâmetro com as mesmas características do Coeficiente Modificador de Custos, porém aplicado aos valores de lucratividade.   |

Fonte: Autor

Estes parâmetros permitem modificar características dos dados do problema em questão. É possível, por exemplo, modificar a lucratividade de cada produto, aumentar ou reduzir as demandas, além de alterar os custos envolvidos na estocagem.

#### 4.5.10 Estrutura Geral do Algoritmo Implementado

A estrutura do algoritmo implementado durante o desenvolvimento deste trabalho pode ser verificado na figura 4.8. Partiu-se da estrutura básica do GLS e foram inseridos novos mecanismos. Nesta figura,  $\sigma$  representa o número máximo de iterações sem melhora para entrar no modo de atuação alternativo,  $\mu$  representa a taxa de crescimento do PA,  $\theta$  representa o tamanho da vizinhança,  $\varepsilon$  representa a quantidade de atributos alterados em uma solução para obtenção de uma nova e  $\tau$  representa o número de iterações para união das soluções relaxada e factível. As rotinas responsáveis pela geração de vizinhanças merecem destaque, já que é nelas que ocorre a integração com o módulo simulador. Estas rotinas podem ser verificadas na figura 4.9.

```

Procedimento OtimizadorEstoques( $\lambda, [I_1 \dots I_u], [c_1 \dots c_u], u, \sigma, \mu, \theta, \varepsilon, \tau$ )
     $k = 0$ 
    Para  $i = 1$  até  $u$  faça
         $p_i = 0$  // inicializa penalizações (zero)
     $h = g + \lambda \cdot \sum_{l=1}^u p_l \cdot I_l$  // define a FO Aumentada
     $S_0 = \text{Busca}_S0()$  // busca S0
    Inserir Atributos de  $S_0$  no PA
     $LED = \text{BuscaDemandas}(s_k, h)$  // busca as demandas por produtos
    Faça até que o critério de parada seja atingido
        Há espaço no pool de atributos?
             $\text{InserirPREsNoPool}(s_k, \mu, PA)$  // insere PREs alternativas no pool
             $s_{k+1} = \text{MelhorVizinho}(s_k, h, \theta, \varepsilon, LED, PA)$  // soluções vizinhas avaliadas pela FOA
            Para  $l = 1$  até  $u$  faça
                 $\text{util}_l(s) = I_l(s_{k+1}) \frac{c_l}{(1+p_l)}$  // calcula utilidade
            Para cada  $l$  tal que  $\text{util}_l(s)$  é máxima, faça
                 $p_l = p_l + 1$  // aplica penalização
            Está em modo de atuação alternativo?
                Retorna para modo de atuação regular
            Execução está a  $\sigma$  iterações sem melhora? // entra no modo de atuação alternativo
                Remover 50% dos atributos do PA
                Mudar Probabilidades de Geração PREs alternativas
                Mudar valor da variação % de quantidade reposta
                Taxa de crescimento  $\mu$  do PA passa para 10
                Tamanho vizinhança  $\theta$  passa para 50
                Qtd. atributos alterados em nova solução  $\varepsilon$  é dobrado
            Execução atingiu um ciclo  $\tau$  iterações?
                Unir soluções  $S^*$  e  $S^*$  Factível
             $k = k + 1$ 
    Fim - enquanto
    Retorne  $S^*$  (melhor solução encontrado com relação a  $g$ )
Fim GLS

```

Figura 4.8 – Estrutura do algoritmo desenvolvido no trabalho.  
Fonte: Autor

```

Procedimento MelhorVizinho(s, h, θ, ε, LED, PA)
    // rotina responsável por gerar soluções vizinhas e retornar a melhor delas
    Para i = 1 até θ faça
         $v_i = \text{NovaSolucao}(s, \varepsilon, PA)$  //cria nova solução com modificação de atributos
        Simular(LED, vi) // simula o sistema com a solução  $v_i$ 
    Fim - para
     $v^* =$  melhor solução vizinha encontrada com relação a h
    Retorne  $v^*$ 
Fim GLS

Procedimento NovaSolucao(s, ε, PA)
    // rotina responsável por alterar atributos de uma solução, gerando uma nova
     $s' = s$ 
    Para i = 1 até ε faça
        Trocar aleatoriamente um atributo de  $s'$  por outro contido no PA
    Fim - para
     $s' =$  nova solução
    Retorne  $s'$ 
Fim GLS

```

Figura 4.9 – Rotinas de geração de soluções vizinhas integradas ao módulo simulador.  
Fonte: Autor

## 5 Experimentos, Resultados e Validação

Neste capítulo serão apresentados os experimentos executados e os resultados obtidos com a ferramenta computacional desenvolvida. Alguns destes experimentos tratam da verificação da validade dos módulos, enquanto outros abordam testes baseados nos dados de demanda prevista para a rede varejista. Esta indicação será feita na descrição de cada um dos módulos.

Este capítulo foi dividido em três partes. A primeira trata do módulo previsor, a segunda do simulador e do gerador de política de reposição inicial e, a terceira parte, apresenta experimentos conduzidos com o módulo otimizador integrado aos demais.

### 5.1 Previsor de Demandas

O primeiro passo para gerar as previsões de demanda, segundo descrito na seção 4.5.2, é escolher um produto para cada categoria. O produto que apresentar o maior volume de vendas e tiver dois anos de dados históricos será utilizado para a definição dos parâmetros  $A$ ,  $B$  e  $C$  empregados na técnica de Suavização Exponencial. Com a utilização do banco de dados da ferramenta, a escolha destes produtos pôde ser feita de forma simples.

O segundo passo trata de efetivamente determinar os valores dos parâmetros de suavização. A tabela 5.1 apresenta os valores de  $A$ ,  $B$  e  $C$  escolhidos para cada categoria de produto, além do valor de  $S$  (equação (2.8)) relativo a tais parâmetros.

Tabela 5.1 – Parâmetros para o módulo previsor.

| <b>Categoria</b> | <b>S</b>   | <b>A</b> | <b>B</b> | <b>C</b> |
|------------------|------------|----------|----------|----------|
| 1                | 1.668.858  | 0,05     | 0,05     | 0,05     |
| 2                | 481.032    | 0,05     | 0,05     | 0,30     |
| 3                | 171.985    | 0,05     | 0,05     | 0,05     |
| 4                | 10.872     | 0,05     | 0,05     | 0,05     |
| 5                | 1.438      | 0,05     | 0,05     | 0,15     |
| 6                | 40.874     | 0,05     | 0,05     | 0,05     |
| 7                | 8.188.272  | 0,05     | 0,05     | 0,20     |
| 8                | 3.162      | 0,10     | 0,05     | 0,05     |
| 9                | 4.527      | 0,05     | 0,05     | 0,25     |
| 10               | 42         | 0,35     | 0,05     | 0,05     |
| 11               | 75         | 0,05     | 0,05     | 0,25     |
| 12               | 53.095     | 0,15     | 0,05     | 0,10     |
| 13               | 106        | 0,05     | 0,05     | 0,10     |
| 14               | 28.404     | 0,05     | 0,05     | 0,15     |
| 15               | 573.932    | 0,15     | 0,05     | 0,05     |
| 16               | 1.891.797  | 0,05     | 0,05     | 0,05     |
| 17               | 243.535    | 0,05     | 0,05     | 0,05     |
| 18               | 72.100.297 | 0,05     | 0,10     | 0,05     |
| 19               | 722.657    | 0,20     | 0,35     | 0,05     |

Fonte: Autor.

Apesar da redução na necessidade de geração de parâmetros, conforme discutido na seção 4.5.2, o processo de avaliação e escolha de *A*, *B* e *C*, para cada categoria, além da geração das previsões de demanda de todos os produtos, exigiram aproximadamente 16 horas para serem finalizados, utilizando o equipamento indicado na seção 5.5.

Na tabela 5.2 é possível verificar o valor do indicador MAPE por categoria. Na segunda coluna é apresentado o indicador MAPE do produto escolhido para avaliação dos parâmetros *A*, *B* e *C* da categoria. A terceira coluna contém o MAPE do produto que apresentou o menor valor para este indicador dentro da categoria. Já a quarta coluna contém o valor do MAPE para o produto que apresentou o maior valor deste indicador dentro da categoria.

Tabela 5.2 – Avaliação do indicador MAPE frente aos dados obtidos no processo de previsão.

| <b>Categoria</b> | <b>MAPE Categoria</b> | <b>MAPE Mínimo</b> | <b>MAPE Máximo</b> |
|------------------|-----------------------|--------------------|--------------------|
| 1                | 2,0397                | 0,0205             | 5,5902             |
| 2                | 1,1289                | 0,0109             | 8,1315             |
| 3                | 0,7508                | 0,0164             | 7,1468             |
| 4                | 0,9976                | 0,0246             | 1,0677             |
| 5                | 0,6610                | 0,0219             | 2,5077             |
| 6                | 1,5407                | 0,0205             | 3,5806             |
| 7                | 5,3625                | 0,0164             | 10,8337            |
| 8                | 0,9980                | 0,0082             | 1,3663             |
| 9                | 0,8083                | 0,0137             | 1,9842             |
| 10               | 0,0601                | 0,0027             | 1,0099             |
| 11               | 0,1366                | 0,0137             | 1,0000             |
| 12               | 0,5792                | 0,0109             | 0,9126             |
| 13               | 0,1544                | 0,0164             | 1,0000             |
| 14               | 1,7198                | 0,0150             | 3,1406             |
| 15               | 0,6873                | 0,0137             | 2,8185             |
| 16               | 0,5640                | 0,0246             | 9,4308             |
| 17               | 0,8437                | 0,0219             | 4,8946             |
| 18               | 4,8630                | 0,0219             | 8,5558             |
| 19               | 1,9906                | 0,0055             | 6,2900             |

Fonte: Autor.

Através de uma análise dos valores apresentados na coluna “MAPE Máximo” da tabela 5.2, é possível verificar que algumas categorias apresentam casos de erro destacadamente mais alto. Os cinco piores casos, categorias 2, 3, 7, 16 e 18, foram analisados. Descobriu-se que os produtos que apresentaram os maiores valores de erro são produtos novos ou descontinuados.

No caso de produtos novos, existem dados de venda para o segundo ano, ou parte dele, mas não para o primeiro. A previsão é feita com base nos valores do primeiro ano e, como estas observações não existem, a previsão gerada também trouxe valores zerados, enquanto que a demanda real, observada no segundo ano é não nula. Assim, os altos erros apurados se justificam.

De forma análoga, produtos descontinuados apresentam dados no primeiro ano, ou parte dele, mas não no segundo. A previsão foi feita sobre as observações do primeiro ano, não nulas, gerando previsões para o segundo ano, também não

nulas. Contudo, não existem valores observados no segundo ano de dados, gerando também altos erros.

Existem ainda duas categorias, 7 e 18, que apresentam um erro alto para a coluna “MAPE Categoria”, os valores são, respectivamente, 5,3625 e 4,863.

O caso da categoria 18, que apresentou MAPE de 4,863, é explicado pelo fato de ocorrerem súbitas e localizadas reduções nas demandas observadas no segundo ano, principalmente nos meses de junho, agosto, setembro e novembro, conforme pode ser verificado na figura 5.1. O parâmetro A, responsável pela suavização do nível da série temporal, teve o valor de 0,05, de acordo com a tabela 5.2. Este valor é bastante baixo. Lembrando, quanto maior for o valor de A, mais rapidamente os valores do passado perdem significado. A utilização de um valor baixo para A fez com que valores mais recentes da ST tivessem pouca influência na previsão. Um valor mais alto para A poderia deixar a previsão mais sensível a mudanças repentinas, mas teria consequências em outros pontos da ST. O resultado prático é que a previsão manteve seu nível alto, não conseguindo adaptar rapidamente seu comportamento às súbitas reduções, gerando grandes erros em pontos localizados.

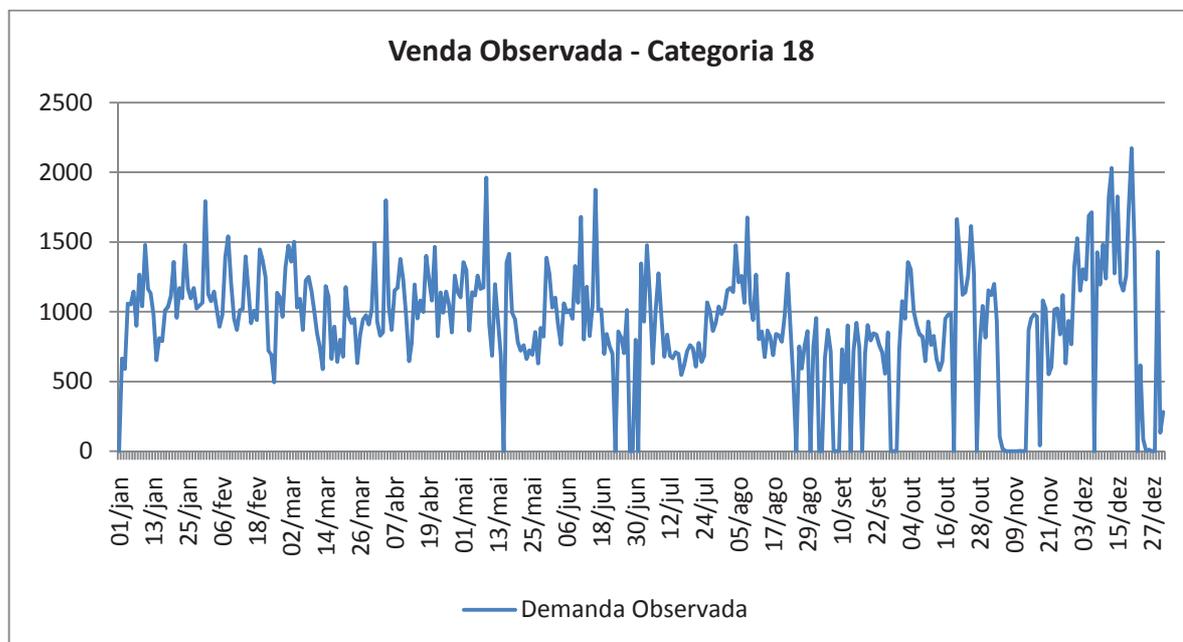


Figura 5.1 – Análise do indicador MAPE da categoria de produtos 18.  
Fonte: Autor

Já o caso da categoria 7, com MAPE de 5,3625, pode ser explicado pelo fato de que o produto foi descontinuado no final do segundo ano. Na figura 5.2 é apresentado o gráfico com as demandas observadas do produto em seu primeiro ano. Na figura 5.3 é apresentado o gráfico do segundo ano de dados, com as demandas observadas e previstas.

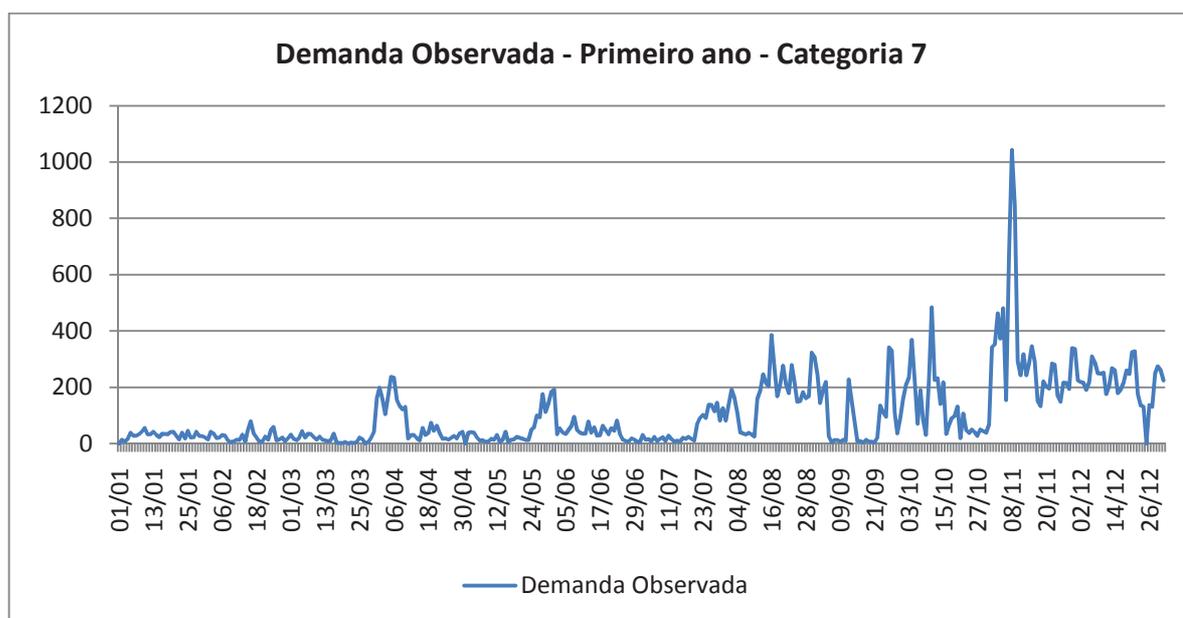


Figura 5.2 – Demanda observada do produto da categoria 7 em seu primeiro ano.  
Fonte: Autor

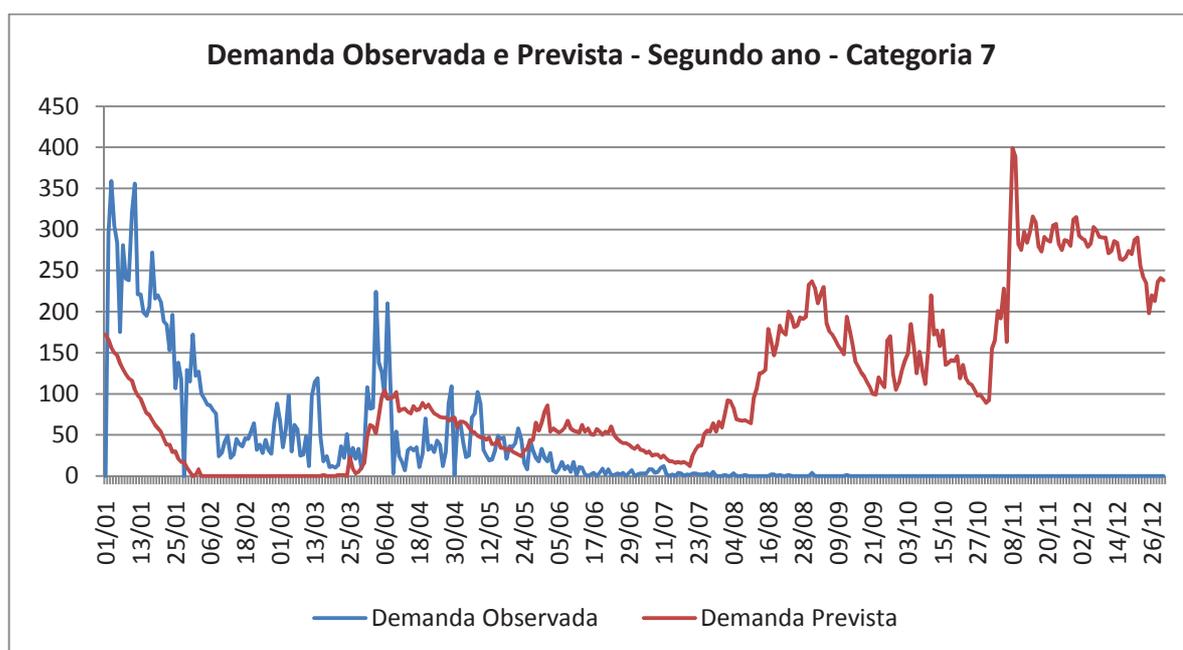


Figura 5.3 – Demanda observada e prevista do produto da categoria 7 em seu segundo ano.  
Fonte: Autor

Ao comparar o gráfico da figura 5.2 com os dados de demanda prevista do gráfico da figura 5.3, é possível verificar que o método predictor reproduz satisfatoriamente o comportamento observado no primeiro ano. Contudo, como já foi dito, este produto foi descontinuado em meados da ST da figura 5.3. Isto resultou em uma previsão de demanda com comportamento semelhante ao observado no primeiro ano, porém em um nível mais baixo, uma vez que no final do segundo ano as demandas observadas são zero, ou muito próximas de zero, por cerca de quatro meses. Novamente a ST prevista demora muito para se adaptar a mudanças bruscas nos valores observados no segundo ano, visto que o parâmetro  $A$  tem valor 0,05, bastante baixo.

Um fato interessante no gráfico da figura 5.3 são os valores iniciais das demandas previstas. O método de inicialização do modelo predictor é feito através do cálculo da média das cinco últimas observações do primeiro ano de dados. A previsão começa um pouco abaixo de 200 unidades, o que é adequado, já que o primeiro ano de dados, figura 5.2, termina em valores próximos a 200. A partir daí, os valores previstos diminuem. É perceptível a existência de uma tendência no início da demanda observada na figura 5.3, no entanto, esta não é o principal motivo para o declínio dos valores previstos, visto que o parâmetro  $B$ , responsável pela ponderação da tendência, é 0,05, ou seja, muito pouco da tendência recente é levada em conta. Esta redução ocorre, na realidade, motivada pela característica sazonal apresentada no primeiro ano, figura 5.2, que leva as demandas a valores inferiores a 100 unidades no período inicial do ano. O valor do parâmetro  $C$ , que controla a característica sazonal, é 0,20

Os valores de  $A$ ,  $B$  e  $C$  foram selecionados automaticamente por um processo iterativo que considera o menor erro global. Em cada previsão gerada podem ser encontradas situações específicas como as recém vistas. A seleção dos valores de  $A$ ,  $B$  e  $C$ , bem como as previsões de demanda, foram feitas por um processo automatizado. Casos especiais necessitam de análise e intervenção humana.

A análise feita mostra que o módulo predictor desenvolvido neste trabalho utilizando SE consegue reproduzir o comportamento observado no passado de séries temporais e, por isso, pode ser dado como validado. O fato de existirem casos

específicos, tais como os apresentados nesta seção, não invalida ou inviabiliza seu uso no que se refere a um método automatizado. O que se faz necessário é a intervenção humana em determinados casos.

Os valores de  $A$ ,  $B$  e  $C$ , em muitos casos dentro do contexto deste trabalho, podem não ser os mais apropriados, uma vez que eles foram gerados com base nos dados de apenas um produto de cada categoria. A parametrização por categoria pode ser boa para alguns produtos, mas talvez não para outros. Novamente, isto não invalida ou inviabiliza o método automatizado na forma como foi proposto, visto que, com um maior esforço computacional, os valores adequados de  $A$ ,  $B$  e  $C$  poderiam ser obtidos para cada um dos produtos.

## **5.2 Validação do Simulador e Gerador de Política de Reposição Inicial**

O módulo simulador desempenha um papel fundamental dentro da ferramenta desenvolvida neste trabalho. Ele tem a função de apurar o comportamento da rede varejista com base nas demandas pelos produtos (LEDs), fornecidas pelo módulo previsor, e nas políticas de reposição de estoques (PREs), sugeridas pelo módulo otimizador. Em outras palavras, dado um conjunto de demandas e uma SR ( $S_k$ ), proposta pelo otimizador, o simulador determina como o sistema se comporta no período de tempo que compreende estes dados. Através dos indicadores de desempenho, o resultado da simulação será então devolvido para o módulo otimizador, que fará uso da FO para determinar a qualidade das soluções propostas. A validação do simulador está embasada em dois experimentos que serão descritos nas seções 5.2.1 e 5.2.2.

### **5.2.1 Simulação Baseada em Demandas Observadas**

O primeiro experimento objetivando a comprovação do funcionamento adequado deste módulo é a simulação da realidade observada. Isso foi feito através do uso do simulador com as demandas observadas no lugar das demandas previstas e com as políticas de reposição de estoques observadas, segundo definido na seção 4.5.4.1. Ao final da execução do simulador, com as demandas e políticas de reposição observadas, o valor de seus indicadores de desempenho refletiram a situação esperada, ou seja, 100% de atendimento à demanda, nenhuma ocorrência de ruptura de estoque, sem penalizações por violação às restrições do problema, tanto para intervalos de reposição quanto para atendimento individual das demandas.

### **5.2.2 Simulação Baseada em Demandas Previstas**

O segundo experimento relativo à validação do simulador compreende a sua execução com as demandas previstas e as políticas de reposição de estoque geradas para este fim, segundo descrito na seção 4.5.4.2. Esta simulação obteve novamente 100% de atendimento à demanda, nenhuma ocorrência de ruptura de estoque, sem penalizações por violação às restrições do problema, tanto para intervalos de reposição quanto para atendimento individual das demandas. Lembrando, este resultado foi possível pois a SR gerada supre os estoques de cada produto em cada loja com o total da demanda do período todo.

### 5.3 Otimizador de Níveis Estoques

Os experimentos conduzidos com o módulo otimizador contemplam todos os módulos da ferramenta desenvolvida, já que ele depende dos demais para que possa ser utilizado. Os experimentos foram feitos com base em 3 instâncias de problema, denominadas IP1, IP2 e IP3.

Cada instância de problema possui um conjunto de valores para os parâmetros da ferramenta, especialmente no que tange aos fatores equalizadores da FO. Lembrando, os fatores equalizadores têm a função de diminuir, ou até mesmo eliminar, a diferença de magnitude entre os componentes da FO. Exemplos típicos são os valores monetários envolvidos (*RFG*) e o retorno sobre o montante investido (*MMFI*). O *RFG* é a diferença entre lucro (*LGV*) e custo (*CGE*), enquanto que o *MMFI* é a razão entre *LGV* e *CGE*. Dependendo do porte do problema, a variação na magnitude do *RFG* pode chegar a quatro ordens de grandeza. Contudo, a magnitude do *MMFI* deverá variar pouco se comparada à variação do *RFG*, sendo observadas variações de apenas uma ordem de grandeza. Por isso, é muito importante que os fatores equalizadores sejam devidamente calibrados de acordo com o porte do problema.

Nas seções 5.3.1 a 5.3.3 são apresentados os experimentos 1, 2 e 3. Eles tratam do problema da instância IP1, onde a solução exata para um caso de teste simples é conhecida. O objetivo destes três experimentos, que possuem complexidade crescente entre si, é apresentar a validação do módulo otimizador, uma vez que, por apresentarem casos simples, a solução exata deve ser encontrada na maioria das execuções da ferramenta. Em outras palavras, tais experimentos visam comprovar que a ferramenta é efetiva naquilo a que se propõe.

A instância IP1 trata de casos de pequeno porte e considera apenas duas demandas com comportamentos distintos. A tabela 5.3 apresenta os valores dos parâmetros utilizados pela ferramenta para esta instância de problema.

Tabela 5.3 – Parâmetros utilizados nos Experimentos da Instância IP1.

| <b>Parâmetro/Restrição</b>                            | <b>Valor</b> |
|---|--------------|
| Fator equalizador componente $RG$ ( $\alpha$ )        | 1            |
| Fator equalizador componente $RFG$ ( $\beta$ )        | 1            |
| Fator equalizador componente $IRT$ ( $\gamma$ )       | 1            |
| Fator equalizador componente $MMFI$ ( $\omega$ )      | 100          |
| Fator equalizador componente $PNSGME$ ( $\varphi$ )   | 100          |
| Peso componente $RG$ ( $b$ )                          | 2            |
| Peso componente $RFG$ ( $a$ )                         | 1            |
| Peso componente $IRT$ ( $c$ )                         | 1            |
| Peso componente $MMFI$ ( $d$ )                        | 5            |
| Peso componente $PNSGME$ ( $e$ )                      | 2            |
| Peso/fator equalizador penalização restrição $LT_k$   | 1.000        |
| Peso/fator equalizador penalização restrição $PNSA_k$ | 1.000        |
| $PNSE_k$  | 100%         |
| $PNSGME$  | 100%         |
| Tamanho da Vizinhança Modo Regular                    | 20           |
| Tamanho da Vizinhança Modo Alternativo                | 100          |
| Tamanho do <i>Pool</i> de Atributos                   | 30           |
| Quantidade de atributos alterados em nova solução     | 1            |
| Coeficiente de intensificação GLS ( $\lambda$ )       | -1           |

Fonte: Autor.

Nas seções 5.3.4 a 5.3.7, são apresentados os experimentos 4, 5, 6 e 7. Eles tratam de casos da instância IP2, utilizando dados gerados pelo módulo previsor. O objetivo é mostrar que a ferramenta é capaz de encontrar soluções para instâncias maiores e com características diversas. Esta instância de problema utiliza dados de demanda prevista e reposição de estoques de 10 lojas e 1.782 produtos, totalizando 13.120 demandas. Nestes experimentos, alguns parâmetros gerais da ferramenta, descritos na seção 4.5.9, são modificados. O objetivo é alterar o cenário padrão da instância, e assim verificar o comportamento da ferramenta em diferentes situações. No experimento 4 não há alteração nos dados do problema. Já nos experimentos 5 a 7, são impostas modificações para que seja possível a avaliação destes novos cenários. É importante evidenciar a diferença existente entre os parâmetros da

tabela 5.4 e os parâmetros utilizados para alteração do cenário padrão, apresentados na seção 4.5.9. Os parâmetros da tabela 5.4 dizem respeito ao comportamento da ferramenta, enquanto que os parâmetros da seção 4.5.9 são empregados para modificar os dados referentes ao comportamento da demanda a ser considerada no problema.

Tabela 5.4 – Parâmetros utilizados nos Experimentos dos Problemas da Instância IP2.

| <b>Parâmetro/Restrição</b>                            | <b>Valor</b>       |
|---|--------------------|
| Fator equalizador componente $RG$ ( $\alpha$ )        | $1 \times 10^{-4}$ |
| Fator equalizador componente $RFG$ ( $\beta$ )        | $5 \times 10^{-4}$ |
| Fator equalizador componente $IRT$ ( $\gamma$ )       | $1 \times 10^{-2}$ |
| Fator equalizador componente $MMFI$ ( $\omega$ )      | 1.000              |
| Fator equalizador componente $PNSGME$ ( $\varphi$ )   | 1.000              |
| Peso componente $RG$ ( $b$ )                          | 3                  |
| Peso componente $RFG$ ( $a$ )                         | 1                  |
| Peso componente $IRT$ ( $c$ )                         | 3                  |
| Peso componente $MMFI$ ( $d$ )                        | 10                 |
| Peso componente $PNSGME$ ( $e$ )                      | 4                  |
| Peso/fator equalizador penalização restrição $LT_k$   | 1.000              |
| Peso/fator equalizador penalização restrição $PNSA_k$ | 1.000              |
| $PNSE_k$  | 90%                |
| $PNSGME$  | 95%                |
| Tamanho da Vizinhança Modo Regular                    | 30                 |
| Tamanho da Vizinhança Modo Alternativo                | 100                |
| Tamanho do <i>Pool</i> de Atributos                   | 30                 |
| Quantidade de atributos alterados em nova solução     | 50                 |
| Coeficiente de intensificação GLS ( $\lambda$ )       | -1                 |

Fonte: Autor.

Na seção 5.3.8 é apresentado o experimento 8. Ele trata da instância IP3, denominado caso completo, uma vez que compreende todas as demandas previstas da rede varejista. Ao todo são 2.236 produtos comercializados em 317 lojas. O tamanho do problema, ou seja, o total de demandas avaliadas, é de 203.098. O

conjunto de valores para os parâmetros utilizados pela ferramenta neste experimento é apresentado na tabela 5.5.

Tabela 5.5 – Parâmetros utilizados nos Experimentos dos Problemas da Instância IP3.

| <b>Parâmetro/Restrição</b>                            | <b>Valor</b>       |
|---|--------------------|
| Fator equalizador componente $RG$ ( $\alpha$ )        | $5 \times 10^{-8}$ |
| Fator equalizador componente $RFG$ ( $\beta$ )        | $1 \times 10^{-5}$ |
| Fator equalizador componente $IRT$ ( $\gamma$ )       | $1 \times 10^{-2}$ |
| Fator equalizador componente $MMFI$ ( $\omega$ )      | 10.000             |
| Fator equalizador componente $PNSGME$ ( $\varphi$ )   | 10.000             |
| Peso componente $RG$ ( $b$ )                          | 1                  |
| Peso componente $RFG$ ( $a$ )                         | 5                  |
| Peso componente $IRT$ ( $c$ )                         | 1                  |
| Peso componente $MMFI$ ( $d$ )                        | 1                  |
| Peso componente $PNSGME$ ( $e$ )                      | 3                  |
| Peso/fator equalizador penalização restrição $LT_k$   | 200                |
| Peso/fator equalizador penalização restrição $PNSA_k$ | 200                |
| $PNSE_k$  | 90%                |
| $PNSGME$  | 90%                |
| Tamanho da Vizinhança Modo Regular                    | 18                 |
| Tamanho da Vizinhança Modo Alternativo                | 30                 |
| Tamanho do <i>Pool</i> de Atributos                   | 8                  |
| Quantidade de atributos alterados em nova solução     | 2.000              |
| Coeficiente de intensificação GLS ( $\lambda$ )       | -3                 |

Fonte: Autor.

Os demais parâmetros utilizados pela ferramenta, listados na tabela 5.6, tiveram o mesmo valor para todos os experimentos.

Tabela 5.6 – Parâmetros da ferramenta comuns a todos os experimentos.

| <b>Parâmetro</b>                                     | <b>Valor</b> |
|--|--------------|
| Quantidade de iterações                              | 8.000        |
| Quantidade de iterações para união de soluções       | 100          |
| Quantidade de iterações para alterar modo de atuação | 70           |
| Período  | 1 ano        |

Fonte: Autor.

Os valores atribuídos a cada um dos parâmetros foram determinados durante a fase de desenvolvimento e testes da ferramenta. Durante esta fase, vários testes foram executados, visando verificar o funcionamento da ferramenta e a sintonia dos parâmetros a serem utilizados. Os valores selecionados para cada parâmetro permitem que o espaço de soluções seja explorado inclusive em regiões inactivíveis. A atribuição de valores que não permitam a busca desta forma ocasiona, em muitos casos, a sua estagnação prematura ou até mesmo faz com que soluções melhores do que a inicial não sejam encontradas. Durante a realização dos experimentos observou-se que, para a obtenção de melhores soluções, a trajetória de busca deve passar por regiões inactivíveis do espaço de soluções.

Cabe também observar que, com relação aos parâmetros “Tamanho da Vizinhança Modo Regular” e “Tamanho da Vizinhança Modo Alternativo”, a relação deles com o tamanho do problema não é linear. Em problemas maiores, a troca de muitas políticas de reposição resulta na estagnação da FO, fazendo com que o otimizador não obtenha melhoras satisfatórias. Por este motivo, o valor destes parâmetros não aumenta na mesma proporção que o tamanho do problema.

Durante os experimentos realizados, observou-se que os valores iniciais da FO podem se apresentar negativos, visto que a  $S_0$  utilizada pode gerar altos custos, pois ela supre o estoque de cada produto com o total da demanda prevista no período de 1 ano e assume uma reposição única no primeiro dia do referido período. Por este motivo, a forma de cálculo da variação percentual entre a FO inicial e a FO da solução ótima é dada pela equação (5.1). O objetivo é mostrar o ganho obtido contemplando a distância entre a solução inicial e a solução encontrada ao final da execução do processo de otimização.

$$\text{Variação} = \frac{FO(S^*) - FO(S_0)}{|FO(S_0)|}, \quad (5.1)$$

onde:

$FO(S^*)$ : valor da FO da solução encontrada no final da otimização;

$FO(S_0)$  valor da FO da solução inicial  $S_0$ .

A equação (5.1) também é utilizada para o cálculo da variação de outros indicadores da solução. Neste caso, é necessário substituir o valor da FO pelo valor do respectivo indicador obtido na solução inicial e final.

Em alguns experimentos, os gráficos utilizados para apresentação da evolução da FO durante o processo de otimização foram adaptados para melhor visualização. Deles foram retirados o valor da FO de  $S_0$ , visto que a diferença entre tal valor e os demais pontos do gráfico era muito grande, fazendo com que a visualização do mesmo fosse prejudicada.

### 5.3.1 Experimento 1 - Demanda Diária Constante

Este experimento diz respeito a um produto da instância IP1 e tem o objetivo de validar o módulo otimizador. Tal produto tem demanda diária constante de 1 unidade, ou seja, a cada dia, uma unidade do produto é vendida. Por se tratar de um caso simplificado, é possível determinar a solução exata e ótima do problema. Na

tabela 5.7 são apresentados o lucro unitário, o intervalo mínimo entre reposições, bem como os custos relacionados ao produto.

Tabela 5.7 – Características do Experimento 1.

| <b>Variável/Restrição</b>         | <b>Valor</b> |
|-----------------------------------|--------------|
| Custo Estocagem Dia               | 0,10         |
| Custo Unitário de Reposição       | 0,10         |
| Custo Lote de Reposição           | 0,00         |
| Lucro Unitário                    | 6,00         |
| Intervalo Mínimo entre Reposições | 1            |

Fonte: Autor.

Com os dados da tabela 5.7, é possível determinar que a melhor política de reposição para o produto em questão é repor 1 unidade diariamente. Isso irá atender plenamente à demanda e irá gerar o menor custo possível, já que o custo de reposição do lote é nulo. O custo neste caso é de 36,50 Unidades Monetárias (UM). É importante esclarecer que o custo de estocagem por dia aqui não existe, uma vez que, ao final de cada dia, onde este custo é apurado, não existem unidades em estoque. O custo de estocagem por dia incidirá apenas quando, ao final de um dia, existir estoque não nulo na loja. O lucro da solução exata é de 2.190 UM.

A ferramenta foi executada 10 vezes durante este experimento, sendo que em apenas uma delas a solução exata não foi alcançada, porém um sub-ótimo muito próximo foi atingido, onde o custo de armazenamento apurado foi um pouco mais alto, 48,10 UM, permanecendo os indicadores de lucratividade e atendimento às demandas tão bons quanto nas execuções onde a solução ótima foi encontrada. A tabela 5.8 apresenta os valores iniciais de cada componente de  $S_0$ , os valores obtidos ao final de uma das execuções na qual foi encontrado o valor exato do problema ( $S^*$ ), bem como a variação percentual entre os valores, conforme definido na equação (5.1).

Tabela 5.8 – Resultados do Experimento 1.

| Indicador | $S_0$     | $S^*$    | Variação   |
|-----------|-----------|----------|------------|
| FO        | -4.486,22 | 2753,50  | 161,38%    |
| LGV       | 2.190     | 2.190    | 0,00%      |
| CGE       | 6.679,50  | 36,50    | -99,45%    |
| RFG       | -4.489,50 | 2.153,50 | 147,97%    |
| PNSGA     | 100%      | 100%     | 0,00%      |
| MMFI      | 0,33      | 60,00    | 18.081,82% |

Fonte: Autor.

A figura 5.4 apresenta o gráfico da evolução da FO para uma das execuções que encontrou o valor ótimo para o problema em questão.

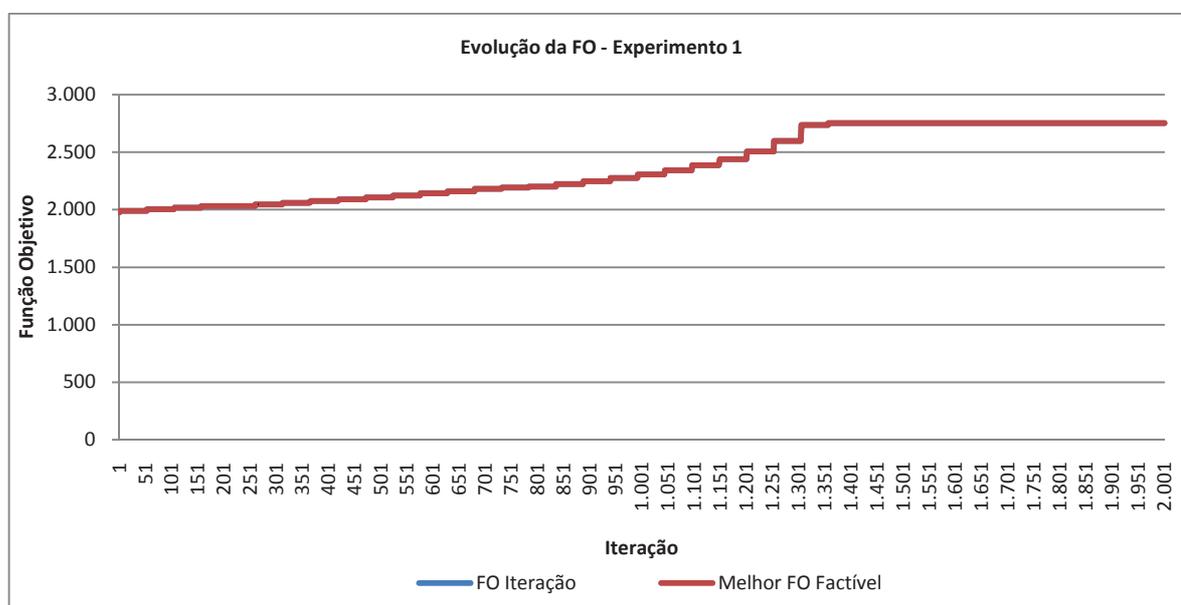


Figura 5.4 – Evolução da FO para cada iteração – Experimento 1.

Fonte: Autor

No gráfico da figura 5.4 o valor da FO de  $S_0$  foi suprimido para uma melhor visualização.

Para a execução da ferramenta onde a solução ótima não foi encontrada, a FO final teve o valor de 2.597,20. O valor médio da FO para dez execuções da ferramenta foi de 2.737,87, um pouco abaixo da solução ótima.

### 5.3.2 Experimento 2 - Demanda Cíclica Constante

O segundo experimento também tem o objetivo de validar o módulo otimizador. O problema aqui tratado compreende o segundo produto da instância IP1. Tal produto tem demanda constante de 5 unidades e ocorre a cada 5 dias. Aqui também é possível determinar a solução ótima para o problema. As características que influenciam o problema, lucro unitário, custos e intervalo mínimo entre reposições, são apresentadas na tabela 5.9.

Tabela 5.9 –Características do Experimento 2.

| <b>Variável/Restrição</b>         | <b>Valor</b> |
|-----------------------------------|--------------|
| Custo Estocagem Dia               | 1,00         |
| Custo Unitário de Reposição       | 0,50         |
| Custo Lote de Reposição           | 0,00         |
| Lucro Unitário                    | 5,00         |
| Intervalo Mínimo entre Reposições | 5            |

Fonte: Autor.

A partir dos dados da tabela 5.9, é possível determinar que a melhor forma de repor o estoque do produto é abastecer a loja com as 5 unidades que serão vendidas nos dias específicos, atendendo à totalidade da demanda, gerando o menor custo possível e respeitando a restrição do intervalo mínimo entre reposições. Neste caso, a demanda total pelo produto durante o ano é de 365 unidades, gerando um lucro de 1.825,00 UM ao custo de 182,50 UM.

Novamente a ferramenta foi executada 10 vezes, sendo que, em todas elas, a solução ótima foi encontrada. A tabela 5.10 apresenta os valores iniciais de cada componente de  $S_0$ , os valores obtidos ao final de cada uma das execuções, bem como a variação percentual entre os valores.

Tabela 5.10 – Resultados do Experimento 2.

| Indicador | $S_0$      | $S^*$    | Varição    |
|-----------|------------|----------|------------|
| FO        | -64.057,20 | 1.742,50 | 102,72%    |
| LGV       | 1.825,00   | 1.825,00 | 0,00%      |
| CGE       | 65.882,50  | 182,50   | -99,72%    |
| RFG       | -64.057,50 | 1.642,50 | 102,56%    |
| PNSGA     | 100%       | 100%     | 0,00%      |
| MMFI      | 0,03       | 10,00    | 32.233,33% |

Fonte: Autor.

A figura 5.5 apresenta o gráfico da evolução da FO para uma das execuções que encontrou o valor ótimo para o problema em questão.

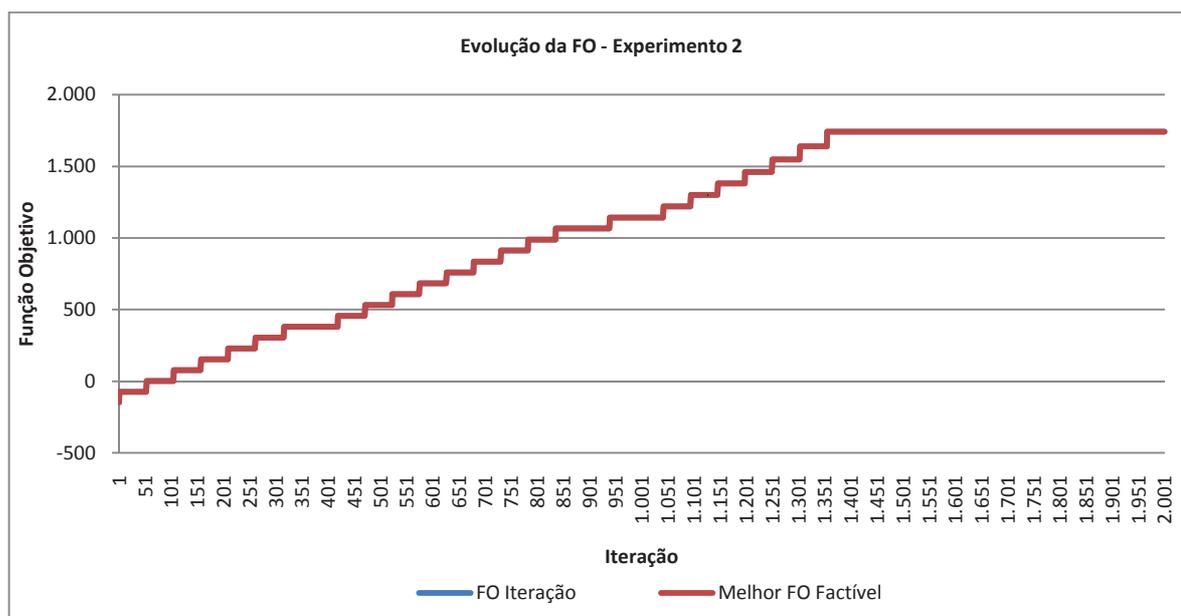


Figura 5.5 – Evolução da FO para cada iteração – Experimento 2.

Fonte: Autor

No gráfico da figura 5.5 o valor da FO de  $S_0$  foi suprimido para uma melhor visualização.

### 5.3.3 Experimento 3 - Demandas Diária Constante e Cíclica Constante

O terceiro e último experimento visando à validação do otimizador trata da demanda dos dois produtos da instância IP1. Eles foram utilizados independentemente nos experimentos 1 e 2. O objetivo agora é mostrar que a ferramenta é capaz de encontrar a solução ótima para os dois casos conjuntamente.

Neste experimento, a solução exata do problema gera um lucro de 4.015 UM a um custo total de 219,00 UM, ou seja, é a soma dos valores obtidos nos experimentos 1 e 2. Mais uma vez a ferramenta foi executada 10 vezes e em apenas uma das dez execuções não foi obtida a solução exata. No entanto, a solução sub-ótima encontrada em uma das execuções chegou ao mesmo valor de lucro e atendimento às demandas, porém com um custo de 219,60 UM, isto é, 0,60 UM acima do valor exato. A tabela 5.11 apresenta os valores iniciais de cada componente de  $S_0$ , os valores obtidos ao final de uma das execuções que encontrou a solução exata, bem como a variação percentual dos valores.

Tabela 5.11 – Resultados do Experimento 3.

| <b>Indicador</b> | <b><math>S_0</math></b> | <b><math>S^*</math></b> | <b>Variação</b> |
|------------------|-------------------------|-------------------------|-----------------|
| FO               | -68.546,40              | 3.979,33                | 105,81%         |
| LGV              | 4.015                   | 4.015                   | 0,00%           |
| CGE              | 72.562,00               | 219,00                  | -99,70%         |
| RFG              | -68.547,00              | 3.796,00                | 105,54%         |
| PNSGA            | 100%                    | 100%                    | 0,00%           |
| MMFI             | 0,06                    | 18,33                   | 30.450%         |

Fonte: Autor.

A figura 5.6 apresenta o gráfico da evolução da FO para uma das execuções que encontrou o valor ótimo para o problema em questão.

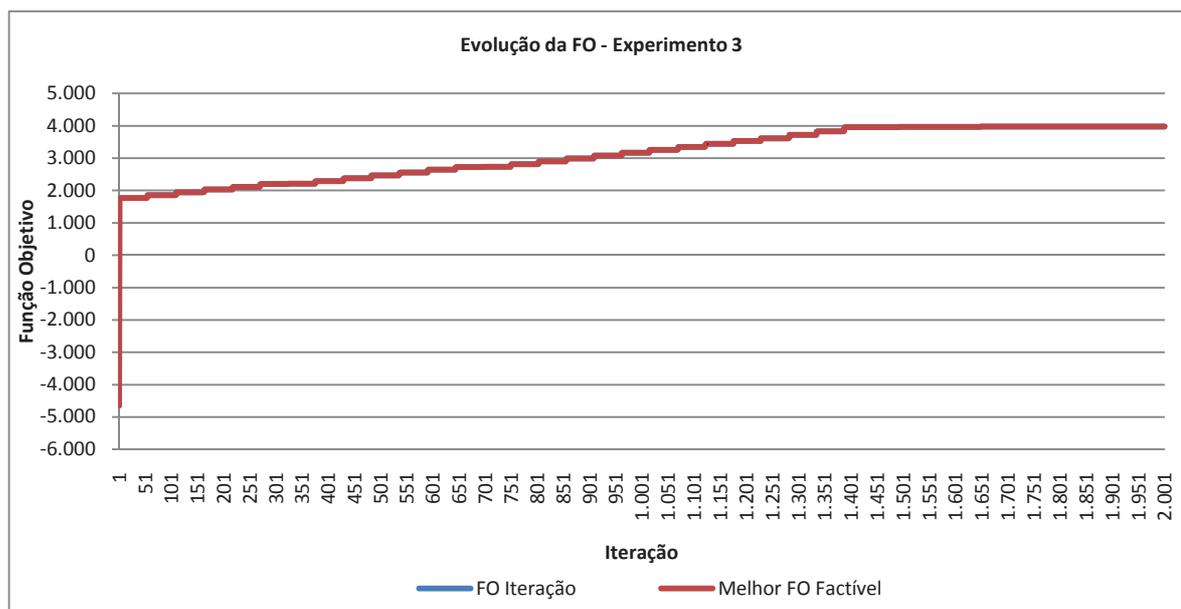


Figura 5.6 – Evolução da FO para cada iteração – Experimento 3.  
Fonte: Autor

No gráfico da figura 5.6 o valor da FO de  $S_0$  foi suprimido para uma melhor visualização.

Na execução da ferramenta onde a solução ótima não foi alcançada, o valor final da FO ficou em 2.978,23. O valor médio da FO ao final das dez execuções foi de 3.979,22, um pouco abaixo da solução ótima.

### 5.3.4 Experimento 4 - Demandas Previstas e Reposição para Atendimento Total

Neste experimento é tratado o caso da instância IP2, utilizando os parâmetros apresentados na tabela 5.4. As demandas geradas pelo módulo predictor, juntamente com as políticas de reposição geradas pelo processo definido na seção 4.5.4.2, são utilizadas pela ferramenta na busca de uma solução de melhor qualidade. Por tratar-se de um problema onde a obtenção da solução exata exige um grande esforço computacional, devido à quantidade elevada de soluções candidatas, a análise dos

resultados estará restrita apenas às melhoras obtidas para os componentes avaliados pela FO. Os valores de lucro e custo por unidade vendida também não serão apresentados, já que esta instância de problema trata de 1.782 produtos.

A tabela 5.12 traz o resumo dos resultados obtidos nas dez execuções da ferramenta. Nesta tabela, além das colunas até então apresentadas nos resultados dos experimentos anteriores, duas novas informações são trazidas. Trata-se da média dos valores de cada componente da  $S^*$  de cada uma das dez execuções, além do desvio padrão, considerando as dez execuções.

Tabela 5.12 – Resultados do Experimento 4.

| <b>Indicador</b> | <b>S<sub>0</sub></b> | <b>S*</b>     | <b>Variação</b> | <b>Média</b>  | <b>Desvio Padrão</b> |
|------------------|----------------------|---------------|-----------------|---------------|----------------------|
| FO               | 5.967,31             | 16.188,14     | 171,28%         | 15.625,27     | 476,39               |
| LGV              | 58.708.736,16        | 53.742.009,16 | -8,46%          | 54.138.779,19 | 326.803,44           |
| CGE              | 78.154.681,12        | 37.519.222,81 | -51,99%         | 39.077.652,12 | 1.326.628,26         |
| RFG              | -19.445.944,96       | 16.222.786,35 | 183,43%         | 15.061.127,07 | 1.015.471,94         |
| PNSGA            | 100%                 | 96,05%        | -3,95%          | 96,39%        | 0,00                 |
| MMFI             | 0,75                 | 1,43          | 90,67%          | 1,39          | 0,04                 |

Fonte: Autor.

Os dados da tabela 5.12 apontam a redução dos indicadores de lucratividade (*LGV*), custo de estocagem (*CGE*) e nível de atendimento às demandas (*PNSGA*). Por outro lado, ocorreu um aumento dos indicadores de resultado financeiro (*RFG*) e retorno sobre investimento (*MMFI*). A redução da lucratividade não compromete a relevância da solução encontrada, uma vez que tal redução ocorreu em uma proporção inferior à redução dos custos de estocagem, possibilitando o aumento do *RFG* e *MMFI*.

Através de uma análise detalhada da melhor solução obtida, a redução da lucratividade ocorreu em função da redução do atendimento às demandas de produtos que trazem pouco retorno à empresa, isto é, produtos cujo custo de manutenção envolvido é muito alto frente aos lucros que se obtém com eles, tornando-os menos interessantes do ponto de vista da relação entre lucro e custo. A restrição *PNSGME*, com o valor de 95%, conforme definido na tabela 5.4, impediu

que o atendimento à estas demandas fosse ainda mais reduzido. Se esta restrição fosse totalmente relaxada, ou seja, zerada, os indicadores de lucratividade e custo de estocagem poderiam sofrer reduções ainda maiores, mas na mesma proporção entre si conforme aqui apresentado, o que poderia ser interessante para a rede varejista do ponto de vista do indicador *MMFI* no que se refere exclusivamente a tais produtos. Contudo, conforme visto na seção 2.2, a indisponibilidade de um item pode levar o consumidor a desistir de todas as suas compras, o que não é bom para a organização. Relaxar a restrição *PNSGME* pode melhorar o retorno sobre investimento observado na solução fornecida pelo otimizador, porém pode ter consequências no sistema real. É importante ter isto em mente quando se aplicar uma atenuação na restrição de nível de serviço global mínimo exigido.

A figura 5.7 apresenta o gráfico de evolução da FO durante a execução do módulo otimizador.

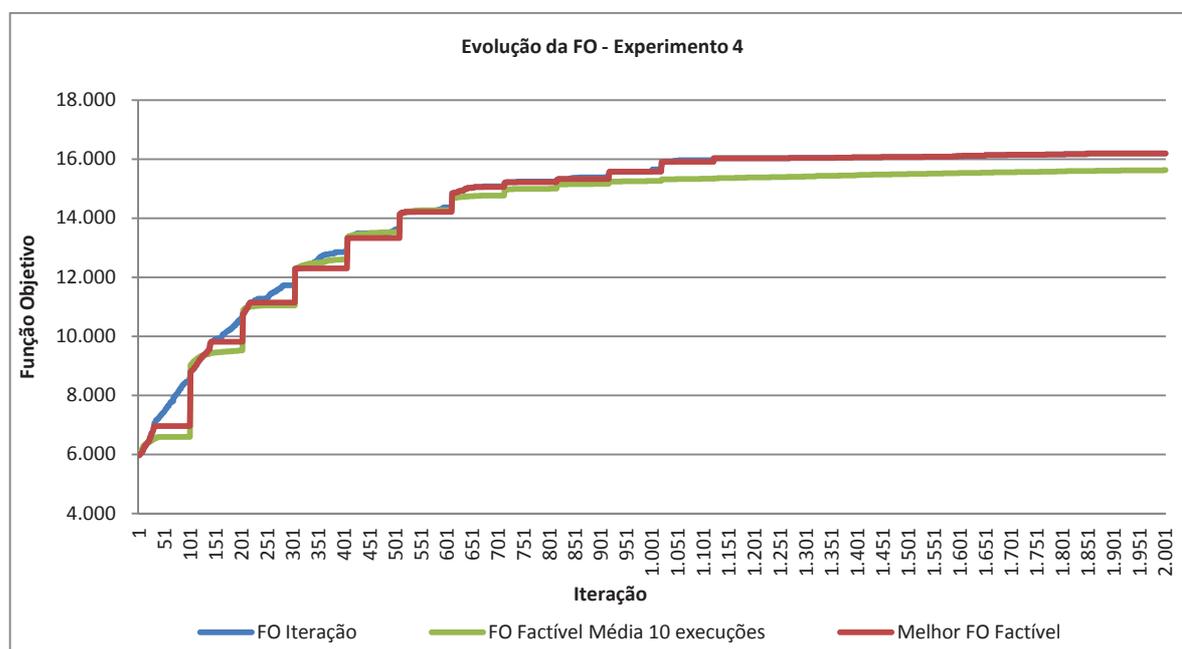


Figura 5.7 – Evolução da FO para cada iteração – Experimento 4.  
Fonte: Autor

No gráfico da figura 5.7 é possível verificar o funcionamento da estratégia de união das soluções relaxada e factível. No início da execução o algoritmo encontrou soluções factíveis melhores que  $S_0$ . Isto pode ser visto pela sobreposição das linhas

*FO Iteração e Melhor FO Factível* do gráfico. Logo em seguida, soluções melhores, porém infactíveis, foram encontradas. Por volta da iteração 101 ocorreu a união das soluções, fazendo com que o valor da FO correspondente à linha *Melhor FO Factível* subisse rapidamente e continuasse evoluindo nas iterações seguintes. Em momentos posteriores, a união voltou a ocorrer, aparentemente, conforme o comportamento apresentado pela linha correspondente no gráfico.

O gráfico da figura 5.7 apresenta uma informação a mais em relação aos gráficos dos experimentos anteriores, é a *FO Factível Média 10 Execuções*. Ela representa o valor médio da FO a cada iteração, considerando as 10 execuções da ferramenta. É possível observar que as linhas que representam *FO Iteração e Melhor FO Factível*, em pontos localizados, ficam abaixo de *FO Factível Média 10 Execuções*. Isso demonstra que a obtenção de uma solução ótima no final da execução do otimizador pode apresentar uma trajetória de busca algumas vezes inferior a outras trajetórias que, embora apresentem melhor qualidade no decorrer do processo de solução, ao final não evidenciam tal qualidade.

### **5.3.5 Experimento 5 - Demandas Previstas Reduzidas**

Neste experimento o parâmetro “Coeficiente Modificador de Demanda” foi aplicado ao caso da instância IP2. Com isso, as quantidades demandadas foram reduzidas pela metade. Apesar da redução na demanda, a solução inicial deste problema não sofreu modificações. Isto ocasiona um excesso de itens em estoque, já que as reposições esperam uma demanda maior. Este experimento é um cenário alternativo àquele apresentado no experimento 4.

A tabela 5.13 traz o resumo dos resultados obtidos nas dez execuções da ferramenta.

Tabela 5.13 – Resultados do Experimento 5.

| Indicador | $S_0$          | $S^*$          | Variaco | Mdia          | Desvio Padro |
|-----------|----------------|----------------|----------|----------------|---------------|
| FO        | -1.867,76      | 5.271,86       | 382,26%  | 5.222,79       | 31,23         |
| LGV       | 29.354.368,08  | 27.813.229,54  | -5,25%   | 27.791.531,90  | 36.253,65     |
| CGE       | 86.117.993,67  | 43.077.441,11  | 49,98%   | 43.248.641,76  | 114.407,87    |
| RFG       | -56.763.625,59 | -15.264.211,57 | 73,11%   | -15.457.109,86 | 122.793,71    |
| PNSGA     | 100%           | 98,54%         | -1,46%   | 98,56%         | 0,00          |
| MMFI      | 0,34           | 0,65           | 91,18%   | 0,64           | 0,00          |

Fonte: Autor.

Os dados da tabela 5.13 apontam uma pequena reduo no indicador de lucratividade, enquanto que o indicador de custo de estocagem foi reduzido quase pela metade. Esta reduo no custo de estocagem era esperada, visto que a soluo inicial para reposio de estoques da rede varejista, neste experimento, tinha o dobro do necessrio para atender s demandas, ou seja, muitas unidades em estoque. Assim, reduo nos nveis de estoque foram, em geral, bem aproveitadas, j que dificilmente violavam as restrioes do problema relativas ao atendimento s demandas dos consumidores, e tambm porque diminuam os custos de manuteno de estoque.

O indicador *MMFI* obtido na soluo final deste experimento  inferior a 1, o que significa que, para cada unidade monetria empregada nos custos de estocagem, apenas 0,65 UM so obtidas em retorno. O indicador *RFG* apresenta um valor negativo, ou seja, a soma de todos os custos em estocagem  superior ao lucro obtido. A soluo encontrada  vivel do ponto de vista do modelo construdo. Contudo, apesar da melhora obtida com a execuo da ferramenta, esta soluo  invivel do ponto de vista financeiro. Pode-se concluir que, na ocorrncia de uma reduo desta magnitude nas demandas, a operao da rede varejista poderia ser comprometida. Cabe aqui a anlise e avaliao do usurio da ferramenta.

Outro ponto a ser analisado  o valor do indicador *CGE* obtido com  $S_0$ . O valor dele  superior quele obtido no experimento 4, a diferena  de aproximadamente 8.000.000,00 UM. Vale lembrar que a soluo inicial para ambos os experimentos  a mesma. A explicao para esta diferena  a demanda. Como a demanda neste experimento  menor, sobraro mais unidades de produtos em

estoque ao final de cada dia, acarretando em um custo maior de estocagem. No experimento 4, havia uma quantidade menor de itens em estoque ao final de cada dia pois a demanda era maior, gerando menores custos.

A figura 5.8 apresenta o gráfico de evolução da FO durante a execução do módulo otimizador.

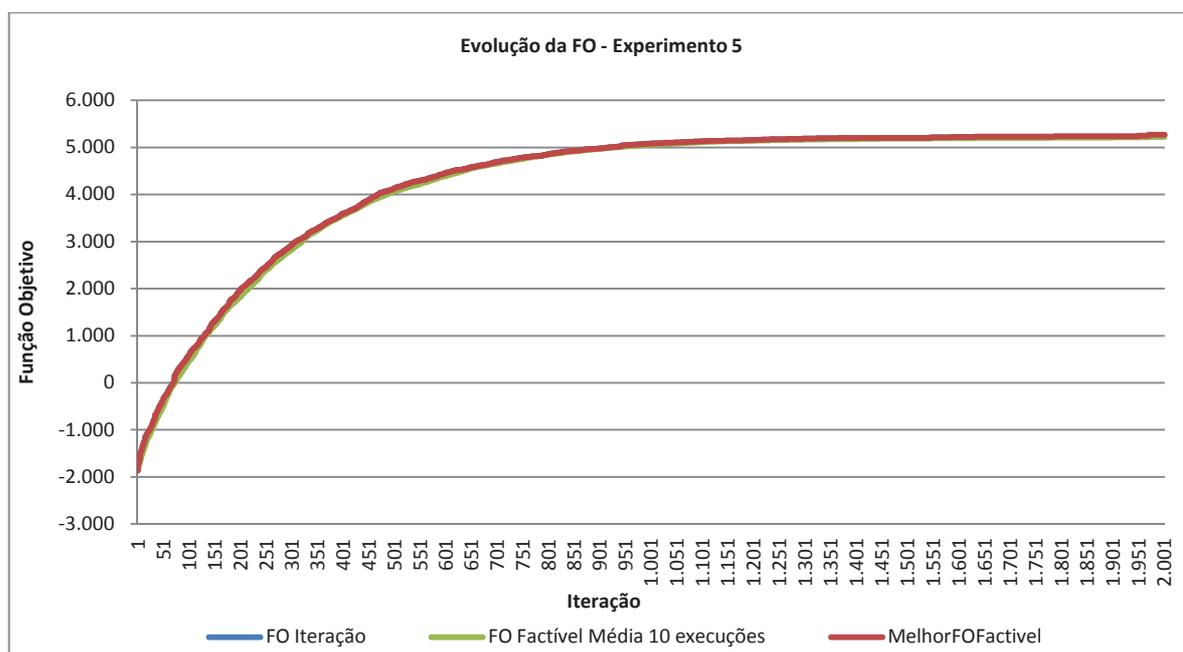


Figura 5.8 – Evolução da FO para cada iteração – Experimento 5.  
Fonte: Autor

No gráfico da figura 5.8 é possível verificar que a melhor solução é muito próxima à melhor solução viável encontrada, visto que as linhas do gráfico, aparentemente, estão sempre sobrepostas. A ferramenta evoluiu satisfatoriamente com base na política inicial de reposição e chegou a um valor consideravelmente superior. O comportamento muito próximo de *FO Iteração* e *Melhor FO Factível* pode ser explicado pelo fato de que a solução inicial neste experimento continha um excesso de unidades de cada produto. Comumente, o que motiva o distanciamento entre *FO Iteração* e *Melhor FO Factível* é justamente a violação de restrições. Com estoque em excesso, dificilmente há violação de restrições, permitindo que, a cada iteração, uma nova solução factível e melhor que a da iteração anterior fosse encontrada. O desvio padrão da FO da tabela 5.13 comprova que as soluções

encontradas nas diferentes execuções da ferramenta, neste experimento, estão bastante próximas e que a ferramenta não enfrenta dificuldades para encontrar soluções melhores que a inicial.

### 5.3.6 Experimento 6 - Demandas Previstas com Redução do Lucro Unitário

Este experimento parte das demandas relativas à instância IP2 e utiliza o parâmetro “Coeficiente Modificador de Lucro” para reduzir a lucratividade de cada produto. O valor do coeficiente aplicado é de 0,7, ou seja, redução de 30% nos lucros obtidos. Este experimento é um cenário alternativo, gerado a partir daquele existente no experimento 4.

A tabela 5.14 traz o resumo dos resultados obtidos nas dez execuções da ferramenta.

Tabela 5.14 – Resultados do Experimento 6.

| Indicador | S <sub>0</sub> | S*            | Variação | Média         | Desvio Padrão |
|-----------|----------------|---------------|----------|---------------|---------------|
| FO        | 1952,44        | 10.101,34     | 417,37%  | 9.762,20      | 203,33        |
| LGV       | 41.096.115,31  | 37.708.242,24 | -8,24%   | 37.932.227,16 | 113.158,32    |
| CGE       | 75.368.320,11  | 38.109.252,54 | -49,44%  | 39.337.132,07 | 682.407,31    |
| RFG       | -34.272.204,8  | -401.010,30   | 98,83%   | -1.404.904,91 | 596.502,61    |
| PNSGA     | 100%           | 96,17%        | -3,83%   | 96,44%        | 0,00          |
| MMFI      | 0,53           | 0,99          | 86,79%   | 0,96          | 0,01          |

Fonte: Autor.

A melhora na FO foi de mais de 400%. O CGE neste experimento foi reduzido quase à metade do valor inicial, o LGV sofreu uma pequena redução e o MMFI teve um aumento significativo, na ordem de mais de 86%. Com exceção do LGV e do PNSGA, todos os demais indicadores foram melhorados. Uma análise crítica do LGV deve ser feita. Novamente, sua redução se deve a uma diminuição no atendimento às demandas de produtos que trazem pouco retorno à empresa. Considerando este

aspecto, uma redução no *LGV* ocasiona uma melhora no *MMFI*, o que pode ser positivo para a empresa. O resultado financeiro global, *RFG*, também teve um aumento importante.

Apesar de todas as melhoras obtidas, o *RFG* ainda é negativo, ou seja, os custos são maiores que os lucros. O *MMFI*, que mede o retorno monetário sobre investimento, quando apresenta valor 1, indica que a lucratividade e os custos envolvidos geram uma situação onde a operação da empresa apenas se sustenta, ou seja, todos os custos são pagos com a lucratividade apurada, porém, sem superávit. Neste experimento, o *MMFI* teve valor de 0,99, valor este muito próximo a 1. O resultado deste experimento, em função do valor obtido para o *MMFI*, poderia representar um balanço financeiro estável, onde a operação da rede varejista cobre apenas os custos envolvidos, conforme recém explicado.

A figura 5.9 apresenta o gráfico de evolução da FO para este experimento.

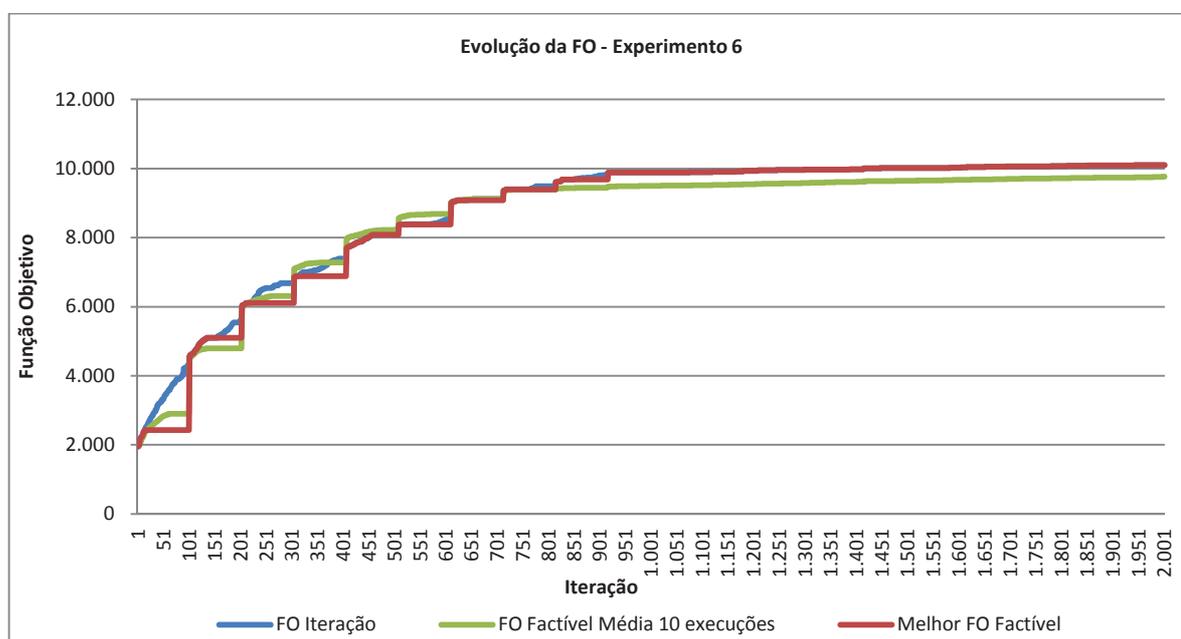


Figura 5.9 – Evolução da FO para cada iteração – Experimento 6.  
Fonte: Autor

O gráfico da figura 5.9 assemelha-se ao apresentado na figura 5.7, relativo ao experimento 4. Há momentos onde *FO Iteração* se separa de *Melhor FO Factível*. Isto não ocorreu no experimento 5, figura 5.8. Os três experimentos têm a mesma

solução inicial e as mesmas restrições, porém, no experimento 5, tais restrições foram, de certa forma, relaxadas, visto que ali a demanda foi diminuída em 50%, fazendo com que soluções infactíveis dificilmente fossem encontradas, o que não ocorre nos experimentos 4 e 6.

### 5.3.7 Experimento 7 - Demandas Previstas com Relaxamento das Restrições

Este experimento utiliza a instância IP2 e assemelha-se ao caso apresentado no experimento 4, com as mesmas demandas e solução inicial. A diferença aqui é a relaxação das restrições do problema. As restrições  $PNSGME$  e  $PNSE_k$ , inicialmente com níveis de exigência de 95% e 90%, respectivamente, foram ambas reduzidas para 10%. Além disso, as restrições de intervalo entre reposições  $LT_k$  foram reduzidas à metade. O objetivo é verificar possíveis ganhos com a suavização de exigências do sistema.

A tabela 5.15 traz o resumo dos resultados obtidos nas dez execuções da ferramenta.

Tabela 5.15 – Resultados do Experimento 7.

| Indicador | $S_0$          | $S^*$         | Variação | Média         | Desvio Padrão |
|-----------|----------------|---------------|----------|---------------|---------------|
| FO        | 9.167,31       | 19.983,56     | 117,99%  | 19.931,04     | 38,15         |
| LGV       | 58.708.736,16  | 53.660.775,60 | -8,60%   | 53.510.395,46 | 91.527,31     |
| CGE       | 78.154.681,12  | 36.226.590,20 | -53,65%  | 36.217.790,03 | 54.625,55     |
| RFG       | -19.445.944,96 | 17.434.185,40 | 189,65%  | 17.292.605,43 | 93.778,28     |
| PNSGA     | 100%           | 95,69%        | -4,31%   | 0,96          | 0,00          |
| MMFI      | 0,75           | 1,48          | 97,33%   | 1,48          | 0,00          |

Fonte: Autor.

O comportamento de aumento ou redução dos indicadores se assemelha aos já obtidos nos demais experimentos, ou seja, aumento na *FO*, *RFG* e *MMFI*, e redução em *LGV*, *CGE* e *PNSGA*. Comparando os resultados da tabela 5.15 com aqueles obtidos no experimento 4, tabela 5.12, é possível observar uma melhora de 1.211.399,05 UM no *RFG* de  $S^*$ , enquanto que o *PNSGA* foi diminuído em apenas 0,36%. O desvio padrão do *RFG* neste experimento é de 93.778,28, o que indica que, em geral, os resultados obtidos para o *RFG* variam pouco. Assim, é possível concluir que relaxar as restrições de intervalo mínimo entre reposições resulta, consistentemente, em um melhor resultado financeiro global. Isso pode servir de base para negociação com fornecedores, buscando a redução do intervalo entre reposições dos produtos.

A figura 5.10 apresenta o gráfico de evolução da *FO* para este experimento.

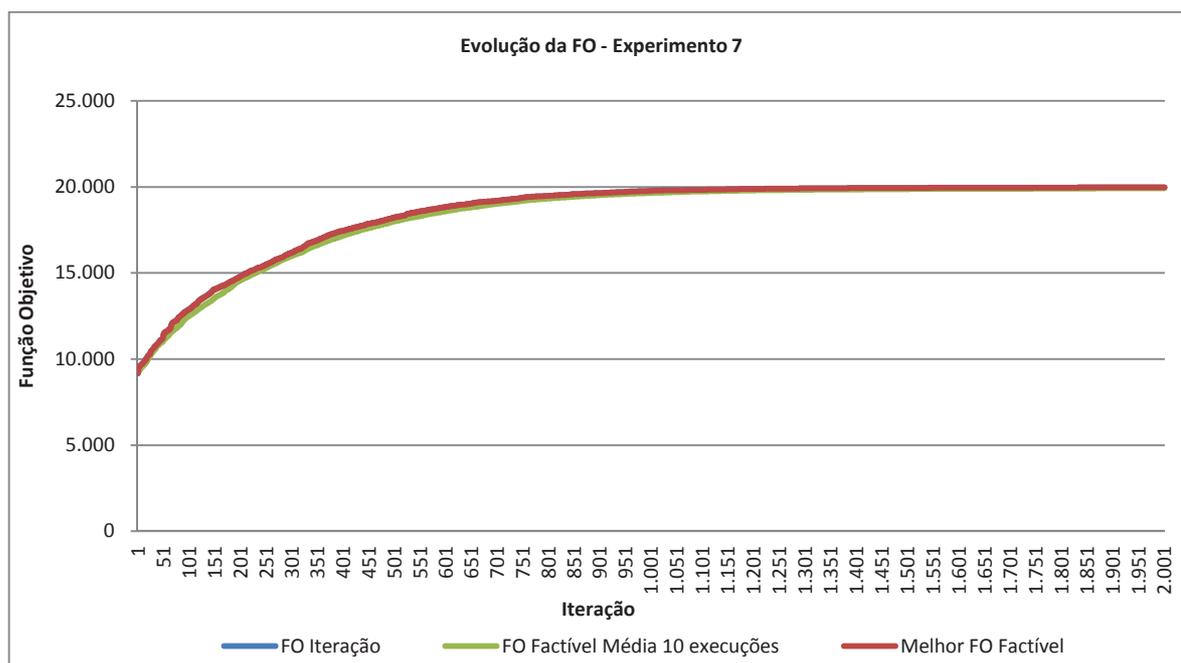


Figura 5.10 – Evolução da FO para cada iteração – Experimento 7.  
Fonte: Autor

O gráfico da figura 5.10 assemelha-se ao apresentado na figura 5.8, relativo ao experimento 5, no que diz respeito à proximidade de *FO Iteração*, *FO Factível Média 10 Execuções* e *Melhor FO Factível*. Isso ocorre também neste experimento pois dificilmente soluções infactíveis são encontradas, mantendo *FO Iteração* e

*Melhor FO Factível* sempre muito próximas. A melhor solução encontrada nas 10 execuções deste experimento ficou um pouco acima da média das dez execuções. O desvio padrão da FO, apresentado na tabela 5.15 comprova que as soluções  $S^*$  encontradas em cada uma das execuções, ao final das 2.000 iterações, varia muito pouco. Isso explica a proximidade de *FO Factível Média 10 execuções* às demais linhas do gráfico.

### 5.3.8 Experimento 8 - Problema Completo da Rede Varejista

Este experimento trata do caso da instância IP3, com a avaliação de 203.098 demandas. Estão contemplados todos os 2.236 produtos comercializados pela rede varejista em seus 317 pontos de venda.

Este experimento difere dos até então apresentados pelo fato de o processo de otimização ter sido executado por 8.000 iterações ao invés de apenas 2.000. A razão para o aumento no número de iterações baseia-se no tamanho do problema, uma vez que durante a fase de experimentação, ao executar a ferramenta para o caso da instância IP3, verificou-se que na iteração 2000 a FO ainda não apresentava um comportamento assintótico de evolução.

Os dados avaliados são aqueles gerados pelo módulo previsor. Estas demandas, bem como as políticas iniciais de reposição foram submetidas à ferramenta. Os resultados obtidos são apresentados na tabela 5.16.

Tabela 5.16 – Resultados do Experimento 8.

| <b>Indi-<br/>cador</b> | <b>S<sub>0</sub></b> | <b>S*</b>      | <b>Variação</b> | <b>Média</b>   | <b>Desvio<br/>Padrão</b> |
|------------------------|----------------------|----------------|-----------------|----------------|--------------------------|
| FO                     | 10.520,19            | 17.130,71      | 62,84%          | 16.764,45      | 221,74                   |
| LGV                    | 472.920.596,04       | 459.735.724,20 | -2,79%          | 460.575.123,33 | 472.458,74               |
| CGE                    | 508.516.836,60       | 392.161.485,80 | -22,88%         | 398.202.818,80 | 3.479.168,16             |
| RFG                    | -35.596.240,56       | 67.574.238,40  | 289,84%         | 62.372.304,53  | 3.029.769,67             |
| PNSGA                  | 100%                 | 98,16%         | -1,84%          | 98,27%         | 0,00                     |
| MMFI                   | 0,93                 | 1,17           | 25,81%          | 1,16           | 0,01                     |

Fonte: Autor.

Comparando os valores de  $S_0$  e  $S^*$ , é possível verificar que, mesmo para um problema de grande porte, como o avaliado neste experimento, a ferramenta é capaz de partir de uma solução que apresenta déficit no indicador *RFG*, para uma solução melhor, onde a lucratividade supera os custos. A variação dos indicadores seguiu o mesmo comportamento observado nos experimentos anteriores, aumento na *FO*, *RFG* e *MMFI* e redução no *LGV*, *CGE* e *PNSGA*. Contudo, a redução dos indicadores *LGV* e *PNSGA* neste experimento foi consideravelmente menor do que nos experimentos anteriores.

A figura 5.11 apresenta o gráfico de evolução da *FO* para este experimento.

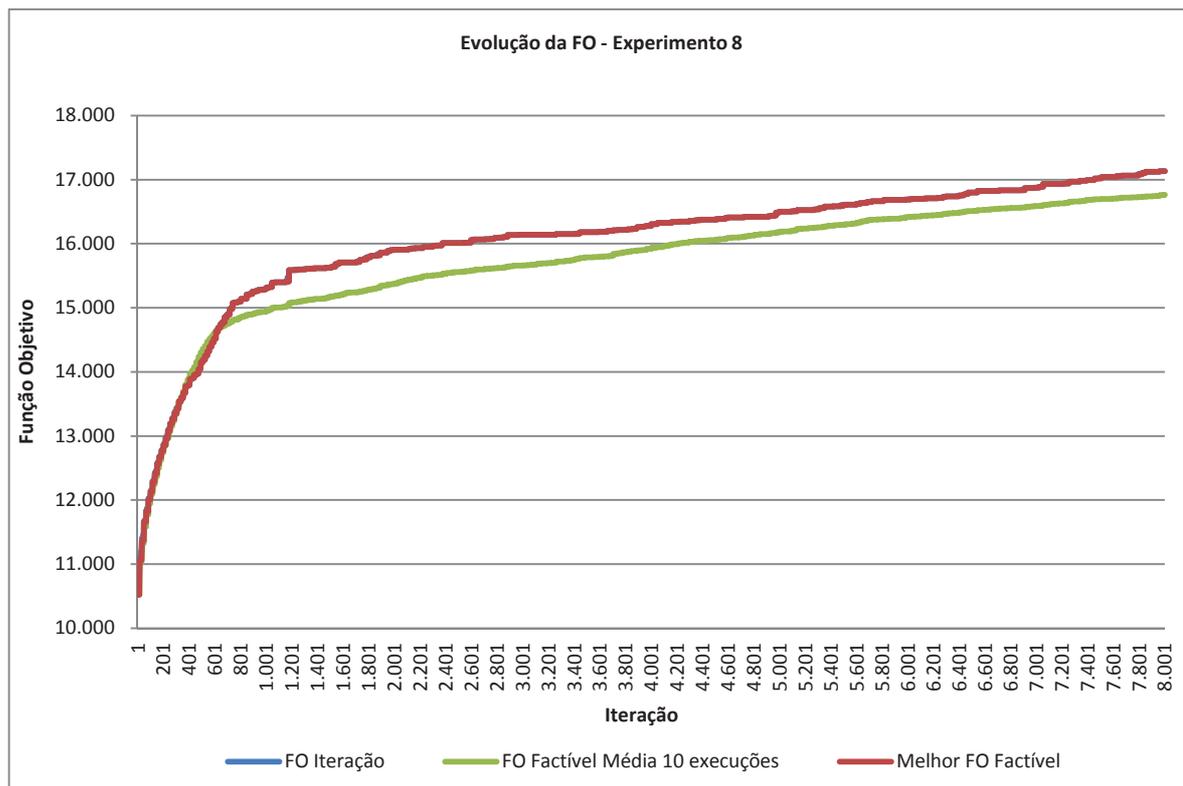


Figura 5.11 – Evolução da FO para cada iteração – Experimento 8.  
Fonte: Autor

Analisando o gráfico da figura 5.11 é possível observar que, nas iterações iniciais, a ferramenta proporcionou uma taxa de crescimento da FO bastante acentuada. Isso ocorreu até meados da iteração 1.000. Deste ponto em diante, o gráfico apresenta, aparentemente, uma taxa de crescimento menor e constante. A partir de meados da iteração 650, o valor de *Melhor FO Factível* permaneceu significativamente acima de *FO Factível Média 10 Execuções*. Isso leva a crer que, possivelmente, na execução da ferramenta onde foi obtido o melhor resultado, foi encontrada uma solução intermediária que teve influência impactante para obtenção da melhor solução ao final da execução.

Novamente, observando o gráfico da figura 5.11, pode-se concluir que a execução da ferramenta com apenas 2.000 iterações deixaria de obter resultados superiores, reafirmando a importância de sua execução por um número maior de iterações. Observa-se também que, aparentemente, pela inclinação das curvas do gráfico da figura 5.11, soluções melhores ainda podem ser encontradas.

## 5.4 Resumo sobre os Experimentos

Os experimentos 1, 2 e 3, que trataram da instância IP1, foram utilizados para validar o módulo otimizador. Durante a condução dos mesmos, a solução exata para pequenos problemas foi encontrada em 28 de 30 execuções. Por se tratarem de problemas simples, a solução exata deles é conhecida. Estes experimentos foram conduzidos com dados gerados artificialmente e de forma controlada. O tempo necessário para cada execução da ferramenta nestes experimentos é inferior a um segundo.

Os experimentos 4, 5, 6 e 7 trataram da instância IP2, consideravelmente maior que a instância IP1, e usaram dados gerados pelo módulo previsor. O experimento 4 tratou de um cenário padrão. Os experimentos 5, 6 e 7 criaram cenários alternativos ao tratado no experimento 4. Isto foi feito através do uso dos parâmetros gerais da ferramenta. Para cada execução da ferramenta, com estes dados, foram necessários entre 5 e 6 minutos.

O experimento 8 tratou do problema completo da rede varejista, também com base em dados de demanda gerados pelo módulo previsor. Neste experimento, o parâmetro “Tamanho do *Pool* de Atributos” necessitou ser reduzido para 8. Valores superiores a 8 ocasionaram, em diversas execuções, o uso de toda a memória disponível na máquina onde a ferramenta foi executada. O tempo necessário para cada execução da ferramenta para a instância IP3 foi de, aproximadamente, dezessete horas.

## 5.5 Plataforma de Desenvolvimento e de Condução de Experimentos

A ferramenta computacional desenvolvida no decorrer deste trabalho foi construída e testada sob a seguinte plataforma:

### *Hardware:*

- a. Computador equipado com processador Intel i7 de 2.8GHz de oito núcleos;
- b. 10GB de memória RAM;
- c. 640GB de espaço em disco;

### *Software:*

- d. Windows 7 Professional 64 bits;
- e. Banco de dados Microsoft SQL Server 2008;
- f. Ambiente de desenvolvimento Microsoft Visual Studio 10, linguagem C#;

## 6 Conclusões

Este trabalho propôs uma ferramenta para otimização de níveis de estoque de uma rede varejista. Trata-se de um problema onde é necessário definir quando ocorrerão as reposições de estoque de cada produto, em cada loja da rede, bem como a quantidade a ser reposta. Diversos aspectos do problema são considerados, como custos de armazenamento e reposição, lucratividade, níveis de atendimento às demandas e intervalos mínimos entre reposições consecutivas.

Este trabalho foi dividido em quatro partes. Cada uma delas compreende um módulo da ferramenta desenvolvida, com funções especializadas e utilizando técnicas distintas apropriadas. O objetivo geral do trabalho foi alcançado, uma vez que obteve-se sucesso no desenvolvimento de cada um dos módulos propostos, bem como na integração dos mesmos.

Alguns experimentos foram conduzidos utilizando a ferramenta desenvolvida. Os experimentos foram divididos em três grupos. O primeiro grupo abordou alguns casos simples, com apenas uma ou duas demandas, onde a solução exata para o problema é conhecida e pôde ser confrontada com a solução obtida pela ferramenta. O objetivo destes experimentos foi o de validar a ferramenta.

Um segundo grupo de experimentos, de maior tamanho e complexidade, foi conduzido. Nestes casos, foram avaliadas mais de 13.000 demandas em cada experimento. O objetivo com este segundo grupo foi demonstrar a robustez da ferramenta, através da criação e emprego de diferentes cenários de demandas, bem como demonstrar sua capacidade de lidar com problemas de maior porte.

Ainda dentro da experimentação, o problema completo da rede varejista foi submetido à execução da ferramenta desenvolvida. Este problema possui mais de 200.000 demandas e caracteriza o terceiro grupo de experimentos. O objetivo deste experimento foi demonstrar que a ferramenta é capaz de lidar com problemas de grande porte, característico de situações da vida real, tendo sido encontradas soluções de qualidade superior às inicialmente propostas.

Os resultados obtidos durante a condução dos experimentos demonstraram que a ferramenta desenvolvida é capaz de gerar previsões de demanda condizentes com o comportamento observado de cada produto, sugerir boas soluções para a reposição de estoques dos produtos comercializados em cada um dos pontos de venda da rede varejista, além de permitir a criação e simulação de cenários alternativos à realidade observada. Os ganhos obtidos nos indicadores de desempenho do sistema de estocagem, com a utilização da ferramenta, são significativos e podem variar de acordo com o problema tratado. Os cenários criados durante a fase de experimentação demonstraram que a ferramenta pode ser utilizada no apoio à tomada de decisão, visto que permite a inserção de mudanças no sistema de estocagem sem necessidade de alteração do sistema real.

A ferramenta mostrou-se capaz de avaliar diversos aspectos do problema como custos, lucratividade, atendimento às demandas e retorno monetário sobre investimento. Ela conta ainda com uma série de parâmetros que permitem simular diferentes cenários, dando a seus usuários a possibilidade de apurar o comportamento do sistema de estocagem em diferentes situações. O desempenho da ferramenta é satisfatório mesmo para problemas de grande porte.

Dentre as contribuições do trabalho, destaca-se o uso da metaheurística *Guided Local Search*, em especial no que se refere ao problema tratado, visto que, durante a busca por trabalhos relacionados ao problema de otimização de estoques, é possível encontrar trabalhos que utilizam metaheurísticas, mas não a metaheurística GLS. Outra importante contribuição é o uso de dados reais de demanda, observados em períodos anteriores, o que é de grande valia para gerar previsões confiáveis. Além disso, o método proposto usa uma técnica de otimização combinada com um módulo de simulação. Esta combinação, conhecida como Otimização da Simulação, tem sido bastante utilizada em problemas de diversas áreas. Este trabalho reafirma a importância e efetividade da aplicação combinada destas duas técnicas.

A continuidade da pesquisa sobre o tema, bem como do desenvolvimento do método ora proposto, sugere, para trabalhos futuros, a possibilidade de estudo e entendimento de possíveis atrasos nas entregas de pedidos por parte dos fornecedores, o que sem dúvida afeta o sistema de estocagem e o atendimento às

demandas. Uma alternativa para superar tal dificuldade pode ser o uso de um fator estocástico envolvido no processo de estocagem, no que se refere à disponibilidade de produtos para venda, podendo esta característica ser inserida na ferramenta através de novos parâmetros. Outra possibilidade é o desenvolvimento de um método que utilize processamento distribuído, visto que, para problemas de grande porte, o tempo necessário para obtenção de resultados satisfatórios é de algumas horas. O ganho de tempo possível com a distribuição do processamento permite que o método em si seja melhorado com , por exemplo, novas estratégias de vizinhança ou até mesmo o aumento dos valores de alguns parâmetros do otimizador, como o tamanho da vizinhança. Isso permitiria uma busca ainda mais ampla sobre o espaço de soluções.

A ferramenta desenvolvida trata dos estoques de diferentes pontos de venda da rede varejista, mas não trata de centros de distribuição, que são depósitos maiores, com maior capacidade de armazenamento. Uma sugestão de melhoria para a ferramenta seria considerar este aspecto do problema, assumido como uma simplificação do sistema real, neste trabalho. Ainda, o resultado obtido com o problema completo da rede varejista sugere que soluções ainda melhores podem ser encontradas, afirmando a possibilidade de continuidade e melhoria do trabalho ora apresentado.

Há ainda uma vasta gama de possíveis diferentes experimentos que podem ser conduzidos através da utilização dos parâmetros que a ferramenta possui. Isto permitiria a criação e análise de novos cenários e, possivelmente, a descoberta de peculiaridades de interesse envolvidas no sistema de estocagem de uma rede varejista.

## BIBLIOGRAFIA

BACCI, L. A.; **Combinação de métodos de Séries Temporais para Previsão da Demanda de café no Brasi**. Dissertação de Mestrado. Universidade Federal de Itajubá. Itajubá, MG, 2007.

BALLOU, R.; ***Business Logistics Management: planning, organizing, and controlling the supply chain***. 4 ed. Prentice Hall. Londres, 1998.

BANKS, J. E.; ***Handbook of simulation: principles, methodology, advances, applications, and practice***. John Wiley & Sons, New York, 1998.

BOCTOR, F. F.; ***Offsetting inventory replenishment cycles to minimize storage space***. *European Journal of Operational Research* 203, 321-325, 2010.

BUFFA, E. S.; SARIN, R. K.; CHVÁTAL; ***Modern Production - Operations Management***. Willey, New York, 1987.

CHING, H. Y.; ***Gestão de estoques na cadeia de logística integrada – Supply Chain***. Atlas. São Paulo, 1999.

CHOPRA, S.; MEINDL, P.; ***Supply Chain Management. Strategy, Planning, and Operation***, Prentice Hall, 2008.

COELHO, L. C.; **Utilização de modelos de suavização exponencial para previsão de demanda com gráficos de controle combinados Shewhart-CUSUM**. Dissertação de Mestrado em Engenharia de Produção, Departamento de Engenharia de Produção e Sistemas, Universidade Federal de Santa Catarina, Florianópolis, Brasil, 2008.

COELHO, L. C.; FOLLMANN, N.; RODRIGUEZ, C. M. T.; **O Efeito Chicote e o seu Impacto na Gestão das Cadeias de Suprimentos**. VII Simpósio de Excelência em Gestão da Tecnologia. Resende, RJ. 2007.

CORRÊA, H. L.; GIANESI, I. G. N.; CAON, M.; **Planejamento, Programação e Controle da Produção com MRPII / ERP: Conceitos, Uso e Implantação**. 4. ed. São Paulo: Atlas, 452 p., 2001.

DANIEL, J. S. R.; RAJENDRAN, C.; **A simulation-based genetic algorithm for inventory optimization in a serial supply chain**. *International Transactions in Operations Research* 12, 101–127. Madras, India, 2005.

FAVARETTO, D.; PESENTI, R.; UKOVICH, W.; **Discrete frequency models inventory management – an introduction**. *International Journal of Production Economics* 71, 331-342, 2001.

FERREIRA, A. B. M.. **Novo Aurélio: O Dicionário da Língua Portuguesa**. Rio de Janeiro: Nova Fronteira, 1999.

GIGLIO, D.; MINCIARDI, R.; SCANE, S.; SIRI, S; **Optimization of inventory levels and production effort in Hybrid Inventory-Production (HIP) systems**. 4<sup>th</sup> IEEE Conference on Automation Science and Engineering. Washington DC, 2008.

GLOVER, F.; KOCHENBERGER, G. A.; **Handbook of Metaheuristics**. Kluwer Academic Publishers, Boston, 2003.

HANKE, J. E.; REITSCH, A. G.; **Business Forecasting**. Allyn and Bacon Inc., Boston, Massachusetts, 1981.

HILLIER, F.S., LIEBERMAN, G. J.; **Introduction to Operations Research**. 7<sup>th</sup> ed. McGraw-Hill Inc. New York, 2001.

JOINES, J.A.; GUPTA, D., GOKCE, M.A., KING, R.E., KAY, M.G.; **Supply chain multi-objective simulation optimization**. *Winter Simulation Conference (WSC'02)*, v. 2, p. 1306-1314, 2002.

KOTLER, P.; **Administração de Marketing. Análise, Planejamento, Implementação e Controle**. 5 ed. São Paulo: Atlas, 1998.

LAW, A. M.; KELTON, W. D.; **Simulation Modeling and Analysis**. 3<sup>rd</sup> ed. McGraw-Hill Inc. Boston, 2000.

LAW, A. M.; MCCOMAS, M. G.; **Simulation-based Optimization**. *Proceedings of the 2002 Winter Simulation Conference*. p 41-44. San Diego, CA, 2002.

LENARD, J. D.; ROY, B.; **Multi-Item Inventory Control: A Multicriteria View**. *European Journal of Operational Research*, v. 87, p. 685-692, 1995.

LOESCH, C.; SARI, S.T.; **Redes neurais artificiais: fundamentos e modelos**. Fundação Universidade Regional de Blumenau. Blumenau, 1996.

MAKRIDAKIS, S.; WHEELWRIGHT, S. C.; HYNDMAN, R. J.; **Forecasting – Methods and Applications**. 3<sup>rd</sup> ed. John Wiley & Sons, Inc. Danvers, MA, 1998.

MELE, F. D.; ESPUÑA, A.; PUIGJANER, L.; **Supply Chain Management through Dynamic Model Parameters Optimization**. *Industrial and Engineering Chemistry Research Journal*. v. 45, p. 1708-1721, 2006.

MOREIRA, D. A. **Administração da produção e operações**. 4 ed., São Paulo: Ed. Pioneira, 1999.

ODAN, F. K.; **Previsão de Demanda para Sistemas de Abastecimento de Água**. Dissertação de Mestrado. Escola de Engenharia de São Carlos, Universidade de São Paulo. São Carlos, SP, Brasil, 2010.

ÓLAFSSON, S.; KIM, J.; **Simulation Optimization**. *Proceedings of the 2002 Winter Simulation Conference*. p 79-84. San Diego, CA, 2002.

OSTROM, C. W.; **Time Series Analysis**. *Sage University Papers Series on Quantitative Applications in the Social Sciences*, 07-009. Thousand Oaks, CA: Sage, 1978.

PAPADIMITRIOU, C. H.; STEIGLITZ, K.; **Combinatorial Optimization**. *Dover Publications Inc*. Mineola, NY, 1998.

PEDGEN, C.D.; SHANNON, R. E.; SADOWSKI, R. P.; **Introduction to Simulation Using SIMAN**. McGraw-Hill, New York. 1995.

PEIXOTO, E. C.; PINTO, L. R.; **Gerenciamento de estoques via previsão de vendas agregadas utilizando simulação**. *Produção*, v. 16, n. 3, p. 569-581. São Paulo, SP, Set./Dez., 2006.

PORTUGAL, M. S.; FERNANDES, L.G.L.; **Redes Neurais Artificiais e Previsão de Séries Econômicas: Uma Introdução**. *Nova Economia*, v.6. Belo Horizonte, 1996

RADHAKRISHNAN, P.; PRASAD, V. M.; GOPALAN, M. R.; **Inventory Optimization in Supply Chain Management using Genetic Algorithm**. *International Journal of Computer Science and Network Security*, v. 9 n. 1, 2009.

RODRIGUEZ, M. A.; VECCHIETTI, A.; **Inventory and delivery optimization under seasonal demand in the supply chain**. *Computers and Chemical Engineering*, 2010.

SACHA, T. B.; **Especificação de uma ferramenta para previsão de demanda para equipamentos de infra-estrutura de tele-comunicações**. Dissertação de Mestrado, Pontifícia Universidade Católica do Paraná. Curitiba, Paraná, Brasil, 2008.

SLACK, N.; CHAMBERS, S.; JOHNSTON, R.; **Administração da Produção**. 2ª ed. Atlas, 2002.

SOUZA, M. O., FILHO, V. J. M. F.; **Análise da cadeia de suprimento de um combustível especial através da simulação computacional**. XLI Simpósio Brasileiro de Pesquisa Operacional – SBPO, 2009.

TAHA, H. A. **Operations Research: An introduction**. 6th ed. Upper Saddle River: Prentice-Hall, 1997.

VOUDOURIS, C; **Guided local search for combinatorial optimization problems**, *PhD Thesis, Department of Computer Science*, University of Essex, Colchester, UK, July, 1997.

VOUDOURIS, C; TSANG, E. P. K.; **Guided local search – Chapter 7**. 1999. Disponível em <<http://sci2s.ugr.es/docencia/algoritmica/GuidedLS.pdf>>. Acesso em: 30/01/2011.

WARBURTON, R. D. H.; **An analytical investigation of the bullwhip effect.** *Production and Operations Management*, v. 13, n. 2, p. 150-160, 2004.

WEI, J; SHIO, K; **Forecasting monthly sales volume of the farmers' market by developing a seasonal adjustable simulator.** *Japanese Society of Agricultural Informatics. Agricultural Information Research*. Japão, 2009.

WERNER, L.; RIBEIRO, J. L. D.; **Previsão de Demanda: uma aplicação dos modelos Box-Jenkins na área de assistência técnica de computadores pessoais.** *Gestão & Produção*, v. 10, n. 1, p. 47-67. São Carlos, SP, 2003.