

UNIVERSIDADE FEDERAL DE CAMPINA GRANDE  
CENTRO DE TECNOLOGIA E RECURSOS NATURAIS  
PÓS-GRADUAÇÃO EM ENGENHARIA CIVIL E AMBIENTAL  
ÁREA DE ENGENHARIA DE RECURSOS HÍDRICOS

**OPERAÇÃO DE REDES DE ESCOAMENTO DE PETRÓLEO  
UTILIZANDO ALGORITMO GENÉTICO MULTI-OBJETIVO**

DISSERTAÇÃO DE MESTRADO

ÉRICA CRISTINE MEDEIROS NOBRE MACHADO

Campina Grande – PB

Maio / 2006

ÉRICA CRISTINE MEDEIROS NOBRE MACHADO

**OPERAÇÃO DE REDES DE ESCOAMENTO DE PETRÓLEO  
UTILIZANDO ALGORITMO GENÉTICO MULTI-OBJETIVO**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Civil e Ambiental, da Universidade Federal de Campina Grande, em cumprimento às exigências para a obtenção do Título de Mestre.

ÁREA DE CONCENTRAÇÃO: ENGENHARIA HIDRÁULICA

ORIENTADORES: CARLOS DE OLIVEIRA GALVÃO

FRANCISCO VILAR BRASILEIRO

Campina Grande – PB

Maio / 2006

FICHA CATALOGRÁFICA ELABORADA PELA BIBLIOTECA CENTRAL DA UFCG

M149o Machado, Érica Cristine Medeiros Nobre  
2006      Operação de redes de escoamento de petróleo utilizando algoritmo genético multi-objetivo / Érica Cristine Medeiros Nobre Machado. — Campina Grande, 2006.  
145fs.: il.

Referências.

Dissertação (Mestrado em Engenharia Civil e Ambiental) – Universidade Federal de Campina Grande, Centro de Ciências e Recursos Naturais.

Orientadores: Carlos de Oliveira Galvão e Francisco Vilar Brasileiro.

1— Redes de Escoamento de Petróleo - Otimização 2— Redes Hidráulicas - Otimização 3— Controle – Algoritmo Genético I— Título

CDU 556.16:622.323

ÉRICA CRISTINE MEDEIROS NOBRE MACHADO

**OPERAÇÃO DE REDES DE ESCOAMENTO DE PETRÓLEO UTILIZANDO  
ALGORITMO GENÉTICO MULTI-OBJETIVO**

Dissertação aprovada em 08 de junho de 2006.

COMISSÃO EXAMINADORA:

---

Carlos de Oliveira Galvão  
Orientador  
Unidade Acadêmica de Engenharia Civil – UFCG

---

Francisco Vilar Brasileiro  
Orientador  
Unidade Acadêmica de Sistemas e Computação - UFCG

---

Wilson Fadlo Curi  
Examinador interno  
Unidade Acadêmica de Física - UFCG

---

Luísa Fernanda Ribeiro Reis  
Examinadora externa  
Escola de Engenharia de São Carlos – USP

---

Vicente Delgado Moreira  
Examinador externo  
PETROBRAS

*"O Saber é saber que nada se sabe.  
Esta é a definição do verdadeiro conhecimento."*

Confúcio

## **Agradecimentos**

A Deus, pelo amparo nos momentos mais difíceis;

À minha família, em especial aos meus pais Francisco e Edite, pela confiança e apoio incondicional a todas as minhas decisões;

Ao meu esposo, Gildemberg, pela paciência e companheirismo;

Aos orientadores Carlos e Fubica, pela orientação efetiva e constante desse trabalho, com entusiasmo, confiança e dedicação;

Aos membros (Alan, Bárbara, Bruno, Carlos, Cledson, Fubica, Ivonaldo, Kennedy, Marcell, Thiago, Vinícius e Zeca) e ex-membros (Esther, Euriclides e Érico) do projeto SmartPumping, co-responsáveis pela execução desse trabalho;

Aos colegas de mestrado (Alcidney, Cledson, Myrla, Renato e Simone) pelo apoio e amizade consolidada durante esse período das nossas vidas;

Agradecimentos especiais a Esther e Marcell, pelas discussões e valiosas dicas aproveitadas nesse trabalho;

A todos que compõem o Laboratório de Sistemas Distribuídos, pela generosa acolhida e gratificante convívio nesse ambiente;

Aos professores, funcionários e colegas do Laboratório de Hidráulica I e II, pelos ensinamentos e serviços prestados;

Aos engenheiros Fabiano Azevedo e Vicente Delgado da UN-RNCE e ao engenheiro Fábio Arbex do CENPES, pelo esclarecimento de dúvidas, discussões relevantes e envio de dados necessários à execução desse trabalho;

À Coordenadoria de Aperfeiçoamento de Pessoal de Nível Superior – CAPES, pela bolsa de estudo concedida;

À Financiadora Nacional de Estudos e Projetos (FINEP) e à Petróleo Brasileiro S.A. (PETROBRAS), financiadores do projeto intitulado “Controle Inteligente de Sistemas de Bombeamento em Redes de Escoamento de Petróleo – SmartPumping”, cuja infraestrutura deu suporte ao desenvolvimento do presente trabalho.

## Resumo

A otimização da operação de sistemas de escoamento de petróleo é essencial para garantir o atendimento das restrições físicas do sistema e a maximização da eficiência dos objetivos operacionais, pois que prolonga a vida útil do sistema e mantém a produção do petróleo dentro dos requisitos de quantidade e qualidade segundo critérios racionais no custeio da energia elétrica. A utilização de modelos de otimização adaptados especificamente para obtenção da operação ideal permite oferecer uma possibilidade de operação mais racional, diminuindo a subjetividade, os riscos de falhas humanas e os conflitos que geralmente ocorrem quando a tentativa de otimização é feita de modo descentralizado e baseada unicamente na experiência adquirida pelos operadores em campo. O algoritmo genético tem sido utilizado com frequência na otimização desses sistemas, e se destaca pela sua natureza robusta, que permite associar as características de eficácia e eficiência. Recentemente têm sido desenvolvidos diversos algoritmos genéticos multi-objetivo, os quais tratam mais realisticamente problemas complexos que necessitam da otimização simultânea de diversos objetivos. Esse trabalho analisa a incorporação de diversas técnicas e alternativas ao método de otimização multi-objetivo *Strength Pareto Evolutionary Algorithm 2*, com o propósito de aumentar a sua eficiência e torná-lo aplicável ao problema da otimização da operação de sistemas de escoamento de petróleo. As alternativas incorporadas abrangem a utilização da técnica de *seeding*, de heurísticas de reparo e descarte de soluções inviáveis, a integração do conceito de viabilidade com o conceito de dominância, a introdução de conhecimentos nos operadores de reprodução, dentre outras. Os experimentos foram conduzidos em uma sub-rede de escoamento de petróleo da Unidade de Negócios de Exploração e Produção do Rio Grande do Norte e Ceará da PETROBRAS, e os resultados validaram a metodologia como eficiente e aplicável ao problema, ao gerar boas alternativas para o escalonamento das bombas da rede para um período de 24 horas, em um tempo hábil.

## Abstract

The optimization of the operation in oil pipeline networks is essential to guarantee the attendance of constraints and to maximize the efficiency of the operational objectives, in order to draw out its useful life while keeping the oil production in the requirements of quantity and quality with rationality of the costs of electric energy. The use of computational optimization models for solving this type of problem, allows to offer a more rational operation, diminishing the subjectivity, the risks of imperfections and the conflicts that generally occur when this operation are made decentralized and based solely in the experience acquired in field. Genetic algorithms have been used to optimize these systems, and it detaches for its robust nature, that allows associating its effectiveness and efficiency characteristics. Recently, has been developed various multi-objective genetic algorithms, which treat more reliability complex problems which need simultaneous optimization of diverse objectives. This work analyzes the incorporation of diverse techniques and in the Strength Pareto Evolutionary Algorithm 2, with the intention of increase its efficiency and becoming applicable to the problem of pump scheduling in oil pipeline network. The incorporated alternatives surround the use of the technique of seeding, of knowledge for repair and discarding of infeasible solutions, the integration of the concept of viability with the dominance criteria, the introduction of knowledge in the reproduction operators, among others. The experiments are based in a small part of the pumping network of “Unidade de Negócios de Exploração e Produção do Rio Grande do Norte e Ceará”, of PETROBRAS, and the results show an efficient and applicable methodology to the problem, which generates good alternatives for the pump scheduling, for a period of 24 hour, in a skillful time.

## Lista de ilustrações

### Figuras

Figura 1 – Rede típica de escoamento da produção de petróleo (BRASILEIRO, 2005).....	6
Figura 2 – Localização da rede de transporte da UN-RNCE (Fonte: Arquivos de imagens da UN-RNCE).....	8
Figura 3 – Esquema da rede piloto da UN-RNCE.....	11
Figura 4 – Otimização multi-objetivo baseada na preferência (Adaptado de DEB, 2001).....	14
Figura 5 – Otimização multi-objetivo ideal (Adaptado de DEB, 2001).....	14
Figura 6 – Esquema do método de seleção SUS.....	27
Figura 7 – Esquema do operador de cruzamento de um ponto.....	28
Figura 8 – Esquema do operador de cruzamento uniforme.....	29
Figura 9 – Esquema do operador de mutação.....	29
Figura 10 – Rede piloto modelada no SmartPumping.....	64
Figura 11 – Classificação dos indivíduos considerando inicialmente as relações de dominância.....	75
Figura 12 – Classificação dos indivíduos considerando inicialmente o conceito de viabilidade.....	75
Figura 13 – Representação do cromossomo.....	77
Figura 14 – Cruzamento direcionado proposto por Brasileiro (2005).....	79
Figura 15 – Fluxograma de aplicação dos operadores para geração da nova população.....	82
Figura 16 – Exemplo de atuação da regra de reparo.....	84
Figura 17 – Modelagem da rede piloto simplificada para busca exaustiva.....	88

### Gráficos

Gráfico 1 – Caracterização do espaço de busca para a rede piloto simplificada.....	98
Gráfico 2 – Distribuição das soluções no espaço de busca.....	99
Gráfico 3 – Valores de funções-objetivo das soluções do espaço de busca.....	100
Gráfico 4 – Distribuição das soluções viáveis no espaço de busca.....	101
Gráfico 5 – Funções-objetivo das soluções viáveis no espaço de busca.....	102
Gráfico 6 – Caracterização das soluções da fronteira Pareto.....	104
Gráfico 7 – Evolução para a fronteira Pareto das metodologias A, B e C.....	106
Gráfico 8 – Evolução para a fronteira Pareto das metodologias C e 1.....	111
Gráfico 9 – Evolução para a fronteira Pareto das metodologias C e 2.....	112
Gráfico 10 – Evolução para a fronteira Pareto das metodologias C, 3 e 4.....	113
Gráfico 11 – Evolução para a fronteira Pareto das metodologias C, 5, 6, 7 e 8.....	115
Gráfico 12 – Evolução para a fronteira Pareto das metodologias 9, 10 e 11.....	122
Gráfico 13 – Evolução da função-objetivo 1 das metodologias aplicadas sobre a rede piloto.....	126
Gráfico 14 – Evolução da função-objetivo 2 das metodologias aplicadas sobre a rede piloto.....	126
Gráfico 15 – Evolução da função-objetivo 3 das metodologias aplicadas sobre a rede piloto.....	127
Gráfico 16 – Evolução da função-objetivo 1 dos experimentos utilizando restrição temporal.....	129
Gráfico 17 – Evolução da função-objetivo 2 dos experimentos utilizando restrição temporal.....	129
Gráfico 18 – Evolução da função-objetivo 3 dos experimentos utilizando restrição temporal.....	130
Gráfico 19 – Soluções finais normalizadas da otimização considerando a restrição temporal.....	132

## Tabelas

Tabela 1 – Dados físicos da rede piloto.....	12
Tabela 2 – Propriedades dos fluidos da rede piloto.....	12
Tabela 3 – Dados de projeto e de operação da rede piloto.....	12
Tabela 4 – Exemplo de codificações binária <i>Gray</i> e convencional.....	23
Tabela 5 – Características físicas das bombas.....	64
Tabela 6 – Características físicas dos oleodutos.....	64
Tabela 7 – Características físicas dos tanques.....	64
Tabela 8 – Previsão da produção do fluido da rede piloto.....	65
Tabela 9 – Tarifas de energia elétrica.....	65
Tabela 10 – Critérios para aplicação da mutação direcionada alternativa.....	80
Tabela 11 – Parâmetros do algoritmo genético.....	92
Tabela 12 – Caracterização dos pontos de falha das soluções inviáveis.....	99
Tabela 13 – Funções-objetivo das soluções da fronteira Pareto da rede piloto simplificada.....	103
Tabela 14 – Métrica de desempenho 1 para as metodologias A, B e C.....	105
Tabela 15 – Métrica de desempenho 2 para as metodologias A, B e C.....	105
Tabela 16 – Métrica de desempenho 3 para as metodologias A, B e C.....	106
Tabela 17 – Métrica de desempenho 1 para as metodologias C e 1 a 8.....	110
Tabela 18 – Métrica de desempenho 2 para as metodologias C e 1 a 8.....	110
Tabela 19 – Métrica de desempenho 3 para as metodologias C e 1 a 8.....	111
Tabela 20 – Métrica de desempenho 1 para as metodologias 9, 10 e 11.....	121
Tabela 21 – Métrica de desempenho 2 para as metodologias 9, 10 e 11.....	122
Tabela 22 – Métrica de desempenho 3 para as metodologias 9, 10 e 11.....	122
Tabela 23 – Métrica de convergência para os experimentos sobre a rede piloto.....	124
Tabela 24 – Métrica de diversidade para os experimentos sobre a rede piloto.....	125
Tabela 25 – Métrica de otimização para os experimentos sobre a rede piloto.....	125
Tabela 26 – Métrica de convergência para os experimentos utilizando restrição temporal.....	128
Tabela 27 – Métrica de diversidade para os experimentos utilizando restrição temporal.....	128
Tabela 28 – Métrica de otimização para os experimentos utilizando restrição temporal.....	129
Tabela 29 – Soluções finais para a rede piloto considerando a restrição temporal.....	132

## Quadros

Quadro 1 – Métodos clássicos para otimização multi-objetivo (DEB, 2001).....	18
Quadro 2 – Diferenças entre os métodos SPEA e SPEA2.....	69
Quadro 3 – Severidade das restrições violadas.....	74
Quadro 4 – Estratégias de reparo do calculador de solução viável.....	78
Quadro 5 – Metodologias avaliadas na otimização da rede piloto simplificada.....	89

## Lista de abreviaturas e siglas

AG	Algoritmo Genético
ANEEL	Agência Nacional de Energia Elétrica
API	<i>American Petroleum Institute</i>
BS&W	<i>Basic Sediments and Water</i>
CENPES	Centro de Pesquisas e Desenvolvimento Leopoldo Américo Miguez de Mello
COSERN	Companhia Energética do Rio Grande do Norte
CNSGA	<i>Controlled elitist non-dominated sorting genetic algorithm</i>
CSV	Calculador de solução viável
D	Dominado
DPGA	<i>Distance based Pareto genetic algorithm</i>
ECC	Estações coletoras centrais
ECS	Estações coletoras satélites
ETO	Estação de tratamento de óleo
FFGA	<i>Fonseca and Flemming's multi-objective genetic algorithm</i>
HLGA	<i>Hajela and Lin's genetic algorithm</i>
I	Inviável
LOR	Lorena, estação coletora da UN-RNCE
LPX	Leste de Poço Xavier, estação coletora da UN-RNCE
MOEA	<i>Multi-objective evolutionary algorithm</i>
MOGA	<i>Multiple objective genetic algorithm</i>
MOP	<i>Multi-objective optimization problem</i>
ND	Não-dominado
NDV	Não-dominado viável
NPGA	<i>Niched-Pareto genetic algorithm</i>
NSGA	<i>Non-dominated sorting genetic algorithm</i>
NSGA-II	<i>Elitist non-dominated sorting genetic algorithm</i>
PAES	<i>Pareto archives evolution strategy</i>
Pc	Probabilidade de cruzamento
PC	Ponto de corte
PESA	<i>Pareto envelope-based selection algorithm</i>
PETROBRAS	Petróleo Brasileiro S.A.
PAF	Ponto anterior à falha
PF	Ponto de falha
Pm	Probabilidade de mutação
pMOEA	<i>Parallel multi-objective evolutionary algorithm</i>
PPP	Estação de pré-processamento de petróleo
PSPMEA	<i>Parallel strength Pareto multi-objective evolutionary algorithm</i>

RAND	<i>Randomic</i>
RFQ	Riacho da Forquilha, estação coletora da UN-RNCE
SOEA	<i>Single-objective evolutionary algorithm</i>
SPEA	<i>Strength Pareto evolutionary algorithm</i>
SPEA2	<i>Strength Pareto evolutionary algorithm 2</i>
SUS	<i>Stochastic Universal Sampling</i>
UFCG	Universidade Federal de Campina Grande
UN-RNCE	Unidade de Negócios de Exploração e Produção do Rio Grande do Norte e Ceará
UPN	Upanema, estação coletora da UN-RNCE
V	Viável
VEGA	<i>Vector evaluated genetic algorithm</i>
VOES	<i>Vector optimized evolution strategy</i>
WBGA	<i>Weighted based genetic algorithm</i>

## Lista de símbolos e notações

$a, b, c$	Coefficientes da curva característica da bomba
$Ab$	Área da base do tanque
$B$	Bomba de uma unidade consumidora do sistema
$BSW$	Valor do BS&W do fluido
$C$	<i>Cluster</i> (Grupo)
$Custo$	Custo de energia elétrica
$d$	Diâmetro interno do duto
$D$	Densidade de vizinhança
$DP$	Desvio padrão da população
$\sigma$	Distância euclidiana
$dc$	Distância entre <i>clusters</i> (grupos)
$dS$	Duração do horizonte de operação
$dmês$	Duração do mês
$\varepsilon$	Rugosidade absoluta do duto
$E$	Estado da bomba
$f$	Coefficiente do fator de atrito no duto
$F$	Aptidão do indivíduo
$F(Q)$	Ganho/perda de carga nos elementos
$FO$	Função-objetivo
$FP$	Função ponderada
$g$	Aceleração da gravidade
$G$	Geração
$Hman$	Altura manométrica da bomba
$H$	Carga piezométrica
$i$	Intervalo de cálculo do horizonte de operação
$\Delta i$	Duração do intervalo de cálculo
$IC$	Intervalo de confiança
$J$	Matriz jacobiana para cálculo do equilíbrio hidráulico
$\kappa$	Fator de adequação da função-objetivo 3
$L$	Comprimento do duto
$MS$	Métrica de espaçamento
$m, p$	Parâmetros da equação da viscosidade cinemática
$md$	Medida de distância
$n$	Dimensão da amostra
$N$	Nível de fluido no tanque
$NC$	Nível de controle do tanque
$\eta$	Número de nós de carga piezométrica desconhecida

$\eta_M$	Rendimento do motor
$\eta_B$	Rendimento da bomba
$P$	Conjunto de soluções
$P^*$	Conjunto de soluções não-dominadas
$PV^*$	Conjunto de soluções não-dominadas viáveis
$Pot$	Potência da bomba
$Pop$	População corrente
$\overline{Pop}$	População externa
$PU$	União da população corrente com a população externa
$Pr$	Propriedade do fluido da estação receptora
$peso$	Peso atribuído à função-objetivo para ponderação
$q$	Quantidade de indivíduos da população
$Q$	Vazão
$R$	Matriz para cálculo do equilíbrio hidráulico
$RF$	Valor do <i>Raw Fitness</i> do indivíduo
$Rey$	Número de Reynolds do escoamento
$\rho$	Massa específica do fluido
$s$	Elemento com carga piezométrica conhecida
$S$	Valor do <i>Strength</i> do indivíduo
$st$	Coefficiente de <i>Student</i>
$\Delta S$	Desvio padrão da amostra
$T$	Temperatura do fluido
$t$	Intervalo de atuação
$\Delta t$	Duração do intervalo de atuação
$tarifa$	Tarifa de energia elétrica
$UC$	Unidade consumidora de energia elétrica
$V$	Espaço de busca das soluções factíveis
$\nu$	Viscosidade cinemática do fluido
$Var$	Variância
$V_t$	Volume de fluido no tanque
$V_e$	Volume de fluido na entrada
$\%Vol$	Proporção percentual de volume
$Volume$	Volume entregue na estação receptora final
$\bar{x}$	Média amostral
$\mu$	Média populacional
$\alpha, \ell, \delta, \lambda, k$	Indivíduos das populações
$ \cdot $	Cardinalidade do conjunto
$\lceil \cdot \rceil$	Arredondar para cima

# Sumário

<i>Agradecimentos</i>	<i>i</i>
<i>Resumo</i>	<i>ii</i>
<i>Abstract</i>	<i>iii</i>
<i>Lista de ilustrações</i>	<i>iv</i>
<i>Lista de abreviaturas e siglas</i>	<i>vi</i>
<i>Lista de símbolos e notações</i>	<i>viii</i>
<i>Sumário</i>	<i>x</i>
<b>1. Introdução</b>	<b>1</b>
<b>2. Operação de redes de escoamento de petróleo</b>	<b>5</b>
<b>2.1. Formalização do problema</b>	<b>5</b>
<b>2.2. Estudo de caso</b>	<b>8</b>
<b>3. Revisão Bibliográfica</b>	<b>13</b>
<b>3.1. Otimização multi-objetivo</b>	<b>13</b>
3.1.1 Considerações gerais	13
3.1.2 Dominância e conceitos de Pareto	15
3.1.3 Métodos de otimização	16
<b>3.2. Algoritmos evolucionários</b>	<b>18</b>
3.2.1 Princípios	18
3.2.2 Algoritmos Genéticos	19
3.2.2.1 Representação das soluções	22
3.2.2.2 População inicial e substituição das populações	23
3.2.2.3 Função-objetivo e aptidão	24
3.2.2.4 Operador de seleção	25
3.2.2.5 Operadores de reprodução	27
3.2.2.6 Convergência do algoritmo	29
3.2.2.7 Parâmetros de controle	30
3.2.3 Algoritmos Evolucionários para Otimização Multi-objetivo	31
3.2.3.1 Breve Histórico	31
3.2.3.2 Métricas de desempenho	37
3.2.3.3 Consideração das restrições	39
<b>3.3. Trabalhos Correlatos</b>	<b>40</b>
3.3.1 Redes de escoamento de petróleo	40
3.3.2 Redes de escoamento de água	42
<b>3.4. Análise da revisão de literatura</b>	<b>45</b>
<b>4. Metodologia</b>	<b>47</b>

<b>4.1. Modelo computacional SmartPumping</b>	<b>47</b>
4.1.1 Generalidades	47
4.1.2 Mistura de fluidos	50
4.1.3 Equilíbrio hidráulico	53
4.1.4 Cálculo tarifário	58
4.1.5 Modelagem da rede piloto no SmartPumping	62
<b>4.2. Objetivos da operação</b>	<b>65</b>
<b>4.3. Método para otimização multi-objetivo</b>	<b>68</b>
4.3.1 Algoritmo evolucionário multi-objetivo SPEA2	68
4.3.2 Inclusão do conceito de viabilidade no método SPEA2	73
4.3.3 Representação das soluções e geração da população inicial	76
4.3.4 Operadores de reprodução direcionados	78
4.3.5 Descarte e reparo de indivíduos inviáveis	82
4.3.6 Redução do conjunto final e escolha da solução	84
<b>4.4. Avaliação do modelo de otimização multi-objetivo</b>	<b>87</b>
4.4.1 Experimentos de avaliação	87
4.4.2 Métricas de desempenho para as metodologias aplicadas sobre a rede piloto simplificada	93
4.4.3 Métricas de desempenho para as metodologias aplicadas sobre a rede piloto	95
<b>4.5. Processo de desenvolvimento do método</b>	<b>97</b>
<b>5. Resultados e discussão</b>	<b>98</b>
<b>5.1. Espaço de busca do problema</b>	<b>98</b>
<b>5.2. Aplicação sobre a rede piloto simplificada</b>	<b>105</b>
5.2.1 Avaliação das alternativas de preenchimento da população externa	105
5.2.2 Avaliação das alternativas incorporadas individualmente à metodologia base	109
5.2.3 Avaliação das alternativas incorporadas conjuntamente à metodologia base	120
<b>5.3. Aplicação sobre a rede piloto</b>	<b>124</b>
<b>5.4. Aplicação sobre a rede piloto com restrição temporal</b>	<b>128</b>
<b>6. Conclusões e recomendações para estudos futuros</b>	<b>133</b>
<b>Referências Bibliográficas</b>	<b>136</b>

## 1. Introdução

O Brasil tornou-se no corrente ano um dos poucos países auto-suficientes em petróleo, ao produzir 1,9 milhões de barris/dia ao passo que consome 1,8 milhões. Cerca de 20% dessa produção é do tipo *onshore* (terrestre), sendo a Unidade de Negócios de Exploração e Produção do Rio Grande do Norte e Ceará (UN-RNCE) da PETROBRAS (Petróleo Brasileiro S.A.) responsável pela maior produção de petróleo nesse setor, explorando mais de 4.500 poços situados na bacia Potiguar, a qual abrange parte dos estados do Rio Grande do Norte e Ceará. A PETROBRAS e a UFCG vêm desenvolvendo, em parceria, o sistema computacional SmartPumping para controlar em tempo real o escoamento de fluidos em redes, e ser utilizado, inicialmente, como subsídio à tomada de decisão no âmbito da UN-RNCE.

O controle operacional de um sistema de produção de petróleo consiste em determinar, para um determinado horizonte futuro, quais bombas devem ser ligadas e em que intervalo de tempo, de modo que as restrições físicas da rede sejam atendidas, a produção não seja reduzida e os objetivos operacionais sejam atingidos com o máximo de eficiência. A adoção de um método de otimização eficiente nas atividades operacionais de campo se propõe a diminuir a subjetividade inerente à operação tradicionalmente realizada, a qual é baseada na experiência dos operadores, e aumentar a eficiência operacional.

Como os objetivos operacionais que se deseja atingir são de naturezas diferentes, o problema é caracterizado como multi-objetivo, cuja solução se torna mais complexa, principalmente devido aos objetivos serem geralmente conflitantes.

Em uma operação típica do sub-sistema “parque de bombas” de uma rede de escoamento de petróleo, o objetivo mais comum que se deseja atingir é a minimização do custo de energia elétrica do bombeamento, o qual pode variar expressivamente em função do escalonamento adotado para aquela operação das bombas. Outros custos operacionais podem ser expressos indiretamente em função do escalonamento adotado para as bombas, como através do número de chaveamentos do sistema que fornece um indicador do custo de manutenção das bombas, e da manutenção das características requeridas para o fluido entregue na estação de tratamento de óleo - ETO, as quais influenciam na eficiência dos equipamentos utilizados nessa estação.

A manutenção de propriedades como vazão e BS&W (porcentagem de água e sedimentos) do fluido entregue na ETO dentro dos limites estabelecidos, além de otimizar a operação realizada nessa estação, é importante também para que a produção do sistema seja constantemente mantida e que o fluido produzido esteja em conformidade com os limites fixados pelo *American Petroleum Institute* (API), o que pode ser considerado um objetivo operacional tão ou mais importante que os anteriores.

Dentre as restrições físicas da rede a serem atendidas durante a operação, as quais eventualmente podem ser consideradas como um objetivo explícito, estão o atendimento dos limites de velocidade e pressão nos dutos, das demandas da produção e dos limites de armazenamento dos tanques. Além das restrições físicas e dos objetivos operacionais, a determinação da operação ótima desses sistemas também está sujeita às restrições temporais, para que seja possível a sua utilização em campo.

Várias técnicas de otimização têm sido utilizadas para o problema operacional do escoamento em redes, tendo o algoritmo genético se destacado na resolução deste problema devido a sua natureza robusta, obtida pela associação das características de eficácia e eficiência. A eficiência é a capacidade de o algoritmo encontrar rapidamente uma solução para o problema, enquanto que a eficácia é a capacidade de encontrar a (ou se aproximar da) solução ótima global, a qual é composta de múltiplas soluções ótimas, no caso da otimização ser multi-objetivo.

Especificamente para as redes de escoamento de petróleo a natureza multi-objetivo do problema do escalonamento das bombas não tem sido considerada na literatura. De um modo geral, a maioria das metodologias que vem sendo empregadas para resolução desse tipo de problema não está adaptada para aplicação ao mundo real, por não considerar a complexidade inerente da dimensão das redes, não ajustar-se às particularidades típicas da operação de que se trata e não considerar a restrição temporal necessária para utilização contínua em campo.

Nesse contexto, o objetivo dessa pesquisa é indicar uma metodologia aplicável à otimização da operação de sistemas de escoamento de petróleo, considerando os múltiplos objetivos e as restrições específicas do problema. Foi escolhida a técnica dos algoritmos genéticos, a qual se mostra mais adequada para otimização do problema em análise devido: 1) ao espaço de busca grande e complexo, com presença de ótimos locais, situação que os algoritmos genéticos conseguem contornar com facilidade devido à exploração simultânea de vários pontos no espaço de busca; 2) à combinação de bombas diferentes na rede de escoamento e de restrições complicadas, o que dificulta a representação através de equações

matemáticas, requeridas em outros métodos de otimização; 3) à adoção de funções-objetivo conflitantes e de grandezas diversas, as quais podem ser consideradas explicitamente em uma otimização por algoritmo genético, sem a necessidade de normalização; e 4) à necessidade de utilização de um simulador hidráulico externo, no qual um algoritmo genético pode ser facilmente acoplado.

Após a definição de um método evolucionário multi-objetivo, serão incorporadas, nesse método, técnicas e alternativas que se propõem a aumentar sua eficiência e eficácia, bem como suprir algumas de suas deficiências. Dessa forma, os objetivos específicos dessa pesquisa constituem em quantificar o ganho de desempenho obtido quando da inclusão de conhecimento nos operadores do algoritmo genético e da utilização de heurísticas de reparo, descarte e ordenamento das soluções inviáveis.

Esse trabalho está organizado em seis capítulos. No capítulo 2, são apresentadas as características da operação em redes de escoamento de petróleo, como também os problemas inerentes dessa operação. A delimitação da rede de estudo, parte integrante da UN-RNCE, a qual servirá para análise e validação do algoritmo genético multi-objetivo e das alternativas incorporadas, também é apresentada nesse capítulo.

No capítulo 3 é realizada a revisão da literatura sobre os algoritmos evolucionários, em especial dos algoritmos genéticos, com revisão dos seus fundamentos e das suas vantagens em relação aos métodos tradicionais em problemas complexos. Especificamente para os algoritmos evolucionários multi-objetivo, é apresentado um breve histórico da evolução e aperfeiçoamento desses métodos até os dias atuais. Ao final do capítulo, é feita uma análise das pesquisas correlatas, tanto para o caso do escoamento de petróleo quanto para o caso do escoamento de água, cujo estado da arte apresenta-se muito mais evoluído e amplo do que para o caso do petróleo.

O capítulo 4 se propõe a detalhar cada metodologia utilizada nessa pesquisa, iniciando pela descrição do modelo computacional SmartPumping, o qual é utilizado para simulação hidráulica do escoamento e cálculo tarifário da operação. Apresenta ainda a definição das funções-objetivo a serem otimizadas, o detalhamento da metodologia de otimização multi-objetivo adotada e a descrição dos experimentos realizados para avaliação do desempenho dessa metodologia.

Os resultados dos experimentos são apresentados no capítulo 5, cuja análise conduz à seleção de uma metodologia robusta e adequada para a resolução do problema da operação

das bombas em um sistema de escoamento de petróleo. Neste capítulo, é realizada ainda, a análise da viabilidade da utilização, em campo, da metodologia selecionada. Finalmente, o capítulo 6, apresenta as conclusões e sugestões para novos estudos em continuidade ao presente.

## 2. Operação de redes de escoamento de petróleo

### 2.1. *Formalização do problema*

O petróleo é uma substância oleosa, inflamável, menos densa que a água, com cheiro característico e de cor variando entre o negro e o castanho escuro. É encontrado concentrado em terrenos denominados bacias sedimentares, formadas por camadas ou lençóis porosos de areia, arenitos ou calcários. Ao acumular-se, formam jazidas, onde é encontrado o gás natural, na parte mais alta, e petróleo e água, nas mais baixas.

O sistema de produção de petróleo tem início com a extração nos poços, onde o fluido emergido (composto de água salgada, gás natural e petróleo bruto) é centralizado em um equipamento denominado *manifold* que envia a produção de diferentes poços para uma Estação Coletora. O gás natural produzido pode ser queimado na própria estação, ou direcionado para um gasoduto e conduzido para uma Unidade de Processamento de Gás Natural - UPGN.

Parte da água produzida pelos poços é separada na estação coletora, o restante é bombeado através de oleodutos, juntamente com o petróleo, para a Estação de Tratamento de Óleo - ETO. A água extraída, que não possui valor econômico, é tratada e reinjetada nos poços, atuando como mantenedora da pressão da jazida, ou descartada através de emissário submarino, atendendo às normas ambientais que rejeitam o seu despejo a céu aberto. Na estação de tratamento, o petróleo é previamente tratado para atender às normas estabelecidas antes de ser enviado para as refinarias. Nessa estação ocorre a redução do BS&W (*Basic Sediments and Water*) que é o percentual de água e sedimentos presente no petróleo, até os limites fixados pelo API (*American Petroleum Institute*).

A Figura 1 mostra a configuração típica de uma rede de escoamento da produção de petróleo. As estações coletoras que recebem produção apenas de poços são denominadas Estações Coletoras Satélites – ECS, enquanto as que recebem, além dos poços, produção de outras estações, são denominadas Estações Coletoras Centrais – ECC.

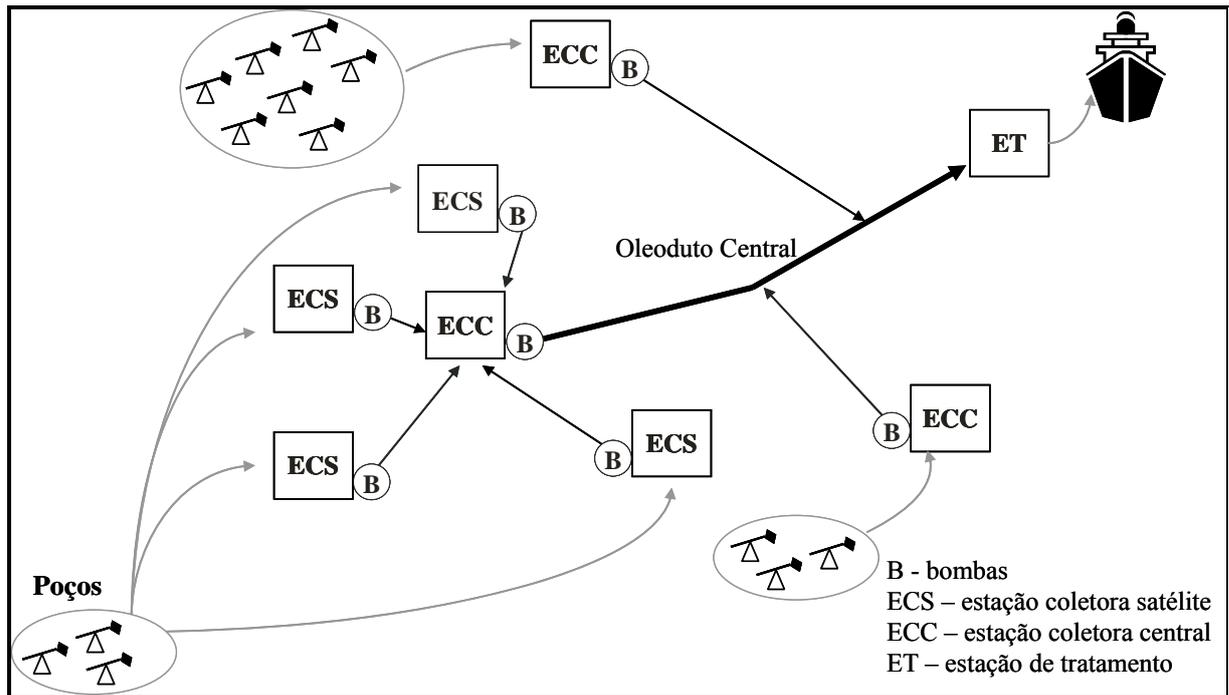


Figura 1 – Rede típica de escoamento da produção de petróleo (BRASILEIRO, 2005).

Uma das principais metas que se deseja atingir na operação de uma rede de escoamento de petróleo, considerando exclusivamente o sub-sistema “parque de bombas”, é diminuir os custos com energia elétrica referente ao bombeamento. O custo de energia elétrica é composto pelo custo de bombeamento dos poços para as estações coletoras, pelo custo de bombeamento das estações coletoras para a estação de tratamento, por custos de iluminação, entre outros.

O custo de bombeio dos poços para as estações coletoras é pouco variável, devido ao seu funcionamento contínuo. Desse modo, o sistema modelado nesse trabalho compreende apenas a produção entre as estações coletoras e a de tratamento por fornecer maior possibilidade de economia de energia elétrica através do escalonamento inteligente das bombas, diminuindo ou interrompendo o bombeamento em horários de pico de energia elétrica quando as tarifas são mais caras.

A redução dos custos de manutenção dos sistemas de bombeamento das estações coletoras é outro objetivo a ser alcançado. Esse custo é de difícil quantificação, mas é fortemente influenciado pela operação das bombas, sendo que escalonamentos com um alto número de chaveamentos aceleram o desgaste das bombas e diminuem a sua vida útil. O número de chaveamentos em um sistema é a quantidade de vezes que cada bomba que estava desligada foi acionada, e pode ser utilizado como parâmetro na escolha de soluções que irão provocar menos desgaste, e, portanto, menores custos.

O processo de tratamento de óleo na ETO é influenciado pela variação das características do fluido recebido nesta estação, de maneira que faz-se necessário minimizar a variação daquelas características até para que se aperfeiçoe o processo. Uma vazão pouco variável nessa estação possibilita, por exemplo, otimizar a operação do extrator e do separador de óleo, os quais foram projetados para operar em uma vazão pré-determinada ou numa faixa estreita de vazão.

O volume de produtos químicos utilizado para o tratamento do óleo é proporcional, dentre outros, ao BS&W do fluido recebido na ETO. Por um lado, se a porcentagem de água que chega nessa estação está abaixo dos limites estabelecidos, o volume de produtos químicos utilizado tornar-se-á super-dimensionado, causando desperdícios dos produtos; por outro lado, se a porcentagem de água está muito acima do esperado, o volume de produtos químicos se tornará insuficiente, sendo necessário, algumas vezes, reprocessar o óleo. Desse modo, um fluido com propriedades e fluxo constantes na entrada da estação de tratamento de óleo constitui objetivo da operação.

Além dos objetivos operacionais expostos, o atendimento do aumento de produção do sistema, sem que haja interferência em sua rede física, é uma meta a ser atingida. Segundo Silva (1999), um dos investimentos mais altos na estruturação da capacidade de escoamento de petróleo está na fase de construção dos dutos. Após essa construção, se houver deficiências na capacidade de escoamento da rede, devido a um aumento expressivo da produção, por exemplo, os gastos envolvidos no redimensionamento das redes serão extremamente altos, por se tratar de dezenas, ou centenas, de quilômetros de dutos e requerer algum tipo de paralisação parcial da linha de produção. Logo, quanto mais eficientemente esses sistemas forem operados, mais adiada será uma interferência na estrutura física na rede de escoamento.

A rede de escoamento de petróleo está sujeita, ainda, a uma série de restrições físicas e operacionais, tais como o limite de armazenamento dos tanques, a capacidade das bombas e os limites de pressões e velocidades nos dutos. O problema da operação desses sistemas se resume em determinar, para um horizonte definido, quais bombas devem operar em cada intervalo de tempo de modo que as restrições sejam satisfeitas, os múltiplos objetivos sejam otimizados e a demanda de produção seja atendida.

## 2.2. Estudo de caso

A Unidade de Negócios de Exploração e Produção do Rio Grande do Norte e Ceará (UN-RNCE) da PETROBRAS (Petróleo Brasileiro S.A.) é responsável pela maior produção de petróleo terrestre do Brasil, explorando mais de 4.500 poços compreendidos entre os estados do Rio Grande do Norte e Ceará. São cerca de 70 estações coletoras que utilizam em torno de 270 bombas para conduzir a produção ao longo de 300 km de dutos até a estação de tratamento de óleo em Guamaré, localizada no litoral norte do estado do Rio Grande do Norte (Figura 2).

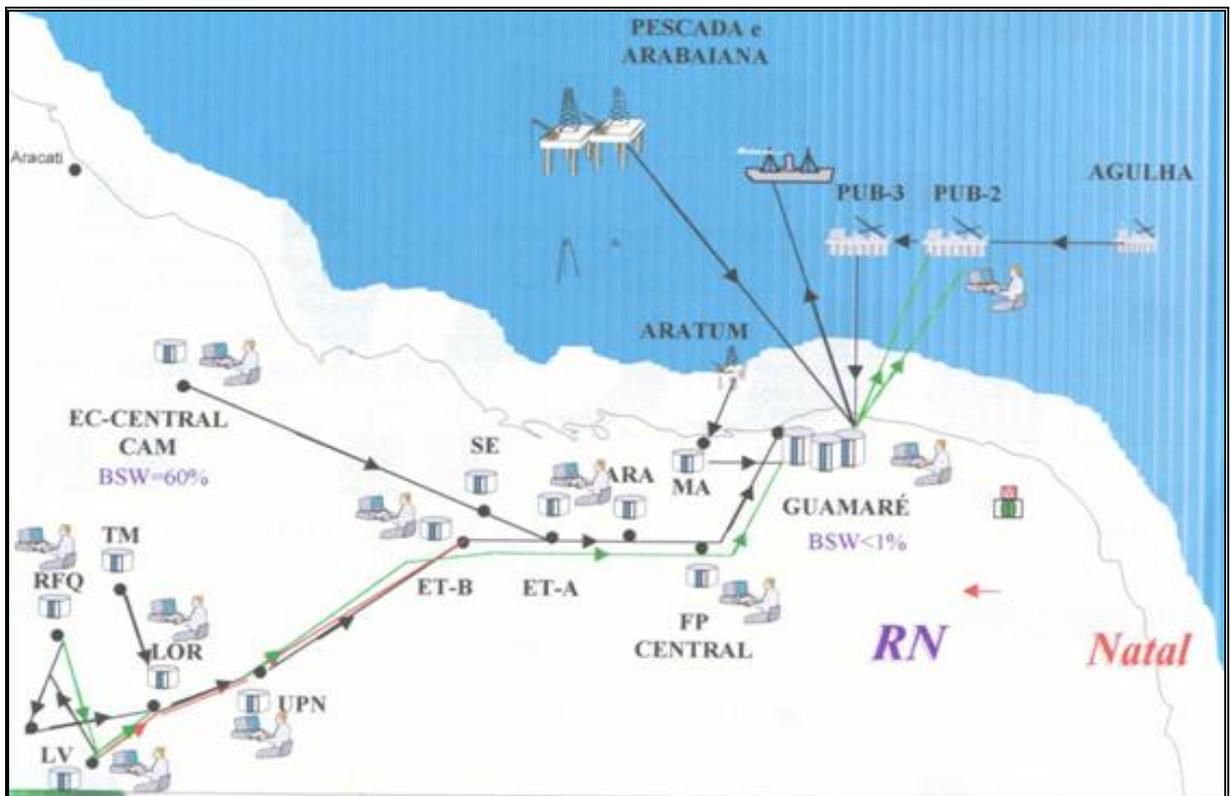


Figura 2 – Localização da rede de transporte da UN-RNCE (Fonte: Arquivos de imagens da UN-RNCE)

O controle da operação desse sistema é feito de forma descentralizada, com auxílio de equipamentos de segurança como sensores de nível e pressostatos e observando-se um sistema de monitoramento, denominado supervisório, o qual disponibiliza os níveis dos tanques registrados através dos transmissores de nível. Uma operação usual consiste em

desligar as bombas apenas quando os seus tanques de armazenamento estão próximos do nível mínimo de controle e no horário de pico de energia elétrica. Dessa forma, o escalonamento global das bombas gerado para o sistema pode não representar uma operação ótima, pois, os operadores de cada unidade administrativa, composta por uma estação coletora central e suas estações coletoras satélites, têm uma visão limitada do sistema como um todo. Como essas estações compartilham a mesma estação de tratamento de óleo e utilizam da mesma rede de oleodutos, podem ocorrer violações nas restrições operacionais do sistema, como os limites de pressão e velocidade nos dutos e o armazenamento nos tanques da ETO, e/ou o não atendimento dos demais objetivos almejados na operação.

Para minimizar os conflitos inerentes à complexidade do monitoramento e controle das redes de escoamento e tornar a operação mais eficiente, a PETROBRAS e a UFCG vêm desenvolvendo, em parceria, o sistema computacional SmartPumping (GALVÃO *et al.*, 2004; BRASILEIRO, *et al.*, 2003; <http://www.lsd.ufcg.edu.br/sp>) cujo objetivo principal é controlar em tempo real o escoamento de fluidos em redes.

A rede de escoamento composta pelas estações coletoras Lorena - LOR, Riacho da Forquilha - RFQ e Leste de Poço Xavier - LPX, que bombeiam sua produção para a Estação Coletora Central Upanema – UPN, está sendo utilizada para calibração do modelo hidráulico do SmartPumping através do monitoramento registrado no sistema de monitoramento da UN-RNCE, sendo denominada de rede piloto. Essa rede será utilizada para testes, análise e validação do modelo de otimização aqui proposto. Na Figura 3 (pág. 11) é mostrada a posição relativa das estações da rede piloto, a quantidade de bombas e tanques em cada estação, o comprimento dos dutos que ligam as estações e suas respectivas cotas topográficas (altura em relação ao nível do mar).

Dados físicos e operacionais da rede piloto foram obtidos através de visitas a campo e informações disponibilizadas pela PETROBRAS. As estações de RFQ, LPX e UPN contêm, cada uma, dois tanques de armazenamento. Foi constatado que, com exceção de LPX, os tanques de RFQ e UPN funcionam individualmente, ou seja, não-equalizados.

As bombas do sistema, em um total de seis, são do tipo volumétricas rotativas. Nas bombas volumétricas, a movimentação do fluido é causada diretamente pela ação do órgão de impulsão da bomba que obriga o fluido a executar o mesmo movimento a que está sujeito esse impulsor, e operam aquelas bombas apanhando um volume fixo de líquido e libertando a uma pressão mais alta por meio de um pistão (volumétricas alternativas) ou de uma engrenagem rotativa (volumétricas rotativas).

Bombas volumétricas alternativas envolvem o movimento de vai-e-vem de um pistão no interior de um cilindro, resultando em um escoamento intermitente, pois, para cada golpe do pistão, um volume fixo do líquido é descarregado na bomba. Ao contrário das bombas alternativas, as bombas rotativas resultam em um escoamento contínuo, pois utilizam uma engrenagem, lóbulo, parafuso, ou cata-vento para comprimir o líquido, o qual entra do lado de baixa pressão por uma abertura entre o elemento giratório e a parede de bomba e é expulso por uma válvula de mão única. Bombas volumétricas rotativas são tipicamente usadas em altas pressões, e são boas para fluidos viscosos e de baixa pressão de vapor (MACINTYRE, 1997).

O primeiro trecho da rede, entre RFQ e LPX possui diâmetro interno do duto de 154,00 mm; já os demais trechos possuem diâmetro interno de 261,88 mm. O oleoduto que sai de RFQ passa por dentro da estação LPX, o que significa que o trecho entre LPX e LOR deve comportar, além da produção de LPX, também a produção de RFQ, e assim por diante. A Tabela 1, vide página 12, mostra os dados físicos dos tanques, dutos e bombas fornecidos para a rede piloto. A Tabela 2, por sua vez, mostra os valores aproximados das propriedades dos fluidos em cada estação coletora, obtidos a partir de uma medição específica, portanto, sujeitos a variação em medições posteriores. A Tabela 3 mostra os dados de projeto e de operação fornecidos para a rede piloto.

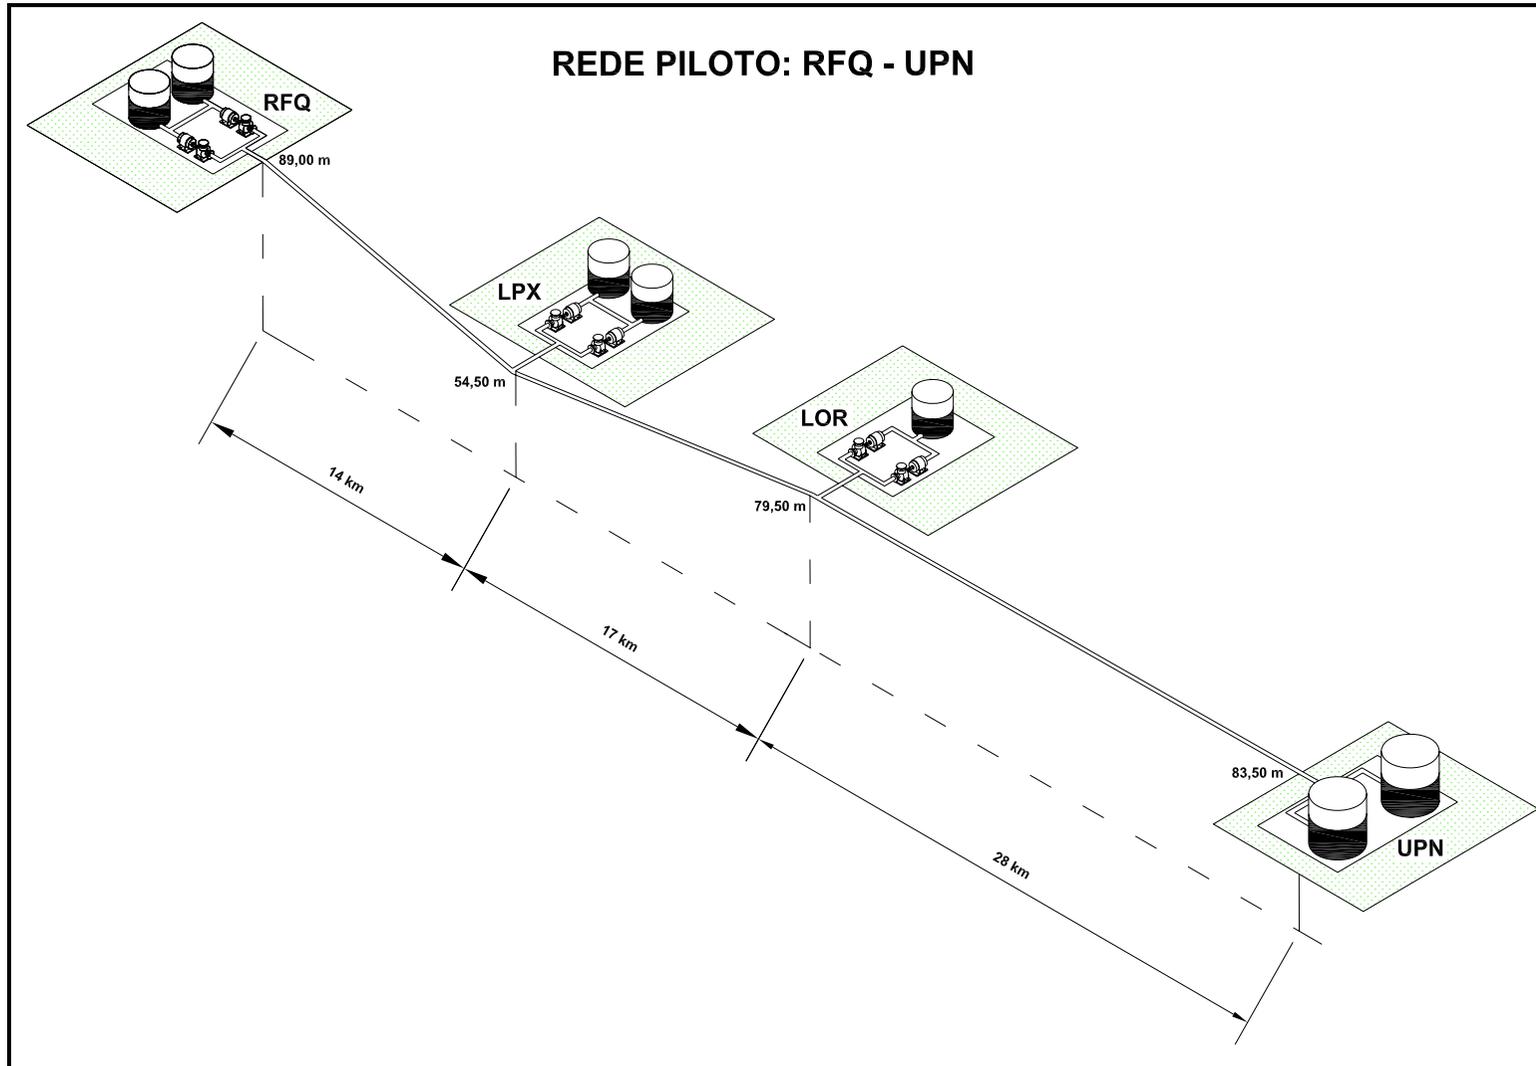


Figura 3 – Esquema da rede piloto da UN-RNCE.

Tabela 1 – Dados físicos da rede piloto.

Estação	TANQUES			
	Altura [m]	Diâmetro [m]	Cota da base [m]	
RQF	7,612	7,637	89,00	
	7,612	7,637	89,00	
LPX	8,200	5,000	54,50	
	8,200	5,000	54,50	
LOR	7,310	7,637	79,50	
UPN	9,112	11,000	83,50	
	9,112	11,000	83,50	
Estação	BOMBAS			
	Fabricante	Modelo		
RQF	NETZSCH	8NE100A		
	NETZSCH	8NE100A		
LPX	NETZSCH	8NE100A		
	NETZSCH	8NE100A		
LOR	NETZSCH	2NE89A		
	NETZSCH	2NE89A		
UPN	NETZSCH	NE80A		
	WORTHINGTON	4HO124		
Estação	DUTOS			
	Cota inicial [m]	Cota final [m]	Comprimento [m]	Diâmetro interno [mm]
RFQ/LPX	89,00	54,50	14.000	154,00
LPX/LOR	54,50	79,50	17.000	261,88
LOR/UPN	79,50	83,50	28.000	261,88

Tabela 2 – Propriedades dos fluidos da rede piloto.

Estação	BS&W [%]	Densidade	Viscosidade cinemática [cP]	
			40°C	60°C
RQF	≤ 1,00	≈ 0,841	≈ 8,00	≈ 4,00
LPX	≤ 6,00	≈ 0,825	≈ 6,00	≈ 4,00
LOR	≤ 23,00	≈ 0,834	≈ 6,00	≈ 4,00

Tabela 3 – Dados de projeto e de operação da rede piloto.

Projeto	Duto	RFQ/LPX	LPX/LOR/UPN
	Temperatura [°C]	40,00	30,00
Pressão máxima [kgf/cm <sup>2</sup> ]	72,80	30,00	
Vazão [m <sup>3</sup> /h]	45,00 a 90,00	200,00 a 225,00	
Operação	Pressão máxima [kgf/cm <sup>2</sup> ]	42,00	20,00
	Temperatura [°C]	15,00 a 45,00	18,00 a 45,00

## 3. Revisão Bibliográfica

### 3.1. Otimização multi-objetivo

#### 3.1.1 Considerações gerais

Otimização é o processo de procura da melhor solução possível para um problema, respeitando um conjunto de limitações ou restrições. Quando o problema requer apenas um objetivo a ser otimizado, a meta é encontrar ou se aproximar, ao máximo, da melhor solução possível, denominada ótimo global. Contudo, muitos problemas requerem a otimização de mais de um objetivo simultaneamente, sendo denominados problemas de otimização multi-objetivo (*Multi-objective optimization problem* – MOP) e requerendo uma fundamentação diferente da adotada em problemas de otimização de um único objetivo. Normalmente os objetivos são conflitantes entre si, e, nesses casos, não existe apenas uma solução para o problema, mas várias soluções favoráveis ou soluções de compromisso (*trade-offs*) para todos os objetivos.

Deb (2001) apresenta duas abordagens para solução de problemas de otimização multi-objetivo: a Abordagem Clássica e a Abordagem Geral. A primeira é recomendada quando existe uma preferência relativa pré-definida entre os objetivos de um problema, e consiste em formular uma função-objetivo composta pela soma ponderada dos objetivos. Desse modo, o problema de otimização multi-objetivo se converte em um problema de objetivo único, como esquematizado na Figura 4 (pág. 14) para um problema com dois objetivos a serem minimizados.

Ao utilizar essa abordagem, quando os valores dos objetivos são de grandezas diversas, recomenda-se normalizar esses valores antes da composição da função-objetivo. A normalização é o processo que permite que valores de grandezas não comparáveis entre si sejam convertidos para uma mesma escala, possibilitando a comparação ou agregação desses valores.

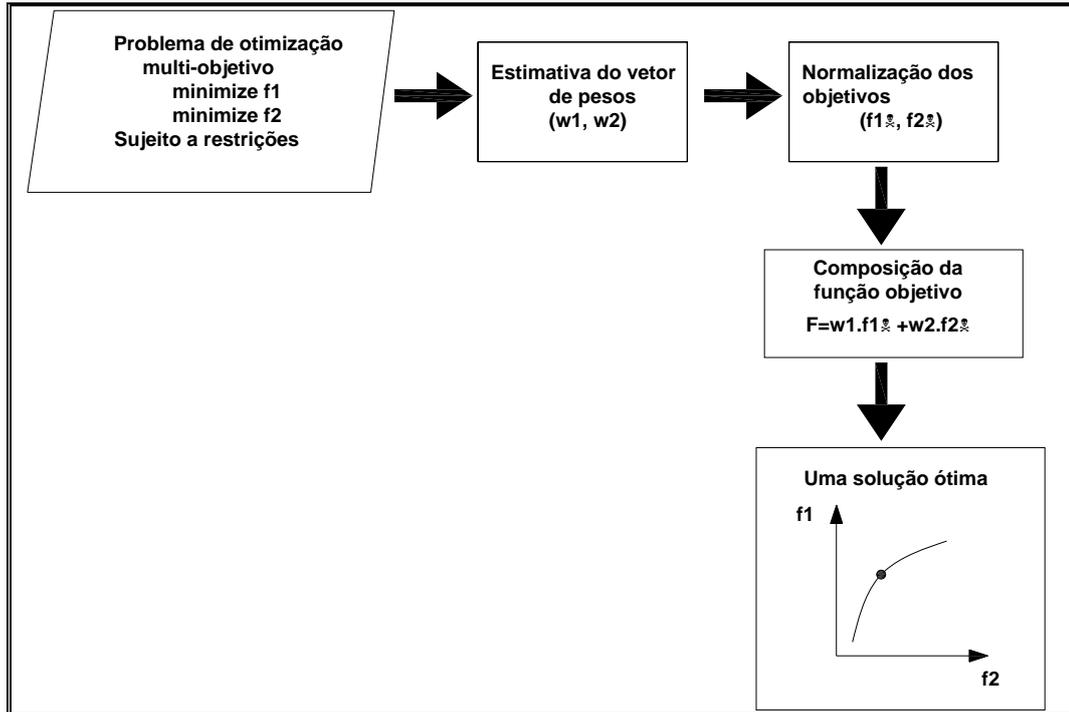


Figura 4 – Otimização multi-objetivo baseada na preferência (Adaptado de DEB, 2001).

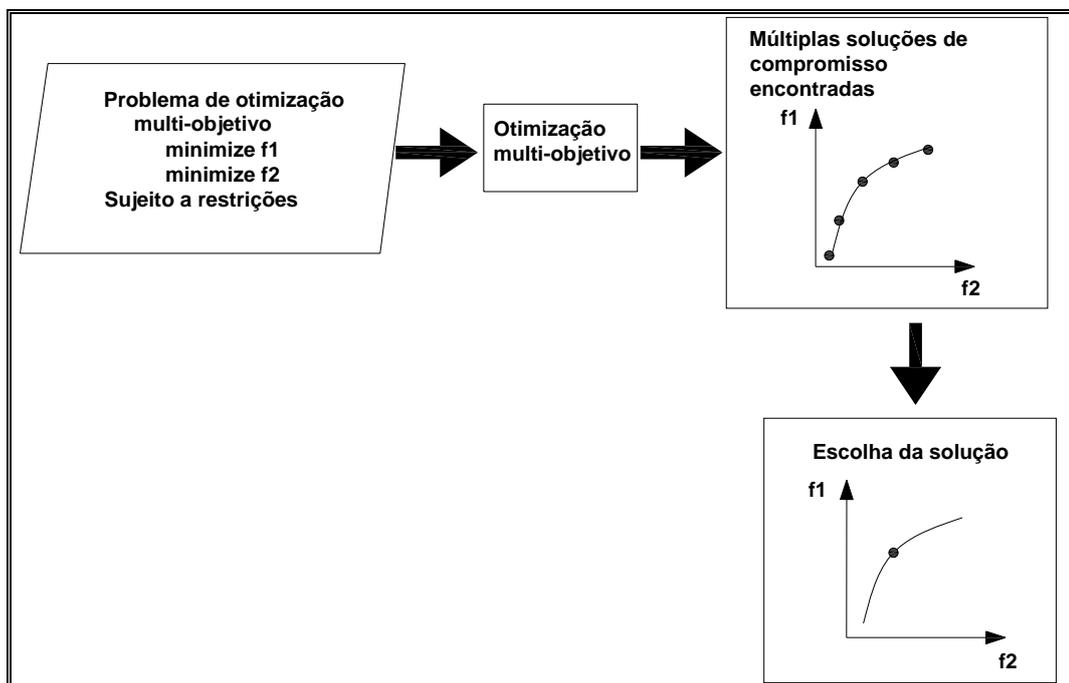


Figura 5 – Otimização multi-objetivo ideal (Adaptado de DEB, 2001).

Quando se deseja diminuir a subjetividade referente à definição dos pesos entre os objetivos, Deb (*op. cit*) recomenda utilizar a Abordagem Geral esquematizada na Figura 5 e denominada ideal. Por essa abordagem um conjunto de soluções de compromisso para todos

os objetivos é encontrado para, só então, serem utilizadas informações adicionais que definirão uma única solução ótima.

### 3.1.2 Dominância e conceitos de Pareto

O conceito de ótimo de Pareto foi formulado pelo mesmo, Vilfredo Pareto, no século XIX (PARETO, 1896 *apud* COELLO, 2000) e tem como definição: “Dado um conjunto de soluções para um problema de otimização multi-objetivo, são denominadas ótimos de Pareto aquelas que, entre si, só é possível melhorar um objetivo causando um detrimento simultâneo em outro, e são melhores que as demais em pelo menos um objetivo”. As soluções que atendem ao conceito de ótimo de Pareto são chamadas não-dominadas e, quando dispostas no espaço de funções-objetivo, definem a fronteira Pareto.

Uma solução  $X_1$  é dita não-dominada por uma solução  $X_2$  quando ela é no mínimo tão boa quanto a solução  $X_2$ , de acordo com todos os objetivos, e  $X_1$  é melhor do que  $X_2$ , de acordo com pelo menos um objetivo ou, matematicamente, quando as seguintes condições são atendidas:  $\{\forall i : FO_i(X_1) \leq FO_i(X_2)\}$  e  $\{\exists j : FO_j(X_1) < FO_j(X_2)\}$ , com  $\leq$  e  $<$  significando, respectivamente, que a solução é “melhor ou igual” e “melhor”.

Em um conjunto de soluções  $P$ , podem ser identificadas as soluções dominadas e as não-dominadas. Um conjunto de soluções não-dominadas  $P^*$  é caracterizado por: quaisquer duas soluções de  $P^*$  são não-dominadas com respeito uma à outra e qualquer solução que não pertença a  $P^*$  é dominada por pelo menos um dos membros de  $P^*$ . Quando a região do conjunto  $P$  representa todo o espaço de busca das soluções factíveis  $V$ , o conjunto de soluções não-dominadas é denominado conjunto ótimo de Pareto. Logo, “o conjunto ótimo de Pareto é o conjunto de todas as soluções não-dominadas do espaço de busca das soluções factíveis”, representado matematicamente por  $P^* = \{X_i \in V \mid \nexists X_j \in V : X_i \text{ é dominado por } X_j\}$  (DEB, 2001).

Em um problema de otimização multi-objetivo, duas metas devem ser atingidas para que o conjunto de soluções não-dominadas encontrado seja considerado satisfatório: que suas soluções estejam tão próximas quanto possível da fronteira de Pareto e que suas soluções sejam tão diversificadas quanto possível. A primeira meta é similar à desejada na otimização

de um único objetivo, a qual se dedica a encontrar o ótimo global do sistema, enquanto que a segunda é específica para otimização multi-objetivo, e é requerida para que seja garantida a diversidade de soluções de compromisso entre todos os objetivos.

### 3.1.3 Métodos de otimização

Os métodos de otimização podem ser classificados de uma maneira geral em métodos de programação linear e de programação não-linear. Os métodos de programação linear exigem que o problema seja representado através de um conjunto de equações lineares, e normalmente não se aplicam aos problemas de engenharia, os quais são geralmente complexos, não-lineares, de difícil representação e descritos por funções nem sempre diferenciáveis (ÁVILA *et al.*, 2003). Os métodos de programação não-linear podem ser classificados em três grupos: Enumerativos, Determinísticos e Estocásticos.

A enumeração completa, também denominada busca exaustiva, é um método enumerativo que consiste em realizar uma varredura completa de todas as soluções possíveis e, portanto, garante que o ótimo global seja sempre encontrado. Apesar da simplicidade, essa metodologia não é recomendável para otimizações de problemas que possuem espaços de busca muito grande, pois podem requerer um tempo inexecutável para avaliar todas as soluções (MICHALEWICZ & FOGEL, 2002).

Embora a busca exaustiva seja um processo determinístico, esse tipo de método se diferencia dos métodos determinísticos propriamente ditos por não utilizar nenhuma heurística durante a sua evolução. Os métodos determinísticos são caracterizados pela busca de soluções no espaço de otimização utilizando geralmente derivadas da função, e têm aplicação mais recomendada em problemas com funções contínuas, convexas e unimodais. O método da subida de encosta (*hill climbing*) é um representante desta classe e, caracteriza-se por investigar os pontos adjacentes do espaço de busca e mover-se na direção que melhora o valor da função-objetivo (COELLO *et al.*, 2002).

Os métodos estocásticos foram desenvolvidos como metodologias alternativas para solução de problemas com espaços de busca complexos, cuja utilização de métodos determinísticos nem sempre se torna eficiente. Essa classe de métodos geralmente geram boas

soluções para a maioria dos problemas de otimização nos quais as buscas determinísticas tradicionais encontram dificuldades (COELLO *et al.*, 2002).

A busca randômica é o exemplo mais simples de uma estratégia estocástica, e consiste basicamente em avaliar um dado número de soluções selecionadas aleatoriamente do espaço de busca. Os algoritmos evolucionários (MICHALEWICZ *et al.*, 1997) também são representantes dessa classe de métodos, os quais são baseados no princípio da evolução natural: sobrevivência do mais forte; e têm como principais representantes as estratégias evolutivas, a programação evolucionária, a programação genética e os algoritmos genéticos.

Independente do tipo de método de otimização escolhido, a formulação utilizada para adaptar esses métodos a uma otimização multi-objetivo pode ser de várias maneiras, onde podem ser destacados os métodos clássicos e os métodos evolucionários. Os métodos clássicos geralmente evitam a complexidade envolvida em um problema multi-objetivo convertendo os vários objetivos em uma única função-objetivo e apresentam como característica comum o fato de encontrar apenas uma solução do conjunto ótimo de Pareto e a exigência de um conhecimento superior do problema para definição do grau de importância de um objetivo sobre o outro. Alguns métodos clássicos encontram dificuldades em encontrar soluções do conjunto ótimo de Pareto em espaços de busca não-convexos. O Quadro 1 mostra alguns métodos clássicos para otimização multi-objetivo descritos em Deb (2001).

Quadro 1 – Métodos clássicos para otimização multi-objetivo (DEB, 2001).

<b>Método</b>	<b>Características</b>
<i>Weighted-sum method</i>	É o método mais simples para otimização com múltiplos objetivos, em que o usuário deve fornecer um conjunto de pesos e fatores para cada objetivo considerado. Em problemas com fronteiras de Pareto convexas, o ótimo encontrado geralmente pertence ao conjunto ótimo de Pareto, no entanto, em problemas com fronteiras não-convexas, o método encontra dificuldades para encontrar uma solução pertencente ao conjunto ótimo de Pareto. Outra desvantagem do método é que todos os objetivos devem ser necessariamente convertidos para um único tipo (minimização ou maximização) e normalizados.
<i><math>\epsilon</math>-constraint method</i>	O objetivo mais relevante é otimizado através de uma função-objetivo simples e os demais objetivos são adicionados em forma de restrições à otimização. Assim, como no método anterior, requer informações adicionais do usuário as quais influenciam fortemente o resultado da otimização. No entanto, apresenta bons resultados em espaços de busca convexas e não-convexas.
<i>Weighted metric method</i>	A característica principal é a otimização de todos os objetivos independentemente. Ao aplicar essa metodologia é necessário normalizar as funções-objetivo quando elas apresentam diferentes ordens de magnitudes, o que requer o conhecimento dos extremos das funções de cada objetivo.
<i>Goal programming method</i>	A idéia principal é encontrar soluções que atinjam uma meta pré-definida para uma função ou um conjunto de funções-objetivo. Cada meta é convertida em pelo menos uma função de igualdade; o objetivo é minimizar as divergências entre as soluções encontradas e a solução esperada.

## 3.2. Algoritmos evolucionários

### 3.2.1 Princípios

Os algoritmos evolucionários baseiam-se no processo de evolução dos seres vivos na busca pela solução ótima. A evolução dos seres vivos se fundamenta no fato que, ao longo das gerações os que são mais aptos em uma população têm uma probabilidade maior de sobreviver e gerar descendentes do que os seres vivos menos aptos, que geralmente são eliminados de modo rápido. Associados ao processo de seleção natural, estão os fenômenos

de recombinação e de mutação, que ocorrem durante o processo de reprodução, atuando sobre o material genético dos cromossomos e garantindo a diversidade das espécies na população.

Em cada iteração, o algoritmo evolucionário utiliza uma população de soluções ao invés de uma única solução. Logo, o resultado de um algoritmo evolucionário também é uma população de soluções, tornando esse algoritmo ideal para ser utilizado em um problema multi-objetivo (DEB, 2001). Outra vantagem dos algoritmos evolucionários sobre os métodos clássicos de otimização multi-objetivo, é que eles são menos suscetíveis à forma ou continuidade da fronteira Pareto ao adaptar-se bem com descontinuidades e concavidades da fronteira (COELLO, 2006).

### 3.2.2 Algoritmos Genéticos

Os algoritmos genéticos (AGs) foram introduzidos por John Holland e popularizados por um dos seus alunos, David Goldberg (HOLLAND, 1975 *apud* GOLDBERG, 1989). Compreende os processos de seleção e genética das populações, em analogia ao princípio de seleção natural e sobrevivência dos mais aptos, declarado em 1859 pelo naturalista e fisiologista inglês Charles Darwin em seu livro “A Origem das Espécies”. São algoritmos computavelmente simples, no entanto, bastante poderosos na otimização, uma vez que promovem uma procura robusta em espaços complexos. Goldberg (1989) definiu robustez em métodos de otimização como o equilíbrio entre a eficiência e a eficácia, necessário para sobrevivência em ambientes diferentes.

Os procedimentos básicos comuns à implementação de qualquer algoritmo genético são (GOLDBERG, 1989): 1) escolha da sistemática de representação das variáveis de decisão; 2) geração de uma população inicial com soluções alternativas para o problema; 3) definição da função-objetivo; 4) especificação dos operadores genéticos para os mecanismos de seleção, recombinação e mutação; e 5) escolha dos parâmetros do AG tais como probabilidades de recombinação e mutação, tamanho da população, condição de finalização e tipo de substituição dos indivíduos pais pelos filhos.

O algoritmo genético original, proposto por Holland, possui um mecanismo extremamente simples, compreendendo fundamentalmente cópias e trocas parciais de cromossomos. Antes de iniciar a otimização, as variáveis de decisão são codificadas na forma

de um cromossomo, geralmente representado por uma cadeia de bits. A população inicial é criada aleatoriamente a partir do espaço de busca, que é a região de todas as possíveis soluções (cromossomos) do problema. Os indivíduos da população inicial são avaliados e ordenados de acordo com o critério de aptidão atribuído através da função-objetivo. Os melhores cromossomos dessa população são selecionados para reprodução e uma cópia destes é alocada em uma população intermediária (*mating pool*).

Para geração da nova população, cromossomos filhos são gerados mediante a recombinação de dois cromossomos da população intermediária (cromossomos pais) através do operador de recombinação (*crossover*). Alguns desses cromossomos filhos (porcentagem muito baixa) são modificados pelo operador de mutação (*mutation*). Em cada geração, novas populações são criadas, produzindo progressivamente descendentes mais aptos, ou seja, com melhores valores de aptidão, até que algum critério de parada seja atingido.

Beasley *et al.* (1993) consideram que um algoritmo de otimização para ser eficiente deve explorar pontos desconhecidos no espaço de busca e utilizar as informações presentes nas soluções já encontradas, sendo essas duas técnicas denominadas respectivamente de *exploration* (exploração) e *exploitation* (prospecção). Os algoritmos genéticos são considerados bons algoritmos de otimização por apresentar possibilidades de implementação dessas duas técnicas através dos operadores genéticos.

Os operadores de seleção caracterizam a técnica *exploitation*, uma vez que dirige a busca em direção aos melhores pontos do espaço. Por sua vez, os operadores de recombinação e mutação exploram pontos desconhecidos do espaço de busca, através da variação nos cromossomos da população (*exploration*). O ideal é que haja um equilíbrio entre essas duas técnicas, pois, algoritmos genéticos com pressão de seleção muito baixa (*i.e.*, quando a aptidão é praticamente a mesma para todos os indivíduos) assumem um comportamento aleatório semelhante aos do método “Gerar e Testar” (muito *exploration*), enquanto que AGs com pressão de seleção muito alta (*i.e.*, presença de super-cromossomos na população), assumem um comportamento muito localizado, semelhante aos métodos de “Subida de encosta” (muito *exploitation*).

Diversos autores destacam as vantagens do algoritmo genético em relação a outros métodos de otimização, principalmente quando o problema a ser otimizado é representado por funções não-lineares ou possui um espaço de busca complexo. Entre essas vantagens se pode citar (GOLDBERG, 1989; LACERDA & CARVALHO, 1999):

- ♣ Realizam buscas simultâneas em várias regiões do espaço de busca, pois trabalham com uma população e não com um único ponto;
- ♣ Utilizam apenas informações da função-objetivo, não requerendo o uso de derivadas ou outro conhecimento auxiliar;
- ♣ Utilizam regras de transição probabilísticas ao invés de determinísticas;
- ♣ Funcionam tanto com parâmetros contínuos como discretos ou uma combinação deles;
- ♣ Otimizam funções-objetivo com superfícies complexas e complicadas, reduzindo a incidência de mínimos locais;
- ♣ São fáceis de serem implementados e adaptam-se bem a computadores paralelos;
- ♣ Possuem flexibilidade quanto aos tipos de função-objetivo;
- ♣ São flexíveis para trabalhar com restrições arbitrárias e otimizar múltiplas funções com objetivos conflitantes;
- ♣ Podem ser hibridizados com outras técnicas de otimização.

Por outro lado, o algoritmo genético possui algumas deficiências que são freqüentemente alvo de críticas, dentre as quais as principais são uma convergência relativamente lenta e certa dificuldade em refinar uma solução que está próxima do ótimo global. Além disso, o desempenho de um algoritmo genético é fortemente influenciado pelos seus parâmetros de controle e, às vezes, o custo computacional pode se tornar elevado, principalmente quando se utiliza variáveis de decisão codificadas em grandes cromossomos, o que exige a análise de populações com muitos indivíduos.

Escolher adequadamente a função de aptidão para os indivíduos, pois nem sempre essa aptidão pode ser tomada como o próprio valor da função-objetivo, e controlar a pressão de seleção do algoritmo genético, evitando a perda de diversidade ao longo das gerações, o que pode causar a convergência prematura, também são precauções a serem tomadas quando da utilização dos algoritmos genéticos em um problema de otimização.

Outra ressalva deve ser feita quando se desejar medir o desempenho de um algoritmo genético, o qual é considerado um método estocástico por combinar mudanças aleatórias com processos probabilísticos, ou seja, dificilmente repete um resultado de um experimento para

outro. Desse modo, o desempenho de um algoritmo genético deve ser avaliado pelo resultado médio de várias execuções do método para um mesmo problema (PACHECO, 1999).

### 3.2.2.1 Representação das soluções

Em um algoritmo genético, cada solução alternativa (cromossomo) para o problema é representada através de uma cadeia de características necessárias à sua completa definição que constituem a variável de decisão do problema (CARRIJO, 2004). Tais características podem ser codificadas de várias formas, dentre as quais, pode-se destacar: a codificação binária, a representação por inteiros e a representação por números reais.

A representação binária é a mais tradicional, sendo de fácil manipulação e utilização. A codificação é feita em sistema binário, utilizando os bits de valor zero ou um. Algumas vezes a variável de decisão pode ser diretamente representada por uma codificação binária, mas certos problemas requerem a conversão da variável de decisão em um cromossomo utilizando a representação binária clássica, que geralmente é feito na base dois. Uma variável de valor 19, por exemplo, possui cromossomo representativo de 10011, pois:  $(1.2^4 + 0.2^3 + 0.2^2 + 0.2^1 + 1.2^0 = 19)$ .

A variação da codificação binária para o código *Gray* (*Gray Code*) foi introduzida no algoritmo genético por Hollstien (1971, *apud* GOLDBERG, 1989) para tentar melhorar o desempenho da otimização, com a singularidade de que variáveis de decisão próximas diferenciam entre si através de uma variação mínima de bits, o que se propõe a aumentar o desempenho do algoritmo.

Quando duas variáveis de decisão subseqüentes são convertidas através da codificação *Gray*, é garantido que apenas um bit irá se modificar entre seus respectivos cromossomos, o que nem sempre ocorre na codificação binária convencional. Um exemplo da diferença entre as codificações binária convencional e *Gray* pode ser facilmente verificado na Tabela 4, onde os números inteiros 7 e 8, representados na codificação convencional pelos cromossomos 0111 e 1000, diferem entre si por quatro bits apesar de serem números seqüenciais, enquanto que, na codificação *Gray*, os respectivos cromossomos desses números (0100 e 1100) diferem entre si por apenas um bit.

Tabela 4 – Exemplo de codificações binária *Gray* e convencional.

Número inteiro	Código binário convencional	Código binário <i>Gray</i>
0	0000	0000
1	0001	0001
2	0010	0011
3	0011	0010
4	0100	0110
5	0101	0111
6	0110	0101
7	<b>0111</b>	<b>0100</b>
8	<b>1000</b>	<b>1100</b>
9	1001	1101
10	1010	1111

Apesar da simplicidade, a codificação binária apresenta alguns pontos fracos alvos de críticas quando o problema requer a conversão de números inteiros em cromossomos binários. Uma dessas deficiências é a necessidade de utilização de cromossomos longos, quando se trabalha com valores altos das variáveis ou quando se deseja uma precisão alta, visto que cada ponto decimal no valor decodificado da variável significa um acréscimo de 3,3 bits no código binário. Outro dado relevante é que a atuação dos operadores não é uniforme, visto que os primeiros bits do gene são consideravelmente mais significativos do que os últimos bits. A representação em inteiros ou reais, por sua vez, caracteriza-se pela utilização de cromossomos menores e é compreendida mais naturalmente pelo ser humano do que a cadeia de bits (LACERDA & CARVALHO, 1999).

A utilização da representação em inteiros ou em números reais requer a utilização de operadores genéticos específicos, uma vez que estes passarão a atuar sobre o parâmetro como um todo, e não apenas em uma parte deles, como feito na troca de bits. No entanto, existe certa facilidade em se criar esses operadores os quais são geralmente aritméticos. Os diversos operadores são ponderados para se determinar quantos filhos cada um vai produzir, e a mutação atua como um operador independente, gerando seus próprios filhos, porém com uma porcentagem muito baixa de descendentes com relação ao restante da população.

### 3.2.2.2 *População inicial e substituição das populações*

A população inicial em um processo de otimização utilizando algoritmos genéticos pode ser gerada de várias maneiras. A geração aleatória é a mais tradicionalmente utilizada, mas outros tipos de gerações podem ser empregadas com o propósito de diversificar a população

inicial e representar pontos em todo o espaço de busca. Uma das formas alternativas para geração da população inicial consiste em gerar metade dos indivíduos de forma aleatória e compor a outra metade pela inversão dos bits dos cromossomos gerados aleatoriamente. A geração uniforme também pode ser utilizada, criando pontos igualmente espaçados no espaço de busca.

Independente do tipo de geração da população inicial, algumas técnicas podem ser utilizadas para melhorar a representação do espaço de busca, como a geração de uma população inicial maior do que as populações das próximas gerações ou a inserção de boas soluções na população inicial, técnica denominada de *seeding*.

Os algoritmos genéticos também podem ser classificados de acordo com a evolução do processo iterativo na produção das populações subseqüentes, em Substituição geracional e *Steady-State*. Na primeira, os indivíduos filhos são criados em número suficiente para substituir toda a população anterior, ou seja, são criados  $N$  filhos para substituir  $N$  pais. Algumas variações podem ser aplicadas na substituição geracional, como selecionar para a população atual os  $N$  melhores indivíduos da união dos indivíduos filhos com os indivíduos pais, ou a utilização do elitismo, um processo que consiste na transferência sem alteração dos melhores cromossomos, em um número pré-determinado, de uma geração para outra. O principal objetivo do elitismo é evitar a perda de uma solução ótima já encontrada, bem como garantir a preservação da carga genética benéfica na população e tornar a convergência mais rápida.

Na substituição *Steady-State*, poucos membros da população são substituídos em cada iteração, uma vez que um número reduzido de filhos é gerado (geralmente um ou dois) para substituir os piores pais. Alternativamente, os filhos gerados podem substituir, ao invés dos piores pais, os seus próprios pais ou os cromossomos pais mais velhos. A substituição *Steady-State* permite poucas variações dos indivíduos entre as gerações, portanto, pode tornar a convergência mais lenta devido a pouca exploração do espaço de busca em cada ciclo.

### **3.2.2.3 Função-objetivo e aptidão**

A função-objetivo relaciona o código representativo de uma solução com a qualidade dessa solução para o problema em análise. A aptidão é o critério fornecido pela função-objetivo que permite avaliar e ordenar as soluções para seu uso posterior pelos operadores de seleção e reprodução. De um modo geral pode-se considerar o valor da função-objetivo como

a aptidão da solução, mas nem sempre essa simplificação é adequada, pois muitas vezes a função-objetivo fornece valores negativos (não aplicável em alguns métodos de seleção), valores muito próximos (o que pode tornar a seleção para reprodução muito aleatória) ou valores de grandezas altamente diversificadas (o que pode causar a convergência prematura da otimização).

Nesses casos, e quando o método de seleção associar a probabilidade de seleção do indivíduo à sua aptidão, é recomendável realizar o mapeamento da função-objetivo, convertendo-a em valores de aptidão mais facilmente trabalháveis. O método do ordenamento linear (BAKER, 1987, *apud* LACERDA & CARVALHO, 1999) é uma metodologia utilizável para essa prática, na qual a aptidão é dada pela Equação 1.

$$F_{\ell} = Min + (Max - Min) \frac{q - \ell}{q - 1} \quad \text{Equação 1}$$

onde:

$\ell$  é o índice do cromossomo na população em ordem decrescente de valor da função-objetivo;

$Max$  e  $Min$  são constantes definidas pelo usuário;

$q$  é o número de indivíduos da população.

Normalmente são utilizados valores de  $Max$  e  $Min$  que atendam às relações:  $1 \leq Max \leq 2$  e  $Max + Min = 2$ . Pois, dessa forma, a aptidão passa a representar o número de filhos esperados do cromossomo e o valor  $(Max - Min)$  a representar a pressão de seleção do algoritmo, dada pela razão entre a maior aptidão e a aptidão média dos indivíduos da população (LACERDA & CARVALHO, 1999).

#### 3.2.2.4 Operador de seleção

O processo de seleção ocorre após a avaliação da função-objetivo e o cálculo das aptidões das soluções, e atua selecionando cromossomos da população de pais e alocando-os em uma população intermediária (*mating pool*), geralmente de dimensão inferior à população do algoritmo, de onde serão extraídos os pares de cromossomos para a reprodução.

Os métodos de seleção podem ser diferenciados entre si através da sua pressão de seleção, que é a relação entre a probabilidade do melhor indivíduo ser selecionado e a

probabilidade média de seleção dos indivíduos, e pela sua perda de diversidade, que é a proporção de indivíduos de uma população que não são selecionados durante esse processo. De um modo geral, métodos com uma pressão de seleção muito alta podem ocasionar a perda de diversidade, por dificultar a reprodução de indivíduos de baixa aptidão. A perda de diversidade, por sua vez, pode induzir a uma convergência prematura, pois o algoritmo terá dificuldade de sair de um ótimo local por não conseguir percorrer suficientemente o espaço de busca. Desse modo, um bom método de seleção deve possibilitar que cromossomos pais com melhores aptidões tenham maiores chances de serem selecionados, objetivando gerar descendentes mais aptos, sem, contudo, bloquear a seleção dos menos aptos.

A Roda da Roleta é o operador de seleção proposto originalmente por Holland e consiste basicamente em atribuir uma probabilidade de seleção para cada cromossomo proporcional à sua aptidão. Cada indivíduo é disposto em uma roleta dividida em fatias que representam, cada uma, a sua probabilidade de seleção. Em cada giro da roleta, o ponteiro indica o indivíduo a ser selecionado, logo, sendo necessários  $N$  giros para compor uma população intermediária de  $N$  indivíduos.

Baker (1987, *apud* LACERDA & CARVALHO, 1999) tentou solucionar o problema da grande variação do número esperado de filhos entre os indivíduos pais, que geralmente ocorre no método da Roda da Roleta, e propôs o método da Amostragem Estocástica Universal ou método SUS (*Stochastic Universal Sampling*). Por esse método, ao invés de um único ponteiro, a roleta possui  $N$  ponteiros igualmente espaçados, e a seleção é realizada através de um único giro da roleta, permitindo, portanto, que indivíduos menos aptos sejam selecionados.

A Figura 6 mostra um exemplo da aplicação do método SUS em que o número de seleção de um mesmo indivíduo é limitado e é permitida a seleção do indivíduo “E”, menos apto. Diferentemente do método da Roda da Roleta, em que, caso fosse aplicado na mesma população, com um único ponteiro e cinco giros, o indivíduo “A” teria grandes chances de ser selecionado várias vezes.

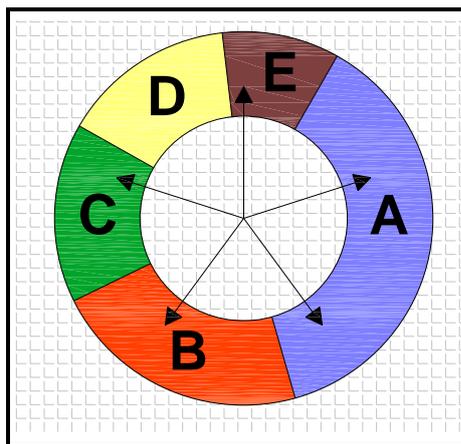


Figura 6 – Esquema do método de seleção SUS.

Outro método de seleção é o Torneio, em que um número pré-determinado de cromossomos pais (geralmente 2 ou 3) é escolhido aleatoriamente com probabilidades iguais, e estes cromossomos são comparados entre si e aquele que tiver melhor aptidão será selecionado para a população intermediária. Desse modo, o número de torneios será igual ao número de indivíduos desejados para a população intermediária. Segundo Carter (2002), esse tipo de seleção possui a vantagem de possuir implementação extremamente simples, eficiente e flexível quanto às pressões de seleção aplicadas. Lacerda e Carvalho (1999) destacam ainda que a utilização desse método não requer o ordenamento da população e nem o escalonamento da aptidão e Goldberg e Deb (1991) consideraram-no um dos métodos que requer menor tempo computacional e é facilmente paralelizável.

### ***3.2.2.5 Operadores de reprodução***

#### **Operador de recombinação para codificação binária**

Recombinação, cruzamento ou *crossover* é a operação aplicada a um par de cromossomos retirados aleatoriamente da população intermediária com o objetivo de gerar cromossomos filhos oriundos da recombinação dos pais. O operador tradicional de recombinação denominado, de cruzamento de um ponto, é realizado através da simples permuta dos cromossomos, ou seja, cada uma das cadeias de bits dos cromossomos pais são cortados em uma posição aleatória originando duas cabeças e duas caudas. A troca das caudas dos cromossomos pais caracteriza a criação dos cromossomos filhos, como esquematizado na

Figura 7. Para cada operação de cruzamento, é gerado um número aleatório entre 0 e 1 e caso o número seja inferior à probabilidade de cruzamento ( $P_c$ ) previamente definida, a operação é efetivada; caso contrário, o par de pais selecionado será copiado para a nova população.

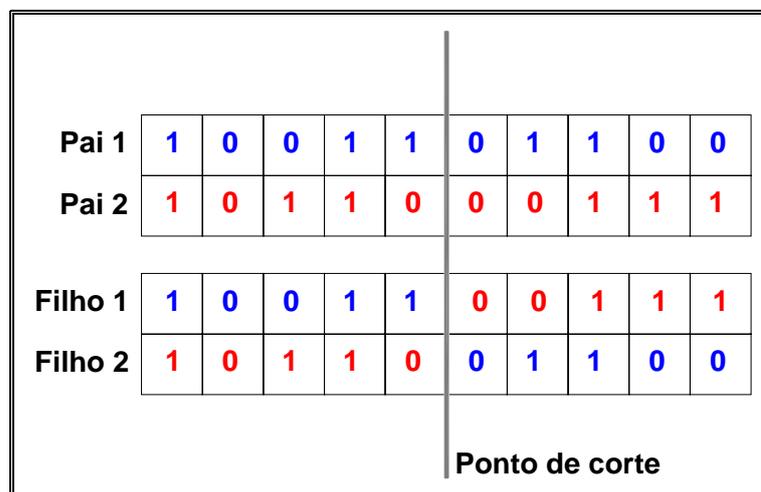


Figura 7 – Esquema do operador de cruzamento de um ponto.

Outras formas diferentes da tradicional podem ser utilizadas para realizar a recombinação. Mais de um ponto de corte podem ser escolhidos caracterizando a operação de cruzamento de múltiplos pontos. No cruzamento de dois pontos, por exemplo, os caracteres entre duas posições escolhidas aleatoriamente são trocados.

O cruzamento uniforme apresenta a particularidade de atuar nos genes individuais dos cromossomos, ao invés de atuar em conjuntos de bits. Consiste em gerar uma máscara de bits para o par de pais selecionado, e copiar para o primeiro filho os bits do primeiro pai de todas as posições em que a máscara de bit for 1, e os bits do segundo pai de todas as posições em que a máscara de bits for 0 (Figura 8). O segundo filho é gerado através da inversão do procedimento, ou seja, copia-se os bits do segundo pai nas posições em que a máscara de bits for 1 e vice-versa.

É sabido que o cruzamento de múltiplos pontos, bem como o cruzamento uniforme, introduz uma variação maior entre os cromossomos pais e filhos, mas, segundo Eshelman *et al.* (1989, *apud* BEASLEY *et al.*, 1993a) o desempenho entre os vários tipos de cruzamento é pouco variável.

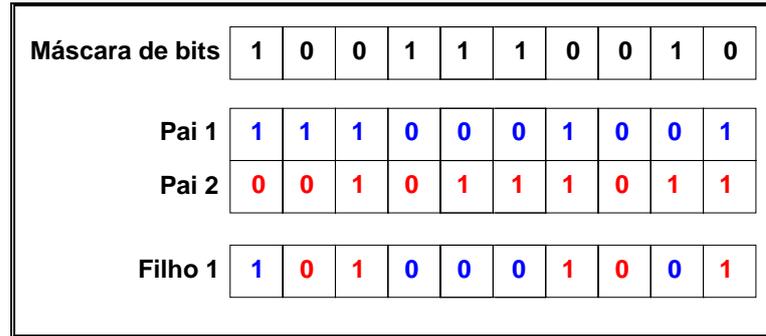


Figura 8 – Esquema do operador de cruzamento uniforme.

### Mutação para codificação binária

Mutação é o operador que possibilita a introdução de características genéticas novas às soluções existentes, através da ocasional inversão dos bits dos indivíduos (Figura 9). É aplicada após o operador de cruzamento com o objetivo de explorar novas regiões do espaço de busca e prevenir a perda de diversidade. A mutação mais tradicionalmente utilizada consiste em gerar um número aleatório entre zero e um, para cada bit do cromossomo avaliado, e inverter os valores dos bits cujos números gerados forem inferiores à probabilidade de mutação definida –  $P_m$ .

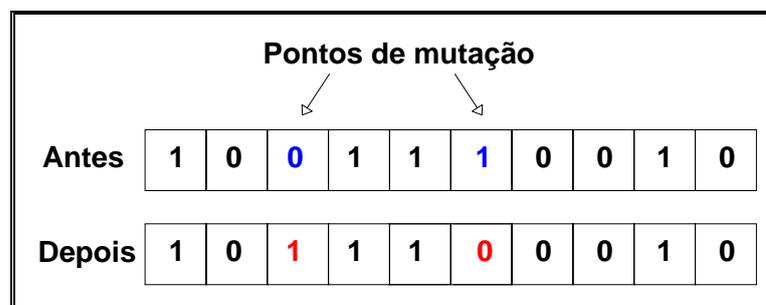


Figura 9 – Esquema do operador de mutação.

#### 3.2.2.6 Convergência do algoritmo

Após a aplicação dos operadores genéticos, uma nova população é gerada e o ciclo se repete iterativamente até que um critério de parada seja satisfeito. Alguns critérios comumente utilizados para indicar a convergência do algoritmo genético são: 1) quando um número pré-determinado de gerações for atingido; 2) quando a maioria dos cromossomos da população

corrente é idêntica ou apresenta variação desprezível; 3) quando não ocorrer melhoras significativas no melhor cromossomo em um determinado número de gerações consecutivas; 4) quando se atingir um determinado valor da função-objetivo, previamente definido; e 5) quando se atingir um determinado tempo de otimização, também previamente definido.

Alguns problemas podem surgir durante a otimização por algoritmos genéticos e que influenciam a convergência do algoritmo, dentre eles, os mais significantes são a convergência prematura e a convergência lenta. A convergência prematura pode ocorrer devido ao surgimento de super-indivíduos na população, os quais geram um número excessivo de filhos, dominando toda a população. Como alternativas para minimizar esse efeito, recomenda-se limitar o número de filhos por indivíduo, evitar que filhos duplicados sejam inseridos na população, ou aumentar a probabilidade de mutação.

A convergência lenta ocorre geralmente quando os valores de aptidão são pouco variáveis entre os indivíduos da população, tornando o algoritmo predominantemente aleatório. Para evitar esse problema, recomenda-se expandir o intervalo de aptidão através do ordenamento ou mapeamento da função-objetivo.

### ***3.2.2.7 Parâmetros de controle***

Um dos desafios para a utilização do algoritmo genético é a adequada escolha dos seus parâmetros de controle. Um algoritmo genético tradicional requer, no mínimo, a definição dos seguintes parâmetros: Probabilidade de cruzamento –  $P_c$ , Probabilidade de Mutação –  $P_m$  e a dimensão da população. Os parâmetros de controle afetam significativamente o desempenho do algoritmo genético. Barcellos (2000), por exemplo, testou o desempenho de um AG para várias probabilidades de mutação em um problema de obtenção de raízes e do caixeiro viajante<sup>1</sup> e obteve variações em torno de 200% no desempenho.

O trabalho de de Jong (1975, *apud* EIBEN *et al.*, 1999) foi um dos pioneiros no estudo dos melhores parâmetros de controle para um algoritmo genético. Utilizando-se cinco funções de teste para comparação do desempenho de um AG tradicional com cruzamento de um ponto e com mutação bit a bit, seus resultados sugeriram um tamanho de população de 50 indivíduos, uma probabilidade de cruzamento de 0,60 e uma probabilidade de mutação de 0,001. Grenfestette (1986, *apud* EIBEN *et al.*, 1999) utilizou o Meta-Algoritmo Genético, que

---

<sup>1</sup> O problema do caixeiro viajante consiste em, dado uma lista de cidades a serem visitadas, determinar o caminho mais curto que o vendedor deve seguir, começando em uma cidade e terminando na mesma cidade.

é um algoritmo genético especialmente desenvolvido para otimizar os parâmetros de controle de um outro AG, e sugeriu os seguintes parâmetros:  $P_m = 0,01$ ,  $P_c = 0,95$  e população de 30 indivíduos. Ambos os trabalhos citados recomendam o uso do elitismo e uma substituição geracional de 100%. Schaffer *et al.* (1989, *apud* EIBEN *et al.*, 1999) realizaram extenso trabalho sobre parâmetros de algoritmos genéticos e recomendam a utilização de  $P_c$  entre 0,75 e 0,95; de  $P_m$  entre 0,005 e 0,01 e uma população com dimensão entre 20 e 30 indivíduos.

Alguns autores recomendam a variação dos parâmetros de controle em função da dimensão do cromossomo. Os estudos teóricos clássicos realizados por Goldberg (1989) sugerem uma equação em que o tamanho da população cresce exponencialmente com a quantidade de bits do cromossomo ( $Pop = 1,65.2^{(0,21.bits)}$ ), o que frequentemente resulta em populações com grandes dimensões e um alto custo computacional requerido. No entanto, Alander (1992), através de estudos empíricos, encontrou bons resultados em otimizações de problemas complexos com populações com dimensões entre uma e duas vezes o número de bits do cromossomo.

Uma vez definida a dimensão da população e do cromossomo, a probabilidade de mutação pode ser limitada, segundo Goldberg e Koza (1990, *apud* SIMPSON *et al.*, 1994), no mínimo igual ao inverso do número de indivíduos da população e, no máximo, igual ao inverso do número de bits do cromossomo.

### **3.2.3 Algoritmos Evolucionários para Otimização Multi-objetivo**

#### **3.2.3.1 Breve Histórico**

Os algoritmos evolucionários são muito populares para otimização de um único objetivo, e, devido às inúmeras vantagens oferecidas, recentemente têm sido desenvolvidos algoritmos evolucionários específicos para a otimização de múltiplos objetivos. Os primeiros métodos desenvolvidos para essa finalidade não consideravam o conceito de dominância de Pareto e forneciam uma única solução, ao invés de um conjunto de soluções de compromisso.

Um dos pioneiros no desenvolvimento de um algoritmo evolucionário multi-objetivo (*Multi-objective evolutionary algorithm* – MOEA) foi Schaffer (1984), que desenvolveu o VEGA - *Vector evaluated genetic algorithm*; logo em seguida, Kursave (1990) apresentou o

VOES - *Vector optimized evolution strategy* e, já na década de 1990, Hajela e Lin (1992) utilizaram um método que aplicava pesos variáveis às funções-objetivo, denominado de WBGA - *Weighted based genetic algorithm* (DEB, 2001).

O VEGA é uma extensão do algoritmo genético tradicional proposto por Holland, diferindo apenas no modo como o operador de seleção é implementado, sendo a simplicidade uma de suas principais vantagens. Utiliza sub-populações para otimizar cada objetivo separadamente, sendo que cada solução é avaliada por uma única função-objetivo. O operador de cruzamento é designado para combinar as melhores soluções individuais na tentativa de encontrar soluções próximas da região ótima de Pareto, mas nem sempre isso ocorre e, eventualmente, o método converge para a melhor solução individual de um dos objetivos.

O VOES possui um mecanismo para reter as soluções não-dominadas e um mecanismo para excluir as soluções excedentes, as quais são escolhidas principalmente considerando o critério de proximidade entre as soluções. Devido à necessidade de se utilizar cromossomos diplóides, contendo um cromossomo dominante e um recessivo, o VOES foi pouco utilizado entre os pesquisadores, de modo que sua eficiência em problemas complexos não foi avaliada. O WBGA possui como vantagem a sua simplicidade mas, como em outros métodos baseados em pesos, pode não encontrar soluções ótimas em espaços de busca não-convexos, além de requerer a conversão de problemas de minimização para maximização e apresentar dificuldades ao construir uma função de aptidão para problemas de minimização e maximização simultâneos.

A utilização dos conceitos de Pareto na otimização multi-objetivo foi sugerida inicialmente por Goldberg (1989), que recomendava utilizar um procedimento de ranqueamento dos indivíduos com base na informação de dominância. Cada indivíduo não-dominado deveria ser removido da população e receber um *ranking* 1; dos que restavam, os novos indivíduos não-dominados recebiam *ranking* 2 e também eram removidos. Este processo se sucedia até que todos os indivíduos recebessem seu *ranking*, o qual serviria de base para o operador de seleção, que atribui uma probabilidade de seleção tanto maior quanto menor o valor do *ranking*. Goldberg ressaltou ainda a necessidade de utilizar algum mecanismo de compartilhamento da aptidão (*fitness sharing*) para manter uma diversidade apropriada nas soluções.

Apesar de não ter desenvolvido propriamente um MOEA, na década de 1990, muitos autores utilizaram as idéias de Goldberg no desenvolvimento de novos métodos evolucionários para o problema da otimização multi-objetivo, o que caracteriza uma geração

denominada por alguns autores (ZITZLER, 2001) de algoritmos evolucionários multi-objetivo clássicos e, por outros (DEB, 2001), de algoritmos evolucionários multi-objetivo não-elitistas. Os MOEAs clássicos foram desenvolvidos na década de 1990 e apresentam como características em comum a ênfase na simplicidade, a consideração dos conceitos de não-dominância de Pareto, a introdução de alguns mecanismos de compartilhamento da aptidão e a não utilização de qualquer forma de elitismo nas suas gerações.

O *Multiple objective genetic algorithm* – MOGA (FONSECA & FLEMING, 1993) foi um dos primeiros métodos dessa geração, e baseia-se nos conceitos introduzidos por Goldberg. Nesta concepção, é atribuído um *ranking* a todos os indivíduos correspondente ao número de indivíduos que o dominam, acrescido de um. Dessa forma, todos os indivíduos não-dominados possuem *ranking* mínimo de 1, cujo valor máximo do *ranking* de um indivíduo é igual ao tamanho da população. Depois de ordenada a população, uma aptidão preliminar (*raw fitness*) é atribuída utilizando uma função linear para mapear a função-objetivo. Com o objetivo de manter a diversidade das soluções, para cada nicho formado por um valor do *ranking*, é calculado o valor médio da aptidão das soluções que o compõem. Os demais operadores são semelhantes aos utilizados em um algoritmo genético simples, com seleção pelo método SUS, cruzamento de 1 ponto e mutação bit a bit.

O MOGA mostra-se falho ao não considerar que todas as soluções de uma fronteira não-dominada tenham a mesma aptidão e, por isso, não garante que a solução de ordenamento menor seja sempre pior do que uma solução de ordenamento maior. Além disso, devido à alta pressão de seleção pode causar convergência prematura (DEB, 2001).

O *Non-dominated sorting genetic algorithm* – NSGA (SRINIVAS & DEB) é similar ao MOGA diferindo na maneira como classifica os vetores solução, pois, nesse método as soluções são subdivididas em classes, e todas as soluções não-dominadas de uma mesma classe recebem a mesma aptidão. O operador de seleção por ordenamento, em conjunto com um procedimento voltado para a criação de nichos, garante a diversidade da população.

Horn *et al.* (1994) propuseram o *Niched-Pareto genetic algorithm* (NPGA), que difere dos métodos anteriores devido à não necessidade de calcular um valor de aptidão que priorize soluções não-dominadas, pois o conceito de dominância é introduzido no operador de seleção, denominado de Torneio de Pareto. Dois indivíduos são escolhidos aleatoriamente e comparados com um sub-conjunto da população (geralmente 10% do conjunto total): se por um lado um dos indivíduos selecionados dominarem o sub-conjunto e o outro não, o indivíduo não-dominado é o campeão do torneio; por outro, se ambos os indivíduos

selecionados forem dominados ou não-dominados pelo sub-conjunto, utiliza-se um contador de nicho para escolher a solução vencedora. A vantagem do NPGA é a não necessidade de utilizar um cálculo explícito para a função de aptidão e a complexidade não ser proporcional ao número de objetivos. A desvantagem é a introdução de novos parâmetros a serem configurados e a influência desses parâmetros nas soluções encontradas.

Segundo Coello (2006), durante a primeira geração de MOEAs, diversos autores compararam o desempenho entre os métodos, sendo demonstrada a superioridade do método MOGA, seguido pelo NPGA e, em terceiro lugar o NSGA, que são os principais representantes dessa geração. Ainda segundo o autor, o principal ganho obtido nessa época foi o reconhecimento de que o sucesso de um MOEA depende da combinação de dois fatores: de um bom mecanismo de seleção dos indivíduos não-dominados, baseados no conceito de ótimo de Pareto, e da utilização de um bom mecanismo para manter a diversidade das soluções.

A segunda geração de MOEAs encontrou como desafio tornar os algoritmos mais eficientes sem perder o desempenho já conseguido com os métodos anteriores. Os métodos dessa geração possuem como características comuns a ênfase na eficiência e a utilização de alguma técnica elitista.

Apesar de outros autores terem introduzido anteriormente o conceito do elitismo em MOEAs, como por exemplo, Osyczka e Kundu (1995, *apud* DEB, 2001) com o *Distance based Pareto genetic algorithm* – DPGA, a literatura de um modo geral destaca o trabalho de Zitzler e Thiele (1998) como um dos pioneiros da segunda geração, sendo o método desenvolvido por eles, o *Strength Pareto evolutionary algorithm* – SPEA, considerado um dos mais representativos dessa geração.

O SPEA une potencialidades de diversos algoritmos em um único e é caracterizado pela manutenção de uma população externa que armazena as soluções não-dominadas encontradas. A cada geração, novas soluções são comparadas com as existentes na população externa e o conjunto de soluções não-dominadas são preservadas. Essa população de elite é utilizada para avaliar a aptidão dos indivíduos baseada no critério de dominância de Pareto, e participa, junto com a população corrente, das operações genéticas.

A aptidão no SPEA é similar ao procedimento de ranqueamento utilizado no MOGA, baseada no número de soluções não-dominadas, e é determinada entre as populações externa e corrente, dessa forma, compartilhando uma desvantagem com o MOGA, no qual o valor da aptidão não garante que todas as soluções não-dominadas sejam ranqueadas igualmente. A

diversidade das soluções no SPEA é considerada quando a população externa atinge a dimensão máxima, e é aplicado um algoritmo de agrupamento (*Clustering method*) para eliminar as soluções excedentes dessa população sem destruir as características de diversidade da fronteira. Uma vantagem do SPEA é a de que o método não requer a introdução de qualquer parâmetro de distância, no entanto introduz um parâmetro extra, o tamanho da população externa, cuja dimensão influencia o desempenho do método.

Zitzler *et al.* (2000) compararam o desempenho de oito métodos aplicados a seis funções de testes. Foram utilizados, nessa análise, seis MOEAs conhecidos na época: os pioneiros, VEGA e WBGA (denominado pelos autores de FFGA – *Fonseca and Flemming's multi-objective GA*); alguns representantes da primeira geração, MOGA (denominado pelos autores de HLGA – *Hajela and Lin's genetic algorithm*), NPGA e NSGA; e o SPEA; único representante da segunda geração. Acrescentaram, ainda, à análise uma estratégia de busca randômica, denominada de RAND e um algoritmo genético que agrega as funções em um único objetivo, denominado de *Single-objective evolutionary algorithm* – SOEA.

Os resultados mostraram a superioridade do desempenho do SPEA em relação aos demais métodos em todas as funções de teste, mostrando ainda que: 1) qualquer MOEA é melhor do que o procedimento de busca randômica; 2) os métodos MOGA, NPGA e WBGA, assim como o RAND, têm dificuldades em manter uma diversidade das soluções encontradas; e 3) entre os métodos não-elitistas, o NSGA apresentou o melhor desempenho. Em uma nova bateria de experimentos, os autores inseriram o mecanismo de elitismo utilizado no SPEA nos métodos VEGA, WBGA, NPGA, MOGA e NSGA, e observaram que a introdução do elitismo melhora significativamente o desempenho dos métodos, e que o método NSGA, na versão elitista, possui desempenho equivalente ao SPEA. Esse fato representa um marco entre a primeira e a segunda geração de métodos evolucionários multi-objetivo, a partir do qual foram desenvolvidos outros métodos elitistas.

A maioria dos métodos da segunda geração introduz o elitismo através de uma população externa, também chamada de arquivo de elite, que retém as soluções não-dominadas já encontradas, como o *Pareto archives evolution strategy* – PAES (KNOWLES & CORNE, 2000) e o *Pareto envelope-based selection algorithm* – PESA (CORNE *et al.*, 2000). O PAES utiliza um *grid* adaptativo para manter a diversidade das soluções e o PESA utiliza um mecanismo de seleção baseado numa medida de agrupamento que decide quais soluções serão introduzidas na população externa. No entanto, alguns autores introduziram o

elitismo de outra forma na evolução sendo o principal representante dessa categoria o *Elitist non-dominated sorting genetic algorithm* – NSGA-II (DEB *et al.*, 2002).

O NSGA-II é uma versão melhorada do método NSGA, o qual se torna mais eficiente que seu antecessor principalmente devido à introdução do elitismo, que não permite apagar uma solução ótima de Pareto já encontrada; e, à utilização de um procedimento de comparação utilizado na seleção por torneio e durante a fase de redução da população, que garante a diversidade entre as soluções não-dominadas.

Deb *et al.* (2002) compararam o desempenho do NSGA-II com o SPEA e o PAES para nove problemas de testes da literatura. Os resultados experimentais mostram que o NSGA-II converge melhor em sete das nove funções testadas, sendo que, nas outras duas, o PAES obteve os melhores resultados. No critério de diversidade o NSGA-II obteve um desempenho melhor nas nove funções de teste, sendo o pior desempenho atribuído ao PAES.

Em 2001, Zitzler e outros autores apresentaram o *Strength Pareto Evolutionary Algorithm 2* – SPEA2 (ZITZLER *et al.*, 2001), que foi desenvolvido para tentar eliminar as restrições existentes no método antecessor e melhorar a eficiência do algoritmo. As três diferenças principais do SPEA2 para o SPEA são: 1) uma estratégia de atribuição da aptidão que considera para cada indivíduo, tanto o número de soluções que o dominam quanto o número de soluções dominadas por ele; 2) a utilização de uma técnica de estimativa da densidade da vizinhança incorporada à aptidão dos indivíduos permitindo uma guia mais precisa no espaço de busca; e 3) a substituição do algoritmo de agrupamento por um método alternativo de truncamento, o qual possui características semelhantes, mas preserva as soluções extremas.

O desempenho do SPEA-II foi comparado com o do seu antecessor, SPEA, e com mais dois métodos da segunda geração, PESA e NSGA-II em cinco funções de testes freqüentemente utilizadas na literatura (ZITZLER *et al.*, *op. cit.*). Os autores concluíram que: 1) em todas as funções de testes, o SPEA2 foi superior ao SPEA; 2) o PESA apresentou uma rápida convergência, provavelmente devido à alta intensidade do elitismo, mas falhou para algumas funções de teste por não manter as soluções da fronteira; 3) o SPEA2 e o NSGA-II mostraram os melhores desempenhos; e 4) quando o número de funções-objetivo aumentou, o SPEA2 apresentou algumas vantagens sobre o PESA e o NSGA-II.

Uma vez convencidos da eficácia dos MOEAs, ou seja, da sua capacidade de encontrar soluções ótimas, os pesquisadores têm concentrado esforços no aumento da sua eficiência, ou

seja, na rapidez com que encontra essas soluções (VELDHUIZEN *et al.*, 2003). Segundo Lücken *et al.* (2004), apesar de os MOEAs terem demonstrado eficácia em espaços de busca complexos, encontrando boa aproximação da fronteira Pareto em problemas multi-objetivo, os mesmos não garantem que o ótimo global seja encontrado em uma única execução, logo, para obter um bom conjunto de soluções, o usual é realizar várias execuções de um dado MOEA e combinar seus resultados. Esse contexto naturalmente conduz à paralelização dos MOEAs, que contribuirá para a expansão do número de indivíduos analisados no espaço de busca e possivelmente aumentará a velocidade de convergência dos algoritmos para a fronteira Pareto em menos execuções.

De acordo com Veldhuizen *et al.* (2003), a paralelização de um MOEA (*Parallel multi-objective evolutionary algorithm* – pMOEA) não é uma tarefa simples, pois envolve a análise de vários paradigmas de paralelização, a associação de parâmetros e a utilização de novos conceitos, como migração, substituição e esquemas de agrupamento. No trabalho citado, os autores conduzem a uma ampla discussão do estado da arte da paralelização de MOEAs, com definição das notações específicas, e discussão dos paradigmas e processos necessários para criar um pMOEA eficaz e eficiente.

Nessa conjuntura, Xiong e Li (2003) apresentam o *Parallel strength Pareto multi-objective evolutionary algorithm* (PSPMEA), o qual se baseia no SPEA2 e utiliza sub-populações que evoluem separadamente, com diferentes probabilidades de cruzamento e mutação, mas que permutam seus indivíduos em uma estratégia elitista. Em adição aos parâmetros e processos usuais do SPEA2, o PSPMEA utiliza o operador de migração, caracterizado por uma frequência de migração e pela quantidade de indivíduos migrados entre as populações. O desempenho entre esses dois métodos foi comparado para as mesmas funções de testes utilizadas em Zitzler *et al.* (2000) e, a análise concluiu que a presença do elitismo em sub-populações torna a eficiência do PSPMEA melhor do que a do SPEA2, o que permite reduzir o seu tempo de execução.

### **3.2.3.2 Métricas de desempenho**

Comparar o desempenho entre métodos evolucionários multi-objetivo não é tão simples como em uma otimização de um único objetivo, que compara unicamente o valor da função-objetivo considerada. Essa complexidade, associada ao surgimento de inúmeros métodos em

um curto espaço de tempo, levou os pesquisadores a buscarem meios de comparar os diferentes métodos e testar a qualidade entre eles.

As duas principais metas que se deseja atingir em um MOEA são (DEB, 2001) encontrar soluções tão próximas quanto possível da fronteira Pareto, e que essas soluções sejam tão diversas quanto possível. Zitzler *et al.* (2000) apresentam essas metas da seguinte maneira: 1) maximizar o número de soluções da fronteira Pareto encontradas; 2) minimizar a distância da fronteira de soluções não-dominadas encontrada para a fronteira Pareto; e 3) maximizar a diversidade das soluções encontradas.

Algumas métricas utilizadas para avaliar o desempenho entre os MOEAs podem ser classificadas como Métricas de convergência que avaliam quão próximo as soluções encontradas estão da fronteira Pareto. Essas métricas requerem o conhecimento prévio da fronteira Pareto, o que nem sempre é possível para aplicações em problemas reais. As métricas da taxa de erro e da distância geracional sugeridas por Veldhuizen (1999) são exemplos desse tipo de métrica.

Para avaliar a diversidade entre as soluções do conjunto não-dominado encontrado, foram desenvolvidas algumas métricas de diversidade, como a métrica de espaçamento, sugerida por Schott (1995, *apud* DEB, 2001), e as métricas de número de nichos e espalhamento máximo de Zitzler *et al.* (2000).

Coello (2006) relata que muitos pesquisadores criticam as métricas de desempenho que avaliam individualmente cada método, ou cada execução de um método. Alguns pesquisadores, inclusive, se depararam com diferenças de desempenho entre os resultados quando comparados graficamente e numericamente com algumas métricas. Recentemente estas métricas são consideradas, por alguns autores, como não confiáveis (ZITZLER *et al.*, 2002).

Desse modo, estão surgindo novas medidas de desempenho, as quais são aplicadas não a apenas um algoritmo de cada vez, mas a dois, daí serem denominadas de métricas de desempenho binárias. A métrica de cobertura de Zitzler *et al.* (2000), que calcula a proporção de soluções de um conjunto não-dominado (dado por uma metodologia), fracamente dominada por outro conjunto (dado por outra metodologia), é um exemplo desse tipo de métrica.

No entanto, as métricas binárias possuem como desvantagens o fato de calcular  $r(r-1)$  indicadores distintos quando se realiza a análise de  $r$  algoritmos diferentes, em contraste dos  $r$

indicadores no caso das métricas convencionais. Outras características e limitações dos diferentes tipos de métricas de desempenho encontradas na literatura podem ser consultadas no trabalho de Zitzler *et al.* (2002).

### 3.2.3.3 Consideração das restrições

Os métodos evolucionários multi-objetivo como originalmente concebidos assumem que o problema de otimização está livre de qualquer restrição, no entanto, a otimização de problemas reais envolve uma série de restrições que precisam ser atendidas para que a solução seja considerada aceitável. As restrições dividem o espaço de busca em duas regiões, de soluções factíveis e de soluções infactíveis, sendo que a fronteira Pareto é definida apenas considerando a região factível (DEB, 2001).

A estratégia mais popular para considerar as restrições é utilizando funções de penalidades das restrições. Essas funções são proporcionais às restrições violadas e devem ser adicionadas a cada valor de função-objetivo, em problemas de minimização, ou subtraídas, em problemas de maximização (MICHALEWICZ & FOGEL, 2002).

Uma função de penalidade comumente utilizada (DEB, 2001) consiste em calcular as restrições violadas, normalizar e somar seus valores, multiplicar por um parâmetro de penalidade para só então ser adicionado a cada valor de função-objetivo, sendo que as soluções que não violam quaisquer restrições retornam função de penalidade de valor zero. Uma precaução que deve ser observada ao utilizar essa estratégia é converter todas as funções-objetivo de maximização para minimização, e um inconveniente da sua utilização é a necessidade de representar todas as restrições do problema em equações matemáticas.

O meio mais simples de considerar as restrições é rejeitar qualquer solução infactível, denominada de penalidade de morte. No entanto, na otimização de problemas reais, o número de soluções factíveis é muito reduzido e o simples descarte das soluções infactíveis pode provocar uma perda de eficiência no algoritmo. Isto acontece tanto na iniciação do algoritmo, que teria dificuldades de gerar aleatoriamente uma população totalmente preenchida de soluções factíveis, quanto durante a evolução, devido à dificuldade de progredir para as soluções que não violam qualquer restrição, principalmente quando estas estão dispersas entre as soluções infactíveis (MICHALEWICZ & FOGEL, 2002).

Um critério também utilizado para considerar as restrições (DEB, 2000, *apud* DEB, 2001) é manter as soluções inactíveis na população e atribuir-lhe medidas da inactibilidade nas quais o método evolucionário pode se basear, atribuindo uma pressão de seleção maior a soluções que violem menos restrições (ou com menos severidade) para, daí, guiar a busca para as regiões factíveis. As soluções inactíveis também podem ser reparadas, através de um procedimento randômico ou de uma estratégia de reparo específica, com procedimentos particulares para cada tipo de restrição do problema. Mas, segundo Michalewicz e Fogel (2002), em alguns problemas, reparar a solução inactível pode se tornar tão complexo quanto resolver o problema original.

Por não requerer a definição de novos parâmetros, alguns autores vêm considerando as restrições nos operadores de seleção por torneio da seguinte forma: entre duas soluções factíveis, escolhe-se a de melhor aptidão; entre uma solução factível e uma inactível escolhe-se a factível, e, entre duas soluções inactíveis, escolhe-se a que viola menos (ou com menos severidade) as restrições. No contexto multi-objetivo, quando não se dispuser de um valor explícito de aptidão, o critério de escolha entre duas soluções factíveis pode ser baseado em apenas uma função-objetivo, baseado nos conceitos de dominância ou baseado em algum critério de diversidade (DEB, 2001).

### **3.3. Trabalhos Correlatos**

#### **3.3.1 Redes de escoamento de petróleo**

Vélez-Langs (2005) apresenta um compêndio sobre a utilização de algoritmos evolucionários na indústria de petróleo, principalmente dos algoritmos genéticos, os quais, segundo o autor, são uma das mais promissoras metodologias para lidar com problemas complexos, como os encontrados nesse campo. Dentre as vantagens do algoritmo genético citadas pelo autor, estão a sua facilidade de aplicação em problemas de otimização multi-objetivo, inclusive com objetivos conflitantes, a sua robustez, a sua eficiência e a sua facilidade de utilização.

O foco do presente trabalho é o problema do escalonamento das bombas (*pump scheduling*) em uma rede de escoamento, cuja solução consiste em determinar, entre as

bombas disponíveis, quais deverão ser ativadas e em que períodos do dia, de modo a atender às restrições operacionais do sistema, otimizar os múltiplos objetivos e garantir o atendimento da produção requerida. A otimização desse tipo de problema em sistemas da produção de petróleo tem sido pouco explorada pelos pesquisadores, já que grande parte da utilização do algoritmo genético na indústria de petróleo se concentra na caracterização de reservatórios subterrâneos (BATYRSHIN *et al.*, 2005; BUSH & CARTER, 1996; SOLENG, 1999; ROMERO & CARTER, 2001), na inversão sísmica (MANSANNÉ & SCHOENAUER, 2002; BOSCHETTI, 1995) e no desenvolvimento de campos de petróleo (TÚPAC *et al.*, 2002).

No âmbito de transporte e operação das redes de escoamento de petróleo, podem ser citados os trabalhos de Goldberg (1985), que utiliza o algoritmo genético para acompanhar a operação de dutos, e o trabalho de Almeida *et al.* (2001), que utiliza um algoritmo genético voltado para a programação da produção de uma refinaria de petróleo para minimizar os custos com energia elétrica.

Especificamente para o problema do escalonamento de bombas, Silva (1999) utilizou o algoritmo genético em conjunto com a programação linear para otimizar o transporte de um campo petrolífero localizado no sul da Argentina até a sua estação de pré-processamento de petróleo - PPP. O problema foi decomposto em sub-problemas, um para cada intervalo de tempo, sendo os sub-problemas resolvidos sequencialmente, do primeiro ao último intervalo de tempo, e a resolução de cada intervalo ocorrendo em duas etapas. Na primeira etapa utiliza-se o algoritmo genético para decidir quais bombas serão ativadas, através da minimização de uma função de aptidão de caráter multi-objetivo, a qual satisfaz o objetivo principal da operação (minimizar a diferença entre o volume de entrada na PPP e o volume de entrada pré-estabelecido) e agrega as restrições como forma de penalidades. Na segunda etapa, é utilizada a programação linear para determinar em que rotação cada bomba deve operar de modo que a vazão de alimentação da PPP seja o mais próximo possível da vazão desejada.

Um indivíduo do algoritmo genético, na resolução proposta por Silva (1999), é composto de um vetor de 16 bits, um para cada bomba do sistema, onde o número 1 indica que a bomba está ligada e o número 0, desligada, no determinado intervalo de tempo. Desse modo, o espaço de busca do problema é composto de 65.536 soluções (dado por  $2^{16}$ ). A consideração dos intervalos independentes, adotada por Silva (*op. cit*), permite uma redução significativa do espaço de busca, mas, por outro lado, em uma operação de 24 horas, por

exemplo, a otimização individual de cada intervalo talvez não forneça uma otimização global do horizonte de operação completo.

Brasileiro (2005) propôs um algoritmo genético modificado para otimizar o problema do escalonamento de bombas em uma rede de escoamento de petróleo, considerando como objetivo principal o custo de energia elétrica por volume bombeado através de uma função de adaptabilidade ponderada no tempo para minimizar as perdas devido às incertezas na previsão da produção do sistema. Para tratar as restrições temporais, inerentes à aplicação em tempo real, a autora utilizou a técnica de *seeding* para inserir na população inicial uma solução gerada por um sistema de regras. As restrições operacionais foram tratadas utilizando uma abordagem direta, na qual, para cada tipo da violação da restrição, são atribuídas severidades diferentes, que servem de base no ordenamento dos indivíduos para seleção.

O principal diferencial do algoritmo genético proposto por Brasileiro (*op. cit*) é a utilização de operadores genéticos inteligentes, os quais baseiam o ponto de cruzamento e de mutação no intervalo de tempo em que ocorreu a inviabilidade para aumentar as chances de se gerar indivíduos viáveis. Um procedimento de descarte de certos indivíduos inviáveis também foi adotado no mesmo trabalho e o elitismo foi utilizado para que as soluções ótimas encontradas não fossem perdidas.

### **3.3.2 Redes de escoamento de água**

Têm sido bastante freqüentes pesquisas abordando a otimização da operação de redes de escoamento de água. Os primeiros estudos nesse campo utilizavam principalmente as programações linear, não-linear, dinâmica, mista e outros tipos de programação, para otimizar um único objetivo: o custo com energia elétrica. Segundo Tsutiya (2001), o consumo nas estações elevatórias pode representar até 90% do custo total de energia elétrica em sistemas de abastecimento de água, portanto, na otimização da operação desses sistemas, é fundamental um escalonamento inteligente das bombas. O autor apresenta ainda diversas alternativas para redução do custo de energia elétrica em sistemas de escoamento. Uma delas é a redução do custo de energia pela adoção de alternativas operacionais, como, por exemplo, a diminuição ou interrupção do bombeamento em horários de pico cujas tarifas de energia são mais caras.

Ormsbee e Lansey (1994) apresentaram uma revisão de várias metodologias aplicadas na otimização do problema do escalonamento de bombas em uma rede de escoamento de água, incluindo vários métodos constantemente utilizados na época e baseados em programação matemática. Os autores observaram que a maioria dos algoritmos analisados apenas considerava o custo com energia elétrica consumida, sendo o custo de demanda de energia elétrica ou ignorado ou adicionado como uma restrição do sistema. Nesse mesmo trabalho, os autores caracterizaram as restrições para problemas de sistemas de escoamento de água em três grupos: 1) limitações físicas dos sistemas (capacidade dos reservatórios, capacidade dos mananciais, configuração das bombas, etc.); 2) leis físicas (conservação de massa nos nós da rede, conservação de energia nos anéis, etc.); e 3) requisitos externos (atendimento da demanda, manutenção dos níveis de pressão aceitáveis, etc.).

Lansey e Awumah (1994) destacaram que a maioria dos pesquisadores enfatiza a minimização do custo de energia elétrica das bombas, e ressaltaram a importância de considerar no escalonamento ótimo também o número de chaveamentos das bombas. Os autores citados utilizaram programação dinâmica na otimização e consideraram o número de chaveamentos como uma restrição, sendo estabelecido um número máximo permitido para cada período e um número máximo para todo o horizonte de planejamento.

A aplicação de um algoritmo genético ao problema de escalonamento de bombas em uma rede de escoamento de água foi utilizada por Mackle *et al.* (1995) e Boulos *et al.* (2001). Ambos os trabalhos ressaltaram as deficiências encontradas quando do uso dos métodos tradicionais, como por exemplo: 1) dificuldades para otimizar redes de grande porte, com combinações de bombas diferentes ou com restrições complicadas; 2) facilidades de se prenderem em ótimos locais; e 3) alta sujeição a um número excessivo de simplificações para adequar-se aos modelos matemáticos. A característica em comum dos trabalhos citados é a otimização de um único objetivo, o custo com energia elétrica, e a consideração das restrições como funções de penalidades. No entanto, vale dizer que o trabalho de Boulos *et al.* (*op. cit.*) considera, em adição ao custo com energia consumida, também o custo com demanda de energia, e considera o número máximo de chaveamentos como uma restrição a ser atendida.

A consideração do número de chaveamentos como um objetivo explícito, e não como uma restrição, foi adotada por Schwab *et al.* (1996), que utilizou uma metodologia híbrida (algoritmo genético combinado com um método de busca local) com seleção baseada em ranqueamento dos indivíduos considerando os conceitos de dominância, para minimizar duas funções-objetivo simultaneamente: o custo com energia elétrica e o número de chaveamentos

da operação. As restrições no seu trabalho foram consideradas como penalidades, em adição ao custo com energia elétrica, e todas as soluções infactíveis que eram não-dominadas, recebiam um ranqueamento maior do que as não-dominadas factíveis.

Recentemente, os pesquisadores têm preferido adotar métodos multi-objetivo para tratar o problema da operação das redes de escoamento de água. Carrijo (2004) considerou dois objetivos simultâneos: o de minimizar o custo com energia elétrica (considerando ambos os custos com consumo e demanda de energia) e o de maximizar os benefícios hidráulicos, representados pelo atendimento das pressões nodais, dos níveis dos reservatórios e das demandas. O autor investigou a aplicação de três MOEAs conhecidos: o NSGA, o NSGA-II e o SPEA, tendo o SPEA mostrado melhor desempenho para o seu problema. No trabalho de Carrijo, no vetor de soluções binário, além da representação das bombas do sistema, são representadas também as válvulas, onde 1 significa aberta e 0 fechada, obtendo, portanto, um cromossomo com 168 variáveis de decisão (3 bombas, 4 válvulas, 24 horas em intervalos de 1 hora).

Barán *et al.* (2005) consideraram na otimização quatro objetivos distintos: o custo com consumo de energia elétrica, os picos de potência que refletem no custo de demanda, o número de chaveamentos e a variação do nível dos reservatórios; e analisou a viabilidade de seis MOEAs para um problema de escalonamento de 5 bombas em um horizonte de operação de 24 horas discretizados em intervalos de 1 hora, portanto, com um vetor solução composto por 120 bits. Utilizando métricas de desempenho sugeridas na literatura, os autores concluíram que o método SPEA demonstrou melhor desempenho, sendo o NSGA-II considerado uma boa alternativa. Os autores incorporaram ainda uma heurística em um algoritmo de reparo de soluções infactíveis que violam as restrições de níveis máximos e mínimos dos tanques.

Em um outro trabalho (Lücken *et al.*, 2004), os mesmos autores incorporam o paralelismo nos métodos analisados, através de um coletor e de vários pMOEAs. O coletor recebe as soluções dos pMOEAs e mantém, em um arquivo, apenas as soluções não-dominadas, aplicando o algoritmo de agrupamento do SPEA, apenas se o número de soluções do arquivo ultrapassar a dimensão máxima. Os autores observaram um ganho computacional nos pMOEAs em relação às suas versões seriais.

López-Ibáñez *et al.* (2005) utilizaram o método SPEA2 na otimização de dois objetivos em um problema de escalonamento de bombas, o custo com energia elétrica (referente ao consumo e à demanda) e o número de chaveamentos, e ressaltaram a importância da

utilização de um modelo computacional para simulações hidráulicas em conjunto com o modelo de otimização, o que permite adicionar maior complexidade à rede. Os autores consideraram como restrições operacionais os limites de níveis dos tanques, as pressões nos nós de demanda e uma tolerância para o déficit de volume nos tanques no final do período da operação. A inviabilidade das restrições foi considerada em conjunto com os conceitos de Pareto, considerando as seguintes regras: 1) qualquer solução infactível é dominada por uma solução factível; 2) entre duas soluções infactíveis, a que tiver violado menos vezes a restrição de pressão dominará a outra; e 3) entre duas soluções factíveis, a que tiver o menor déficit de volume dominará a outra, sendo que, em caso de empate, o critério normal de dominância é considerado.

No trabalho citado foram conduzidos experimentos com variações nas populações iniciais, gerando uma população inicial aleatoriamente ou a partir de mutações de indivíduos específicos, utilizando, nesse segundo caso, um indivíduo que mantém todas as bombas ligadas, um outro que mantém todas as bombas desligadas e um de carácter factível. Os autores concluíram que os melhores resultados foram obtidos com a iniciação da população randomicamente ou a partir de mutações de uma solução factível, sendo que a iniciação randômica permite uma diversidade maior das soluções encontradas.

Apesar de utilizarem representação binária, os autores citados alertaram para as desvantagens desse tipo de representação, a qual requer que a bomba seja ligada ou desligada em um espaço definido de tempo, o que impede que a bomba tenha uma programação mais refinada, podendo iniciar ou parar em qualquer tempo. Os mesmos autores propuseram em um trabalho posterior (LÓPEZ-IBÁÑEZ *et al.*, 2005a) o uso de uma representação explícita das bombas a qual permite que a bomba seja ligada ou desligada em qualquer tempo e restringe o número máximo de chaveamentos do sistema.

### **3.4. Análise da revisão de literatura**

Para o problema do escalonamento de bombas em redes de escoamento de água, percebe-se uma evolução das metodologias aplicadas, partindo desde os métodos tradicionais, passando pelos algoritmos evolucionários de um único objetivo até a utilização de MOEAs, nos quais o SPEA, o SPEA2 e o NSGA-II se destacam como os mais recomendados. Para a

consideração das restrições, que inicialmente eram formuladas como uma função de penalidade, atualmente vem sendo adotadas alternativas, como heurísticas de reparo, ranqueamento baseado na inviabilidade dos indivíduos e associação do conceito de Pareto em conjunto com o conceito de inviabilidade.

Na operação de redes de escoamento de petróleo, no entanto, a natureza multi-objetivo do problema não vem sendo considerada explicitamente, como o presente trabalho se propõe a realizar. Dessa forma, serão consideradas na determinação da metodologia aplicável a este trabalho, técnicas recomendadas na literatura que se propõem a melhorar o desempenho da otimização ou tornar a representação mais realista com o mundo real. As técnicas são as seguintes: 1) a consideração do problema multi-objetivo explicitamente; 2) a introdução de soluções viáveis na geração inicial da população para garantir bons resultados; 3) a utilização de uma heurística de reparo e de descarte de soluções infactíveis; 4) a consideração do conceito de viabilidade em conjunto com os conceitos de dominância; 5) a introdução de conhecimento nos operadores de reprodução; 6) a utilização de um modelo de simulação em conjunto com um modelo de otimização; e 7) a consideração do custo de demanda em conjunto com o custo do consumo de energia elétrica.

## 4. Metodologia

### 4.1. Modelo computacional SmartPumping

No presente trabalho o modelo para simulação hidráulica e cálculo tarifário utilizado é parte componente do *software* SmartPumping<sup>2</sup>, que é um modelo computacional multifuncional em desenvolvimento e cujas funcionalidades mais relevantes são: 1) o módulo de simulação, responsável por estabelecer o equilíbrio hidráulico da rede, e capaz de fornecer os valores de vazão e velocidade em cada duto, a pressão em cada nó, os níveis dos tanques, as propriedades do fluido em todos os pontos do sistema e o custo da operação simulada relativo ao consumo e à demanda de energia; 2) o módulo de otimização, fundamentado principalmente na técnica do algoritmo genético e cuja função é definir a melhor decisão operacional para as bombas do sistema de modo a atender os objetivos pré-determinados; 3) o módulo de monitoramento, para atualizar as informações sobre o estado da rede em tempo real; 4) o módulo de previsão da produção, para caracterizar as características previstas para o fluido em um horizonte de operação futuro; 5) o módulo de análise de incertezas, que permite realizar a análise de sensibilidade da simulação derivadas da variabilidade nos valores dos dados de entrada; e 6) outros módulos como: a ferramenta de apoio à calibração da rede, a ferramenta de projeto otimizado de novos dutos, a ferramenta de análise de robustez do modelo de decisão, a ferramenta de registro global dos processos e a ferramenta para edição de funcionalidades do *software*.

#### 4.1.1 Generalidades

No SmartPumping, considera-se como horizonte de operação o período de tempo para o qual uma operação pré-determinada de bombas (escalonamento) deve ser aplicada, devendo ser discretizado em intervalos de cálculo e em intervalos de atuação. Em cada intervalo de cálculo do horizonte de operação, um novo equilíbrio hidráulico é estabelecido, definindo-se as vazões e as pressões correspondentes ao cenário inicial do intervalo. Após ter-se atingido o

---

<sup>2</sup> Versão utilizada neste trabalho: 1.4.3

equilíbrio hidráulico, é realizado o balanço hídrico nos tanques (Equação 2), atualizando seus níveis, os quais servirão de base para um novo equilíbrio hidráulico. O intervalo de atuação deve ser no mínimo igual ao intervalo de cálculo, e corresponde ao intervalo de tempo no qual é possível alterar o estado das bombas do sistema. Segundo Silva (1999), o intervalo de atuação não deve ser muito pequeno sob pena de acarretar um alto número de chaveamentos nas bombas, nem muito grande, por reduzir as possibilidades de otimização. Com relação ao intervalo de cálculo, quanto menor seu valor, mais preciso será o resultado do balanço hídrico dos tanques, no entanto, intervalos de cálculo muito pequenos acarretam um alto custo computacional por requerer que o equilíbrio hidráulico seja estabelecido mais vezes.

$$N_i = \begin{cases} N_{ini}, & \text{se } i = 1 \\ \max \left[ 0, \left( N_{i-1} + \frac{(Qe_{i-1} - Qs_{i-1}) \cdot \Delta i}{Ab} \right) \right], & \text{se } i > 1 \end{cases} \quad \text{Equação 2}$$

onde:

$i$  é um intervalo de cálculo do horizonte de operação;

$N_i$  é o nível de fluido no tanque no intervalo de cálculo  $i$ , tendo como limite máximo superior a altura do tanque, [m];

$N_{ini}$  é o nível de fluido no tanque no início do primeiro intervalo de cálculo, [m];

$Ab$  é a área da base do tanque, [m<sup>2</sup>];

$Qe_i$ ,  $Qs_i$  são as vazões de entrada e de saída do tanque no intervalo de cálculo  $i$ , respectivamente, [m<sup>3</sup>/s];

$\Delta i$  é a duração correspondente a um intervalo de cálculo, [s].

Os elementos da rede representados no SmartPumping são: bombas, tanques, dutos, nós e estações. As bombas podem ser do tipo centrífuga ou volumétrica e têm suas curvas características representadas através de uma equação do segundo grau (Equação 3), sendo que as volumétricas possuem o coeficiente  $a$  da curva característica nulo, ou seja, têm suas curvas características representadas através de uma equação linear. Os tanques são denominados de produtores, quando estão inseridos em uma estação coletora, ou receptores, quando se incluem na estação de tratamento de óleo.

$$Hman_{B,i} = a.Q_{B,i}^2 + b.Q_{B,i} + c \quad \text{Equação 3}$$

onde:

$Hman_{B,i}$  é a altura manométrica da bomba  $B$  no intervalo de cálculo  $i$ , [m];

$Q_{B,i}$  é a vazão da bomba  $B$  no intervalo de cálculo  $i$ , [l/s];

$a$ ,  $b$ ,  $c$  são os coeficientes da curva característica da bomba.

Para cada estação é definida uma previsão da produção de fluido, a qual funciona como caracterizador das propriedades e vazão do fluido oriundo dos poços para as estações coletoras durante o horizonte de operação, e definidor da vazão do fluido retirado da estação receptora. Um fluido é representado no SmartPumping através das seguintes propriedades: vazão -  $Q$ , temperatura -  $T$ , massa específica -  $\rho$ , porcentagem de água e sedimentos -  $BS\&W$  e viscosidade cinemática -  $\nu$ .

Um fluido caracterizado na entrada de uma estação coletora, para um dado intervalo de cálculo, tem suas propriedades mantidas ao longo da rede, na direção do fluxo, até que encontre um nó onde ocorre a mistura, com transferência para o duto subsequente de um fluido derivado com propriedades equivalentes. Na entrada de cada estação coletora e a cada novo intervalo de cálculo, ocorre mistura dos fluidos que estão sendo introduzidos na estação com o fluido no interior do tanque da estação. As regras para mistura de fluidos primitivos, os quais possuem propriedades definidas, para obtenção de um fluido resultante, serão explanadas na seção seguinte.

Além das restrições implícitas do sistema, as quais definem o equilíbrio hidráulico, como a conservação da massa em cada nó e a conservação de energia, o SmartPumping considera explicitamente algumas restrições operacionais do sistema: 1) restrições na capacidade de armazenamento dos tanques, representadas por níveis máximos e mínimos admissíveis para cada tanque; 2) pressões admissíveis nos dutos, representadas por valores máximos e mínimos admissíveis em cada duto; e 3) velocidades admissíveis nos dutos, representadas por valores máximos e mínimos admissíveis em cada duto. Cada vez que uma restrição operacional é violada, o SmartPumping detecta um alarme, e a operação das bombas que provocou esse alarme é dita inviável, ou inactível. O intervalo de atuação onde ocorre o primeiro alarme, considerando a ordem natural desses intervalos no horizonte de operação, é denominado de ponto de falha do cromossomo.

### 4.1.2 Mistura de fluidos

Considerando-se que no início do horizonte de operação todas as características do fluido no interior dos tanques são definidas, a mistura daquele fluido com os que estão sendo introduzidos na estação a cada intervalo de cálculo define a variação dessas características ao longo do horizonte de operação. O resultado da mistura é dado pela média ponderada – para as características de temperatura, BS&W ou massa específica – dos valores dessas características em relação ao somatório dos volumes dos fluidos que entram e do volume de fluido contido no tanque no início do intervalo de cálculo (Equações 4, 5, 6).

$$BSWt_i = \frac{(BSWt_{i-1} \cdot Vt_{i-1}) + \sum_e (BSWe_{e,i-1 \rightarrow i} \cdot Ve_{e,i-1 \rightarrow i})}{Vt_{i-1} + \sum_e Ve_{e,i-1 \rightarrow i}} \quad \text{Equação 4}$$

$$Tt_i = \frac{(Tt_{i-1} \cdot Vt_{i-1}) + \sum_e (Te_{e,i-1 \rightarrow i} \cdot Ve_{e,i-1 \rightarrow i})}{Vt_{i-1} + \sum_e Ve_{e,i-1 \rightarrow i}} \quad \text{Equação 5}$$

$$\rho t_i = \frac{(\rho t_{i-1} \cdot Vt_{i-1}) + \sum_e (\rho e_{e,i-1 \rightarrow i} \cdot Ve_{e,i-1 \rightarrow i})}{Vt_{i-1} + \sum_e Ve_{e,i-1 \rightarrow i}} \quad \text{Equação 6}$$

onde:

$BSWt_i$  é o BS&W do fluido contido no tanque no intervalo de cálculo  $i$ , [%];

$Vt_i$  é o volume de fluido contido no tanque no intervalo de cálculo  $i$ , [m<sup>3</sup>];

$BSWe_{e,i-1 \rightarrow i}$  é o BS&W do fluido da entrada  $e$ , entre os intervalos de cálculo  $i-1$  e  $i$ , [%];

$Ve_{e,i-1 \rightarrow i}$  é o volume de fluido da entrada  $e$ , entre os intervalos de cálculo  $i-1$  e  $i$ , [m<sup>3</sup>];

$Tt_i$  é a temperatura do fluido do tanque no intervalo de cálculo  $i$ , [°C];

$Te_{e,i-1 \rightarrow i}$  é a temperatura do fluido da entrada  $e$ , entre os intervalos de cálculo  $i-1$  a  $i$ , [°C];

$\rho t_i$  é a massa específica do fluido do tanque no intervalo de cálculo  $i$ , [kg/m<sup>3</sup>];

$\rho e_{e,i-1 \rightarrow i}$  é a massa específica do fluido da entrada  $e$ , entre os intervalos de cálculo  $i-1$  a  $i$ , [kg/m<sup>3</sup>].

O volume de fluido contido no tanque em um dado intervalo de cálculo é dado pela multiplicação da área de base do tanque pelo nível de fluido contido no tanque no referido intervalo (Equação 7), enquanto que o volume de fluido de entrada no tanque durante um intervalo é dado pela multiplicação da vazão de entrada no tanque pela duração do intervalo (Equação 8).

$$Vt_i = Ab_i \cdot N_i \quad \text{Equação 7}$$

$$Ve_{i-1 \rightarrow i} = Qe_{i-1 \rightarrow i} \cdot \Delta i \quad \text{Equação 8}$$

onde:

$Qe_{i-1 \rightarrow i}$  é a vazão do fluido de entrada no tanque, entre os intervalos de cálculo  $i-1$  e  $i$ , [ $m^3/s$ ].

As propriedades dos fluidos resultantes da mistura nos dutos são obtidas através da ponderação pela vazão dos valores das propriedades dos fluidos primitivos, para o caso de essas propriedades serem temperatura, BS&W ou massa específica (Equações 9, 10 e 11).

$$BSWx_i = \begin{cases} BSWy_{i-1}, & \text{se duto está conectado ao tanque produtor} \\ \frac{\sum_z (BSWz_i \cdot Qz_i)}{\sum_z Qz_i}, & \text{caso contrário} \end{cases} \quad \text{Equação 9}$$

$$Tx_i = \begin{cases} Ty_{i-1}, & \text{se duto está conectado ao tanque produtor} \\ \frac{\sum_z (Tz_i \cdot Qz_i)}{\sum_z Qz_i}, & \text{caso contrário} \end{cases} \quad \text{Equação 10}$$

$$\rho x_i = \begin{cases} \rho y_{i-1}, & \text{se duto está conectado ao tanque produtor} \\ \frac{\sum_z (\rho z_i \cdot Qz_i)}{\sum_z Qz_i}, & \text{caso contrário} \end{cases} \quad \text{Equação 11}$$

onde:

$BSWx_i$  é o BS&W do fluido do duto  $x$  no intervalo de cálculo  $i$ , [%];

$Tx_i$  é a temperatura do fluido do duto  $x$  no intervalo de cálculo  $i$ , [°C];

$\rho x_i$  é a massa específica do fluido do duto  $x$  no intervalo de cálculo  $i$ , [kg/m<sup>3</sup>];

$BSWy_i$  é o BS&W do fluido no tanque produtor  $y$  conectado ao duto  $x$  no intervalo de  $i$ , [%];

$Ty_i$  é a temperatura do fluido no tanque produtor  $y$  conectado ao duto  $x$  no intervalo de cálculo  $i$ , [°C];

$\rho y_i$  é a massa específica do fluido no tanque  $y$  conectado ao duto  $x$  no intervalo de cálculo  $i$ , [kg/m<sup>3</sup>];

$BSWz_i$  é o BS&W do fluido no duto  $z$  a montante do duto  $x$  no intervalo de cálculo  $i$ , [%];

$Tz_i$  é a temperatura do fluido no duto  $z$  a montante do duto  $x$  no intervalo de cálculo  $i$ , [°C];

$\rho z_i$  é a massa específica do fluido no duto  $z$  a montante do duto  $x$  no intervalo de cálculo  $i$ , [kg/m<sup>3</sup>];

$Q_{z,i}$  é a vazão do fluido no duto  $z$  a montante do duto  $x$  no intervalo de cálculo  $i$ , [m<sup>3</sup>/s].

A variação da viscosidade cinemática do fluido com a temperatura é representada no SmartPumping através da Equação 12, a qual é uma adaptação para as unidades do Sistema Internacional de Medidas (SI) da equação recomendada pela Norma 11A4.5<sup>3</sup> do *American Petroleum Institute* (API).

$$\nu = \{\exp[\exp[p + m \cdot \ln(1,8(273,15 + T))]] - 0,7\} \cdot 10^{-6} \quad \text{Equação 12}$$

onde:

$\nu$  é a viscosidade cinemática do fluido, [m<sup>2</sup>/s];

$m$  e  $p$  são os parâmetros da equação da viscosidade cinemática, [adimensionais];

$T$  é a temperatura do fluido, [°C].

A viscosidade cinemática resultante da mistura de fluidos diferentes é encontrada utilizando uma simplificação de uma metodologia proposta nessa mesma norma para encontrar os parâmetros da equação do fluido resultante. A viscosidade cinemática resultante

<sup>3</sup> Procedure 11A4.5, (1992). Liquid viscosity blending of hydrocarbon mixtures. STD.API/PETRO, TDB Chapter 11.

da mistura de fluidos é sempre feita de dois em dois, ou seja, caso haja mais de dois fluidos a ser misturado, será feita a mistura com dois dos fluidos e o resultado dessas com o terceiro fluido, e assim por diante.

As Equações 13 a 16 são utilizadas, no SmartPumping, para encontrar os parâmetros da equação da viscosidade cinemática do fluido resultante da mistura de dois fluidos (fluido  $F1$  e fluido  $F2$ ), para um dado intervalo de cálculo  $i$ .

$$\%Vol_{F1,i-1} = \frac{(Vol_{F1,i-1})}{(Vol_{F1,i-1} + Vol_{F2,i-1})} \quad \text{Equação 13}$$

$$\%Vol_{F2,i-1} = \frac{(Vol_{F2,i-1})}{(Vol_{F1,i-1} + Vol_{F2,i-1})} \quad \text{Equação 14}$$

$$m_{Fr,i} = \frac{1}{\frac{\%Vol_{F1,i-1}}{m_{F1,i-1}} + \frac{\%Vol_{F2,i-1}}{m_{F2,i-1}}} \quad \text{Equação 15}$$

$$p_{Fr,i} = \frac{\%Vol_{F1,i-1} \cdot m_{F2,i-1} \cdot p_{F1,i-1} + \%Vol_{F2,i-1} \cdot m_{F1,i-1} \cdot p_{F2,i-1}}{\%Vol_{F1,i-1} \cdot m_{F2,i-1} + \%Vol_{F2,i-1} \cdot m_{F1,i-1}} \quad \text{Equação 16}$$

onde:

$\%Vol_{F1,i}$  e  $\%Vol_{F2,i}$  são as proporções percentuais dos volumes dos fluidos primitivos  $F1$  e  $F2$  em relação ao volume total da mistura, no intervalo de cálculo  $i$ , [%];

$m_{Fr,i}$  e  $p_{Fr,i}$  são os parâmetros da equação da viscosidade cinemática do fluido resultante da mistura para o intervalo de cálculo  $i$ , [adimensionais];

$m_{F1,i}$  e  $p_{F1,i}$  são os parâmetros da equação da viscosidade cinemática do fluido  $F1$ , no intervalo de cálculo  $i$ , [adimensionais];

$m_{F2,i}$  e  $p_{F2,i}$  são os parâmetros da equação da viscosidade cinemática do fluido  $F2$ , no intervalo de cálculo  $i$ , [adimensionais].

### 4.1.3 Equilíbrio hidráulico

A resolução do equilíbrio hidráulico da rede é feita utilizando um método híbrido nó-malha denominado por Todini e Pilati (1987) e por Salgado *et al.* (1988) como “Método do Gradiente”. Consiste de um algoritmo para resolução simultânea de equações em um

determinado instante considerando o princípio da continuidade, o princípio da conservação da energia e a relação entre a vazão e a perda de carga.

Em uma rede ramificada, os níveis e as cotas topográficas dos tanques são variáveis conhecidas em um determinado intervalo de cálculo, portanto, pode-se designá-los como sendo nós com carga piezométrica conhecida. Aplicando o método do gradiente, é possível, a partir dessas cargas conhecidas, encontrar os valores das cargas piezométricas desconhecidas nos outros nós, e, conseqüentemente, as vazões em cada um dos dutos ou bombas que interligam esses mesmos nós.

As bombas são elementos de conexão que proporcionam um ganho de carga no sistema, enquanto os dutos são elementos de conexão que proporcionam uma perda de carga no sistema. No equilíbrio hidráulico, o ganho de carga no sistema (Equação 17), convencionado como negativo, é calculado através da curva característica da bomba, enquanto que a perda de carga (Equação 17), convencionada como positiva, é obtida utilizando uma derivação da equação universal da perda de carga em dutos - Equação de Darcy-Weisbach.

O fator de atrito (Equação 18), em escoamentos com número de Reynolds maior do que 2.300 (escoamento de transição a turbulento) é calculado pela “fórmula de Shacham-1” (OLUJIC, 1981 *apud* KOIDE, 1998), e no escoamento laminar é dado pela “equação de Hagen-Poiseuille”.

$$F(Q) = \begin{cases} -(a.Q^2 + b.Q + c), & \text{para as bombas} \\ \left( \frac{8.f.L.Q^2}{\pi^2.g.d^5} \right), & \text{para os dutos} \end{cases} \quad \text{Equação 17}$$

$$f = \begin{cases} \frac{64}{Rey}, & \text{se } Rey < 2.300 \\ \left\{ -2 \cdot \log_{10} \left[ \frac{\varepsilon}{3,7.d} - \frac{5,02}{Rey} \cdot \log_{10} \left( \frac{\varepsilon}{3,7.d} + \frac{14,5}{Rey} \right) \right] \right\}^{-2}, & \text{se } Rey \geq 2.300 \end{cases} \quad \text{Equação 18}$$

$$Rey = \frac{4.Q}{\nu.\pi.d} \quad \text{Equação 19}$$

onde:

$F(Q)$  é o ganho/perda de carga nos elementos, [m];

$L$  é o comprimento do duto, [m];

$g$  é a aceleração da gravidade, [m/s<sup>2</sup>];

$d$  é o diâmetro interno do duto, [m];

$f$  é o coeficiente do fator de atrito no duto, [m];

$\varepsilon$  é a rugosidade absoluta do duto, [m];

$Rey$  é o número de Reynolds do escoamento, [adimensional].

Para cada intervalo de cálculo, o método do gradiente implementado no SmartPumping arbitra inicialmente uma vazão conhecida para as bombas e os dutos do sistema. A vazão arbitrada para os dutos é obtida multiplicando a área da seção transversal dos dutos por uma velocidade de 1,5m/s, e a vazão arbitrada para as bombas é igual à máxima possível, ou seja, a vazão para a qual a altura manométrica é zero.

Sendo o método do gradiente um processo iterativo, na primeira iteração do intervalo de cálculo, considera-se como vazão inicial a vazão arbitrada para determinar as cargas piezométricas desconhecidas nos nós através da resolução de uma operação matricial, e conseqüentemente, a vazão em cada elemento do sistema. A cada nova iteração, considera-se como vazão inicial a vazão da iteração anterior acrescida de um fator de correção. O processo iterativo continua até que sejam satisfeitas, para cada nó com carga piezométrica desconhecida do sistema, o princípio da conservação da massa (Equação 20) e o princípio da conservação de energia (Equação 21), ou seja, até que a correção da vazão seja inferior ao limite admissível (geralmente  $10^{-9}$ ).

$$\sum_w Qaf_w - \sum_y Qef_y = 0 \quad \text{Equação 20}$$

$$H_k - H_l = F(Q)_{k,l} \quad \text{Equação 21}$$

onde:

$Qaf_w$  é a vazão de um duto  $w$  afluente a um nó com carga piezométrica desconhecida, [m<sup>3</sup>/s];

$Qef_y$  é a vazão de um duto  $y$  efluente de um nó com carga piezométrica desconhecida, [m<sup>3</sup>/s];

$H_k$  e  $H_l$  são as cargas piezométricas nos nós  $k$  e  $l$ , respectivamente, [m];

$F(Q)_{k,l}$  é o ganho/perda de carga entre os nós  $k$  e  $l$ , [m].

Em uma dada iteração do método do gradiente, para uma rede com  $\eta$  nós de carga piezométrica desconhecida, a operação matricial resolvida é dada por  $JH = R$ , onde  $J$  (Equação 22) é uma matriz Jacobiana (matriz simétrica positiva definida) de dimensão  $\eta \times \eta$ , obtida utilizando-se apenas a informação do ganho/perda de carga do sistema. Os elementos da diagonal da matriz  $J$  são dados pela soma do inverso da derivada da perda/ganho de carga de todos os elementos de conexão que chegam/saem de um mesmo nó. Os demais elementos, quando existir elemento de conexão entre os nós, são dados pelo somatório do inverso negativo da derivada do ganho/perda de carga dos elementos de conexão entre esses nós; caso contrário terá valor zero (Equação 22).

$$J_{kl} = \begin{cases} \sum_{ec} \frac{1}{F'(Q)_{k,ec}}, & \text{se } k = l \\ \sum_{ec} \left( -\frac{1}{F'(Q)_{k,l}} \right), & \text{se } k \neq l \text{ e existir conexão entre } k \text{ e } l \\ 0, & \text{se } k \neq l \text{ e não existir conexão entre } k \text{ e } l \end{cases} \quad \text{Equação 22}$$

onde:

$J_{kl}$  é o elemento correspondente à linha  $k$  e a coluna  $l$  da matriz  $J$ ;

$ec$  é um elemento de conexão (bomba ou duto) conectado ao nó  $k$ ;

$F'(Q)_{k,ec}$  é a derivada do ganho/perda de carga entre o nó  $k$  e o elemento de conexão  $ec$ , [m];

$F'(Q)_{k,l}$  é a derivada do ganho/perda de carga entre os nós  $k$  e  $l$ , [m].

A matriz  $R$  (Equação 23) possui dimensão  $\eta \times 1$ , onde cada elemento é composto pela soma de três matrizes. A primeira matriz representa o termo da continuidade das vazões, e as demais matrizes são fatores de correção para a vazão.

$$R_k = \left[ \sum_w Qaf_w - \sum_y Qef_y \right] + \left[ \sum_w \frac{F(Q)_{w,k}}{F'(Q)_{w,k}} - \sum_y \frac{F(Q)_{y,k}}{F'(Q)_{y,k}} \right] + \left[ \sum_s \frac{H_s}{F'(Q)_{s,k}} \right] \quad \text{Equação 23}$$

onde:

$R_k$  é o elemento correspondente à linha  $k$  da matriz  $R$ ;

$F(Q)_{w,k}$  é o ganho/perda de carga entre o nó  $k$  e o duto  $w$  afluente a  $k$ , [m];

$F'(Q)_{w,k}$  é a derivada do ganho/perda de carga entre o nó  $k$  e o duto  $w$  afluente a  $k$ , [m];

$F(Q)_{y,k}$  é o ganho/perda de carga entre o nó  $k$  e o duto  $y$  efluente de  $k$ , [m];

$F'(Q)_{y,k}$  é a derivada do ganho/perda de carga entre o nó  $k$  e o duto  $y$  efluente de  $k$ , [m];

$s$  é um elemento com carga piezométrica conhecida, conectado ao nó  $k$ ;

$F'(Q)_{s,k}$  é a derivada do ganho/perda de carga entre o nó  $k$  e o elemento com carga piezométrica conhecida  $s$ , [m].

A matriz  $H$  é o vetor de incógnitas dos nós de carga piezométrica desconhecida a ser determinado e possui dimensão  $\eta \times 1$ . É obtida utilizando o processo de solução de equações lineares denominado de decomposição de Cholesky (TODINI & PILATI, 1987). Uma vez determinadas as cargas piezométricas de todos os elementos do sistema, caso o critério de parada não tenha sido satisfeito, calculam-se as vazões iniciais da nova iteração do gradiente através da Equação 24, aplicada a cada elemento do sistema (dutos e bombas).

$$(Q_{k,l})_{u+1} = (Q_{k,l})_u - (dQ)_u \quad \text{Equação 24}$$

$$(dQ)_u = \left( \sum_l \frac{F(Q)_{k,l}}{F'(Q)_{k,l}} - \frac{H_k - H_l}{\sum_l F'(Q)_{k,l}} \right)_u \quad \text{Equação 25}$$

onde:

$(Q_{k,l})_u$  é a vazão entre os nós  $k$  e  $l$ , para a iteração  $u$  do gradiente, [m<sup>3</sup>/s];

$(dQ)_u$  é a correção para a vazão do elemento, [adimensional].

Caso a vazão da nova iteração para uma bomba resulte em um valor negativo, adota-se como metade da vazão anterior. A correção da vazão é um fator que aproxima a vazão dos elementos do valor que atende ao equilíbrio hidráulico, e estabelece o critério de parada do método do gradiente quando a diferença entre esses valores for menor do que o limite pré-estabelecido.

#### 4.1.4 Cálculo tarifário

O cálculo tarifário do SmartPumping é baseado na Resolução ANEEL n° 456 de 29 de novembro de 2000, a qual estabelece as condições gerais de fornecimento de energia elétrica no Brasil. As modalidades de tarifas definidas pela resolução são do tipo: 1) monômnia: tarifa de fornecimento de energia elétrica constituída por preços aplicáveis unicamente ao consumo de energia elétrica ativa; 2) binômnia: tarifas de fornecimento constituído por preços aplicáveis ao consumo de energia elétrica ativa e à demanda faturável; e 3) tarifa de ultrapassagem: tarifa aplicável sobre a diferença positiva entre a demanda medida e a contratada, quando exceder os limites estabelecidos.

A resolução estabelece dois grandes grupos de estruturas tarifárias: a estrutura tarifária convencional e a estrutura tarifária horo-sazonal. A estrutura tarifária convencional é caracterizada pela aplicação de tarifas de consumo de energia e/ou de demanda de potência, independentemente das horas de utilização do dia e dos períodos do ano. O SmartPumping atende essa estrutura tarifária apenas para os consumidores de alta tensão na modalidade binômnia, ou seja, com tarifas para o consumo e a demanda de potência.

A estrutura tarifária horo-sazonal é caracterizada pela aplicação de tarifas diferenciadas de consumo de energia elétrica e de demanda de potência, de acordo com as horas de utilização do dia e os períodos do ano. A modalidade horo-sazonal verde se caracteriza pela aplicação de tarifas diferenciadas de consumo de energia elétrica, de acordo com as horas de utilização do dia e os períodos do ano, bem como de uma única tarifa de demanda de potência. A modalidade horo-sazonal azul, por sua vez, é caracterizada pela aplicação de tarifas diferenciadas de consumo de energia elétrica, de acordo com as horas de utilização do dia e os períodos do ano, bem como de tarifas diferenciadas de demanda de potência, também segundo as horas de utilização do dia. O SmartPumping atende ambas as modalidades azul e verde.

O período úmido compreende os fornecimentos abrangidos pelas leituras de dezembro de um ano a abril do ano seguinte, enquanto que o período seco é o período de 7 meses consecutivos complementares ao período úmido. O horário de ponta é o período definido pela concessionária composto por 3 (três) horas diárias consecutivas, exceção feita aos sábados, domingos e feriados definidos por lei federal, considerando as características do seu sistema

elétrico. O horário fora de ponta é definido como sendo o período composto pelo conjunto das horas diárias consecutivas e complementares àquelas definidas no horário de ponta.

O faturamento das unidades consumidoras de alta tensão é composto das seguintes parcelas: custo da demanda de potência ativa, custo do consumo de energia elétrica ativa e custo do consumo de energia elétrica e demanda de potência reativas excedentes, sendo considerado no SmartPumping apenas os custos referentes ao consumo de energia elétrica e à demanda ativa. Dessa forma o custo com energia elétrica referente ao bombeamento em um horizonte de operação é calculado pela Equação 26.

$$Custo = Custo_E + Custo_D \quad \text{Equação 26}$$

onde:

$Custo$  é o custo com energia elétrica referente ao horizonte de operação, [R\$];

$Custo_E$  é o custo de energia consumida referente ao horizonte de operação, [R\$];

$Custo_D$  é o custo de demanda referente ao horizonte de operação, [R\$].

Para cada intervalo de cálculo, o SmartPumping obtém o consumo de energia multiplicando a potência das bombas em funcionamento na unidade consumidora no referido intervalo, pela duração do intervalo. A multiplicação do consumo de energia pela tarifa apropriada (considerando período do ano e horário do dia, quando for o caso) oferece o custo do consumo de energia elétrica de cada intervalo de cálculo, e seu somatório é o custo referente ao consumo de energia elétrica da unidade consumidora para o horizonte de operação (Equação 27).

$$Custo_E = \sum_{UC} \left( \sum_i \left( \left( \frac{\Delta i}{3600} \cdot \sum_B Pot_{B,i} \right) \cdot tarifa E_i \right) \right)_{UC} \quad \text{Equação 27}$$

$$Pot_{B,i} = \frac{\rho_{B,i} \cdot g \cdot Hman_{B,i} \cdot Q_{B,i}}{\eta M_{B,i} \cdot \eta B_{B,i}} \quad \text{Equação 28}$$

onde:

$UC$  é uma unidade consumidora de energia elétrica do sistema;

$B$  é uma bomba de uma unidade consumidora do sistema;

$Pot_{B,i}$  é a potência da bomba  $B$  no intervalo de cálculo  $i$ , [kW];

$tarifaE_i$  é a tarifa relativa ao consumo de energia elétrica correspondente ao intervalo de cálculo  $i$ , [R\$/kWh];

$\rho_{B,i}$  é a massa específica do fluido da bomba  $B$  no intervalo de cálculo  $i$ , [kg/m<sup>3</sup>];

$\eta M_B$  é o rendimento do motor da bomba  $B$ ;

$\eta B_{B,i}$  é o rendimento da bomba  $B$  no intervalo de cálculo  $i$ .

A Resolução ANEEL 456/2000 estabelece ainda as seguintes definições para demanda de energia, todas expressas em quilowatts - kW: 1) Demanda: média das potências elétricas ativas ou reativas, solicitadas ao sistema elétrico pela parcela da carga instalada em operação na unidade consumidora, durante um intervalo de tempo especificado; 2) Demanda contratada: demanda de potência ativa a ser obrigatória e continuamente disponibilizada pela concessionária, no ponto de entrega, conforme valor e período de vigência fixados no contrato de fornecimento e que deverá ser integralmente paga, seja ou não utilizada durante o período de faturamento; 3) Demanda de ultrapassagem: parcela da demanda medida que excede o valor da demanda contratada; 4) Demanda medida: maior demanda de potência ativa, verificada por medição, integralizada no intervalo de 15 (quinze) minutos durante o período de faturamento; e 5) Demanda faturável: valor da demanda de potência ativa, identificada de acordo com os critérios estabelecidos e considerada para fins de faturamento, com aplicação da respectiva tarifa.

No caso dos consumidores de alta tensão, atendidos pela estrutura tarifária convencional ou horo-sazonal, a demanda faturável corresponde ao maior valor entre a demanda contratada e a demanda medida, exceto para aqueles consumidores classificados como rurais ou reconhecidos como sazonais. Para estes últimos existem critérios diferenciados para a demanda faturável, os quais não estão implementados no SmartPumping.

Desse modo, o custo referente à demanda de potência, utilizado no cálculo tarifário do SmartPumping, considera os seguintes casos: Caso 1 - Demanda medida inferior à demanda contratada - aplica-se a tarifa normal de demanda sobre a demanda contratada; Caso 2 - Demanda medida superior à demanda contratada, mas dentro da tolerância de ultrapassagem - aplica-se a tarifa normal de demanda sobre a demanda medida; e Caso 3 - Demanda medida superior à demanda contratada e acima da tolerância de ultrapassagem - aplica-se a tarifa normal de demanda sobre a demanda contratada, e soma-se a isso a aplicação da tarifa de

ultrapassagem sobre a diferença entre a demanda medida e a demanda contratada. Ou seja, paga-se tarifa normal pelo valor contratado e tarifa de ultrapassagem sobre todo o excedente.

A demanda em cada intervalo de cálculo é estimada no SmartPumping como o somatório das potências das bombas da unidade consumidora no referido intervalo. Para o horizonte de operação, a demanda medida a ser comparada com a demanda contratada, será o máximo valor das demandas considerando todos os intervalos de cálculo e considerando as variações de ponta e fora de ponta.

A partir da comparação entre as demandas medida e contratada, define-se a demanda faturável e seu respectivo custo referente ao horário de ponta ( $custo_{Dp}$ ) e ao horário fora de ponta ( $custo_{Dfp}$ ) e correspondendo à duração de um mês de simulação, que é o período de tempo entre duas faturas consecutivas e para o qual a demanda foi contratada.

Segundo Mackle *et al.* (1995), incluir o custo do pico de demanda de energia elétrica no cálculo tarifário é uma tarefa muito difícil, porque a unidade diária não é a base do custo da demanda, que considera o pior registro ocorrido no período de um mês. No SmartPumping, o somatório do custo mensal de cada unidade consumidora é corrigido para a duração do horizonte de operação através da Equação 29 e constitui parte componente do custo de energia elétrica da simulação (Equação 26, pág. 59).

$$Custo_D = \sum_{UC} \left( \frac{(custo_{Dp} + custo_{Dfp})dS}{dmês} \right) \quad \text{Equação 29}$$

onde:

$custo_{Dp}$  e  $custo_{Dfp}$  correspondem aos custos da demanda do período de ponta e fora de ponta verificados entre “fechamento de faturas”. É função das demandas medidas, da data e das horas transcorridas durante a simulação, da demanda contratada para a ponta e fora de ponta, e das características da tarifação, conforme contrato feito com a concessionária, [R\$];

$dS$  é a duração do horizonte de operação, [s];

$dmês$  é a duração do mês no qual a simulação do horizonte de operação foi executada, [s].

### 4.1.5 Modelagem da rede piloto no SmartPumping

O SmartPumping, por ser um *software* em desenvolvimento, apresenta alguma lacunas na modelagem das redes o que exigiu algumas simplificações na rede piloto para tornar possível a sua representação e simulação hidráulica. A principal simplificação foi a adoção de um único tanque por estação.

Além disso, como essa pesquisa foi conduzida em paralelo ao processo de calibração dos valores de coeficiente de atrito nos dutos e das curvas características das bombas, e em paralelo ao processo de obtenção da previsão da produção dos fluidos efluentes para a rede piloto, algumas considerações foram feitas para obtenção desses valores e de outros dados físicos e operacionais não disponíveis.

#### **Dados físicos da rede**

Considerou-se apenas um tanque por estação, com dimensões iguais às fornecidas (Tabela 1, pág. 12), com exceção da estação LPX onde os tanques funcionam equalizados, sendo adotado apenas um tanque com área da base igual ao somatório das áreas dos dois tanques da estação. Os dados de dutos e cotas topográficas foram mantidos, sendo estimado apenas o valor da rugosidade dos dutos. A rugosidade adotada foi de 0,0015 m, equivalente a um duto de ferro fundido oxidado (PORTO, 2004).

As curvas características das bombas foram obtidas a partir de catálogos referentes às marcas e modelos fornecidos para água a 20°C, com uma rotação de 280 rpm. O rendimento do motor e o rendimento da bomba foram mantidos constantes em 90%.

#### **Propriedades do fluido**

Utilizando os dados fornecidos para as propriedades dos fluidos em uma medição específica (Tabela 2, pág. 12), determinaram-se os coeficientes da equação da viscosidade cinemática, utilizada no SmartPumping (Equação 12, pág. 52). Os dados de previsão do BS&W de entrada da estação e de densidade do fluido foram tomados iguais aos fornecidos na Tabela 2 (pág. 12).

Os dados de previsão da vazão de entrada em cada estação coletora foram estimados considerando um tempo de enchimento dos tanques de cada estação variando entre 5 e 9 horas, sendo o maior tempo de enchimento atribuído para o tanque da estação RFQ e o menor para a estação de LOR. A vazão de saída da estação receptora foi adotada como o somatório das vazões de entrada no sistema. A temperatura adotada foi 40°C constante.

### **Restrições operacionais**

Os níveis admissíveis para os tanques foram adotados em 15% da altura total para nível mínimo de controle e 85% para o nível máximo de controle. Adotou-se como pressão máxima as pressões de operação fornecidas na Tabela 3 (pág. 12), respectivamente 420,0 mca para o duto RFQ/LPX e de 200,0 mca para o duto LPX/LOR/UPN. Como o SmartPumping expressa as pressões em metro coluna de fluido [mcf], as pressões máximas admissíveis foram convertidas para essa unidade multiplicando o seu valor pela densidade média do sistema, cujo valor é 0,8335. A pressão mínima do sistema foi estimada em 5% da pressão máxima.

Para as restrições de velocidade nos dutos, utilizou-se o valor extremo máximo da vazão de projeto fornecido na Tabela 3 (pág. 12), respectivamente 90,0 m<sup>3</sup>/h para o duto RFQ/LPX e de 225,0 m<sup>3</sup>/h para o duto LPX/LOR/UPN. Tendo disponíveis os diâmetros de cada duto, foram avaliadas as respectivas velocidades máximas admissíveis. A velocidade mínima foi estimada em 5% da velocidade máxima.

Foi atribuído um único sistema tarifário horo-sazonal azul para o sistema, com tarifas vigentes na COSERN desde o dia 01/07/2005 para o sub-grupo A4 (Consumo próprio/Industrial/Comercial/Poder Público). O contrato de demanda simulado estipula uma demanda máxima de 60,0 kW para o período de ponta, entre 17:30 h e 20:30 h, e de 90,0 kW para o período fora de ponta, com tolerância de ultrapassagem de 10% em ambas.

Na Figura 10, vide página seguinte, está representada a rede piloto modelada no SmartPumping, e nas tabelas 5 a 9 (págs. 64 e 65) estão descritos os dados físicos, de previsão de fluido, as restrições operacionais e as tarifas de energia elétrica utilizados nessa modelagem.

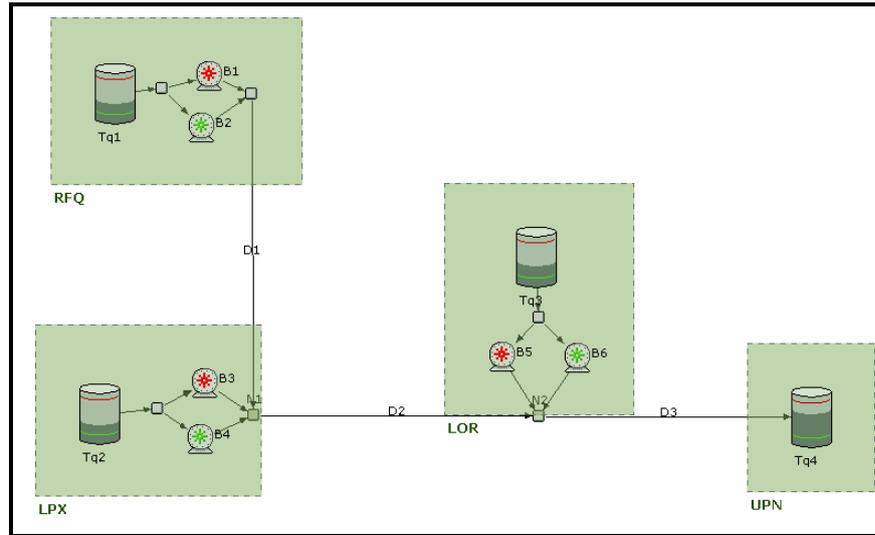


Figura 10 – Rede piloto modelada no SmartPumping.

Tabela 5 – Características físicas das bombas.

Estação	Bomba	Cota [m]	Rendimento do motor [%]	Rendimento da bomba [%]	Curva característica $Q - l/s, H_{man} [m]$
RFQ	B1	89,0	90	90	$H_{man} = -19,19Q + 375,6$
	B2	89,0	90	90	$H_{man} = -19,19Q + 375,6$
LPX	B3	54,5	90	90	$H_{man} = -19,19Q + 375,6$
	B4	54,5	90	90	$H_{man} = -19,19Q + 375,6$
LOR	B5	79,5	90	90	$H_{man} = -41,879Q + 507,02$
	B6	79,5	90	90	$H_{man} = -41,879Q + 507,02$

Tabela 6 – Características físicas dos oleodutos.

Duto	Diâmetro interno [mm]	Comprimento [m]	Pressão admissível [mcf]		Velocidade admissível [m/s]		Cota de montante [m]	Cota de jusante [m]
			Máxima	Mínima	Máxima	Mínima		
D1	154,00	14.000	350,00	17,50	1,34	0,07	89,00	54,50
D2	261,88	17.000	167,00	8,35	1,16	0,06	54,50	79,50
D3	261,88	28.000	167,00	8,35	1,16	0,06	79,50	83,50

Tabela 7 – Características físicas dos tanques.

Estação	Tanque	Cota de fundo [m]	Altura [m]	Nível máximo de controle [m]	Nível mínimo de controle [m]	Área da base [m <sup>2</sup> ]
RFQ	T1	89,00	7,61	6,47	1,14	45,81
LPX	T2	54,50	8,20	6,97	1,23	39,27
LOR	T3	79,50	7,31	6,21	1,10	45,81
UPN	T4	83,50	9,11	7,75	1,37	95,03

Tabela 8 – Previsão da produção do fluido da rede piloto.

Estação	Coeficientes da equação de viscosidade		Vazão de entrada [m <sup>3</sup> /h]	Vazão de saída [m <sup>3</sup> /h]	Massa específica [kg/m <sup>3</sup> ]	Temperatura [°C]
	<i>m</i>	<i>p</i>				
RQF	-5,078	33,012	25,0	-	841,0	40,0
LPX	-3,107	20,372	40,0	-	825,8	40,0
LOR	-3,112	20,437	45,0	-	833,8	40,0
UPN	-	-	-	110,0	-	40,0

Tabela 9 – Tarifas de energia elétrica.<sup>4</sup>

Demanda [R\$/kW]		Demanda de ultrapassagem [R\$/kW]		Consumo [R\$/MWh]			
				Ponta		Fora de Ponta	
Ponta	Fora de Ponta	Ponta	Fora de Ponta	Seca	Úmida	Seca	Úmida
43,45	13,46	130,36	40,37	190,29	172,30	102,93	91,63

## 4.2. Objetivos da operação

Os objetivos da operação abrangidos nesse trabalho consistem em minimizar o custo de energia elétrica da operação, minimizar o número de chaveamentos da operação e minimizar a variação das propriedades do fluido na estação de tratamento de óleo.

A rede piloto utilizada não contém verdadeiramente uma estação de tratamento, e, portanto, não requer uma manutenção da vazão e propriedades do fluido na estação receptora intermediária de Upanema. Mas, como o escopo desse trabalho é avaliar e validar um método multi-objetivo que minimize simultaneamente diversos objetivos da operação, a estação de Upanema será considerada como uma estação de tratamento de óleo.

### Função-objetivo 1: Minimizar o custo de energia elétrica da operação do sistema

Considerado na sua forma unitária, em relação ao volume bombeado para a estação de tratamento de óleo.

$$FOI_{\ell} = \frac{Custo_{\ell}}{Volume_{\ell}} \quad \text{Equação 30}$$

<sup>4</sup> Em vigor a partir de 01/07/2005 com aplicação a partir de 16/09/2005 segundo Resolução Homologatória 103/2005 Anexo II (sem ICMS, PIS e COFINS) – ANEEL.

onde:

$FO1_\ell$  é o valor da função-objetivo referente à minimização do custo de energia elétrica por volume bombeado para o indivíduo  $\ell$ , [R\$/m<sup>3</sup>];

$Custo_\ell$  é o custo de energia elétrica consumida durante o horizonte de operação para o indivíduo  $\ell$ , composto do custo com consumo e demanda de energia, [R\$];

$Volume_\ell$  é o volume entregue na estação receptora para o indivíduo  $\ell$ , [m<sup>3</sup>].

### **Função-objetivo 2: Minimizar o número de chaveamentos da operação**

Representado através da quantidade de vezes que cada bomba do sistema foi acionada durante o horizonte de operação.

$$FO2_\ell = \left( \sum_t \sum_B \max(0, E_{t,B} - E_{t-1,B}) \right)_\ell \quad \text{Equação 31}$$

onde:

$FO2_\ell$  é o valor da função-objetivo referente à minimização do número de chaveamentos durante o horizonte de operação, para o indivíduo  $\ell$ ;

$E_{t,B}$  é o estado da bomba  $B$  no intervalo de atuação  $t$  (0: desligada ou 1: ligada).

### **Função-objetivo 3: Minimizar a variação das propriedades do fluido na estação de tratamento**

Representado através da variação da propriedade desejada para o fluido na estação de tratamento, em relação ao valor simulado dessa propriedade, a qual pode ser expressa em termos de vazão de entrada na estação receptora, BS&W de entrada na estação receptora ou BS&W do fluido da estação receptora, de acordo com os objetivos esperados para a operação.

A equação definida para a minimização da propriedade desejada é genérica não apenas para o tipo da variável, mas também para a forma como se deseja controlar essa variação na estação receptora, podendo ser adaptada a diversos critérios operacionais específicos, conforme descrito nas equações 32 a 34.

$$FO3_{\ell} = \left( \sum_i (Pr_i - Pr d_i) \cdot f(\text{variação}) \right)_{\ell} \quad \text{Equação 32}$$

$$f(\text{variação})_{\text{quadrática}} = (Pr_i - Pr d_i) \quad \text{Equação 33}$$

$$f(\text{variação})_{\text{absoluta}} = \begin{cases} -\kappa, & \text{se } (Pr_i - Pr d_i) \leq 0 \\ 1, & \text{se } (Pr_i - Pr d_i) > 0 \end{cases} \quad \text{Equação 34}$$

onde:

$FO3_{\ell}$  é o valor da função-objetivo referente à minimização da variação da propriedade do fluido na estação receptora para o indivíduo  $\ell$ ;

$Pr_i$  é o valor da propriedade do fluido da estação receptora no intervalo de cálculo  $i$ ;

$Pr d_i$  é o valor desejado para a propriedade do fluido no intervalo de cálculo  $i$ ;

$\kappa$  é o fator de adequação da variação da propriedade ao critério específico desejado.

A função quadrática permite enfatizar, através do quadrado da diferença, as maiores discrepâncias, em detrimento das menores. A função absoluta permite uma flexibilidade maior na consideração da variação da propriedade do fluido escolhida, sendo a forma mais simples, a minimização da variação absoluta, ao utilizar o valor de  $\kappa$  igual a 1.

Utilizar o fator de adequação  $\kappa$  igual a zero equivale a considerar como indesejáveis apenas os valores da propriedade do fluido que forem superiores ao valor desejado, ou seja, o valor desejado é considerado como o valor máximo admissível e deverá ser encontrada uma operação que minimize a variação positiva entre o valor da propriedade resultado da operação e o valor desejado.

Por outro lado,  $\kappa$  entre 0 e 1 permite oferecer um peso maior para as variações positivas em relação às variações negativas. No caso do BS&W, por exemplo, equivale a considerar como mais indesejável o custo de reprocessar o óleo na estação receptora, quando o valor do BS&W ultrapassa o valor desejado, do que o custo referente ao desperdício dos produtos químicos utilizados, quando o valor do BS&W é inferior ao desejado.  $\kappa$  maior que 1 permite oferecer um peso maior para as variações negativas em relação às variações positivas.

### **4.3. Método para otimização multi-objetivo**

Propõe-se aplicar um método multi-objetivo considerando todos os objetivos com o mesmo grau de importância e aplicar uma técnica para reduzir o conjunto de soluções finais encontradas, facilitando a tomada de decisão do usuário. Esse procedimento é considerado ideal por Deb (2001) em relação ao procedimento de atribuir uma informação de preferência prévia do usuário e encontrar uma única solução final.

O método de otimização multi-objetivo escolhido é o SPEA2, o qual, além de aplicar-se a problemas de escalonamentos de bombas, como verificado nos trabalhos correlatos, possui certas características que influenciaram sua escolha, entre as quais se pode citar: 1) a consideração na aptidão dos indivíduos dos conceitos de Pareto e de densidade da vizinhança; dessa forma, o método se propõe a se aproximar progressivamente dos dois critérios estabelecidos para que o resultado de uma otimização multi-objetivo seja considerado de alto desempenho: proximidade e diversidade da fronteira Pareto; 2) o elitismo implícito no método, representado através de uma população externa que armazena as soluções não-dominadas encontradas e é atualizada a cada geração; e 3) a preservação das soluções extremas da fronteira na população externa. As soluções extremas são as soluções que representam o mínimo global de cada função-objetivo, e são importantes não apenas para manter uma boa propagação dos indivíduos da fronteira, mas também porque seriam as soluções ótimas globais obtidas, caso fosse realizada separadamente uma otimização para cada função-objetivo.

#### **4.3.1 Algoritmo evolucionário multi-objetivo SPEA2**

O SPEA2 foi desenvolvido para tentar eliminar as restrições do SPEA e incorporar novas técnicas que melhoram a eficiência do algoritmo. As principais diferenças entre os dois métodos estão sintetizadas no Quadro 2 (pág. 69).

A forma de atribuir a aptidão dos indivíduos foi um dos principais avanços do SPEA2 em relação ao SPEA, pois, no primeiro, quando a população externa contiver apenas uma solução, todos os indivíduos da população corrente terão a mesma aptidão, independentemente de dominarem uns aos outros, provocando uma diminuição na pressão de

seleção, o que aproxima o método de uma busca aleatória. Enquanto que no SPEA2, além de ser considerado na aptidão dos indivíduos da população externa e corrente, tanto o número de indivíduos que o dominam quanto o número de indivíduos dominados por ele, ainda é atribuído um fator relativo à densidade de vizinhança, visando promover a diversidade da fronteira Pareto.

Quadro 2 – Diferenças entre os métodos SPEA e SPEA2.

<b>Características</b>	<b>SPEA</b>	<b>SPEA2</b>
<b>Aptidão dos indivíduos</b>	A aptidão dos indivíduos da população externa é proporcional ao número de indivíduos da população corrente dominados pelo indivíduo em análise. A aptidão dos indivíduos da população corrente é proporcional à aptidão dos indivíduos da população externa que dominam o indivíduo em análise.	A atribuição da aptidão dos indivíduos da população externa e corrente considera, para cada indivíduo, tanto o número de soluções que o dominam quanto o número de soluções dominadas por ele.
<b>Densidade de vizinhança</b>	É considerada implicitamente no algoritmo de agrupamento aplicado na população externa, mas nenhuma informação de densidade da vizinhança é atribuída à população corrente.	Uma técnica de estimativa da densidade da vizinhança é incorporada na aptidão dos indivíduos da população externa e corrente, permitindo uma orientação mais precisa no espaço de busca.
<b>Redução da população externa</b>	O algoritmo de agrupamento promove uma redução na população externa sem destruir as características da fronteira de Pareto mas permite a perda de soluções extremas da fronteira.	Utiliza um método alternativo de truncamento, o qual possui características semelhantes ao algoritmo de agrupamento, mas preserva as soluções extremas.
<b>População externa</b>	A dimensão da população externa varia durante as gerações, permanecendo sempre abaixo ou igual à dimensão máxima. A população externa armazena apenas soluções não-dominadas.	Mantém uma dimensão fixa da população externa preenchendo-a, quando necessário, pelas melhores soluções dominadas da população corrente.
<b>Operador de seleção</b>	É aplicado tanto na população externa quanto na população corrente.	É aplicado apenas na população externa.

O método SPEA2 inicia seu algoritmo gerando duas populações, a população inicial ( $Pop_G$ ) preenchida por indivíduos gerados aleatoriamente, e uma população externa, denominada de arquivo, gerada inicialmente vazia ( $\overline{Pop}_G = \emptyset$ ). Em cada geração, após a definição da população corrente e da população externa (arquivo), cada indivíduo da população corrente é avaliado com respeito às funções-objetivo a serem otimizadas, e, em seguida, é avaliado com respeito às relações de dominância (o número de indivíduos dominados por ele e que o dominam) considerando o conjunto que representa a união da população corrente com a população externa ( $PU_G = Pop_G \cup \overline{Pop}_G$ ).

Para cada indivíduo de  $PU_G$ , é calculado o valor do *Strength* -  $S_{\ell,G}$ , equivalente ao número de indivíduos dominados pelo indivíduo em análise (Equação 35) e o valor do *Raw Fitness* -  $RF_{\ell,G}$ , equivalente ao somatório dos *Strengths* dos indivíduos que dominam o indivíduo em análise (Equação 36).

$$S_{\ell,G} = |\{\delta \mid \delta \in PU_G \wedge \ell \prec \delta\}| \quad \text{Equação 35}$$

$$RF_{\ell,G} = \sum_{\alpha \in PU_G \mid \alpha \prec \ell} S_{\alpha,G} \quad \text{Equação 36}$$

onde:

$S_{\ell,G}$  é o valor do *Strength* do indivíduo  $\ell$  na geração  $G$ ;

$\delta$  é um indivíduo da população externa dominado pelo indivíduo  $\ell$ ;

$PU_G$  é o conjunto formado pela união da população corrente com a população externa da geração  $G$ ;

$|\cdot|$  representa a cardinalidade do conjunto;

$\ell \prec \delta$  significa que  $\ell$  domina  $\delta$ , ou seja, que a seguinte condição foi satisfeita:

$$\{\forall i : FO_i(X_1) \leq FO_i(X_2)\} \text{ e } \{\exists j : FO_j(X_1) \prec FO_j(X_2)\}$$

$RF_{\ell,G}$  é o valor do *Raw Fitness* do indivíduo  $\ell$  na geração  $G$ ;

$S_{\alpha,G}$  é o valor do *Strength* do indivíduo  $\alpha$  na geração  $G$ ;

$\alpha$  é um indivíduo da população externa que domina o indivíduo  $\ell$ .

O valor do *Strength* será tanto maior quanto mais indivíduos forem dominados pela solução em análise, enquanto que o valor do *Raw Fitness* será tanto menor quanto menos

indivíduos dominarem a solução em análise, de modo que, se a solução for não-dominada, o valor do *Raw Fitness* será zero.

Quando muitos indivíduos da população corrente são indiferentes entre si (ou seja, não dominam uns aos outros), nenhuma ou pouca informação pode ser extraída dos conceitos de dominância. No SPEA2, por exemplo, todos os indivíduos não-dominados terão o mesmo valor do *Raw fitness*, e, nesse caso, a informação de densidade da vizinhança é crucial para determinar quais indivíduos são mais aptos e guiar a busca mais eficientemente. Em cada indivíduo de  $PU_G$ , é atribuída essa informação através de uma função decrescente da distância do  $k$ -ésimo vizinho mais próximo do indivíduo em análise (Equação 37). Nesse trabalho foi considerado o valor de  $k$  igual a 1, portanto, após calcular a distância euclidiana<sup>5</sup> entre todos os indivíduos de  $PU_G$ , apenas a menor dessas distâncias será considerada no cálculo da densidade de vizinhança.

$$D_{\ell,G} = \frac{1}{\sigma_{\ell}^k + 2} \quad \text{Equação 37}$$

onde:

$D_{\ell,G}$  é o valor da densidade de vizinhança do indivíduo  $\ell$  na geração  $G$ ;

$\sigma_{\ell}^k$  é a distância euclidiana entre os indivíduos  $\ell$  e  $k$ , ou, para  $k = 1$ , é a distância euclidiana de  $\ell$  para o seu vizinho mais próximo.

O valor da densidade de vizinhança varia desde um valor mínimo próximo de 0 até 0,50, assumindo o valor máximo para indivíduos iguais, e, portanto, com distância euclidiana igual a zero. Quanto menor a densidade de vizinhança do indivíduo, mais isolada está a solução, portanto, mais apta a ser preservada por tentar manter o critério da diversidade.

Após definidos o valor do *Raw Fitness* e da densidade de vizinhança de cada indivíduo em uma geração, o valor da aptidão ( $Fitness - F_{\ell,G}$ ) será dado pelo somatório dessas duas variáveis (Equação 38). Quanto menor o valor do *Fitness* de um indivíduo, mais apto ele está para se propagar e disseminar suas características nas próximas gerações.

---

<sup>5</sup> A distância entre dois pontos  $P1$  e  $P2$  de coordenadas  $(x1, y1)$  e  $(x2, y2)$ , respectivamente, é dada pela fórmula  $d(P1, P2) = \sqrt{(x2 - x1)^2 + (y2 - y1)^2}$ , e é chamada de distância Euclidiana. No método multi-objetivo, as coordenadas representam os valores de funções-objetivo, e devem ser normalizadas antes do cálculo da distância.

$$F_{\ell,G} = RF_{\ell,G} + D_{\ell,G} \quad \text{Equação 38}$$

onde:

$F_{\ell,G}$  é o valor da aptidão do indivíduo  $\ell$  na geração  $G$ .

Todas as soluções não-dominadas do conjunto  $PU_G$  são transferidas para a população externa da próxima geração  $\overline{Pop}_{G+1}$ , sendo avaliadas novamente as relações de dominância das novas soluções inseridas com as já contidas nesse conjunto, mantendo-se no mesmo apenas as soluções não-dominadas. Caso a população externa não seja totalmente preenchida, é completada com os indivíduos dominados de  $PU_G$ , ordenados em ordem crescente do valor de *Fitness*.

Caso a dimensão ultrapasse o valor pré-determinado, é aplicado um algoritmo de corte para eliminar os indivíduos excedentes. O algoritmo de corte é um processo iterativo que reduz, a cada iteração, o indivíduo tal que a sua distância euclidiana para o vizinho mais próximo seja a mínima. E em caso de empate, verifica-se a segunda menor distância euclidiana, e assim por diante. De modo matemático, remove-se o indivíduo  $\ell$ , tal que  $\ell \leq d\delta$  para todo  $\delta \in \overline{Pop}_{G+1}$  (Equação 39). O processo iterativo se encerra quando a dimensão da população externa atinge o valor pré-definido.

$$\begin{aligned} \ell \leq d\delta \quad :\Leftrightarrow \quad & \forall 0 < k < |\overline{Pop}_{G+1}| : \sigma_\ell^k = \sigma_\delta^k \quad \vee \\ & \exists 0 < k < |\overline{Pop}_{G+1}| : [(\forall 0 < \lambda < k : \sigma_\ell^\lambda = \sigma_\delta^\lambda) \wedge \sigma_\ell^k < \sigma_\delta^k] \end{aligned} \quad \text{Equação 39}$$

onde:

$\ell$ ,  $\delta$ ,  $\lambda$ ,  $k$  são indivíduos da população externa  $\overline{Pop}_{G+1}$ .

Depois de estabelecida a população externa da nova geração, é avaliado o critério de parada do algoritmo. Caso o critério não seja atendido, os indivíduos dessa população são selecionados através do operador de seleção por torneio, cujo campeão é o indivíduo de menor valor de *Fitness*. Os indivíduos selecionados são enviados aos operadores de reprodução, os quais irão gerar os novos indivíduos da população  $Pop_{G+1}$ , reiniciando o ciclo.

### 4.3.2 Inclusão do conceito de viabilidade no método SPEA2

Como a aptidão dos indivíduos dada pelo método SPEA2 considera apenas os conceitos de dominância e de densidade de vizinhança, algumas adaptações foram inseridas no algoritmo do SPEA2 para considerar também o conceito de viabilidade das soluções. Essas modificações foram incorporadas em dois lugares específicos do algoritmo do SPEA2: no preenchimento da população externa da próxima geração e na seleção dos indivíduos para reprodução.

#### Preenchimento da população externa

De uma maneira geral, os indivíduos viáveis devem sempre ser priorizados em relação aos inviáveis, e, entre si, os melhores indivíduos viáveis são os que possuem menor *Fitness* -  $F$ , definido no algoritmo do SPEA2 e que incorpora no seu valor os conceitos de dominância.

Entre os indivíduos inviáveis, antes de considerar o valor do *Fitness* na análise, deverá ser considerado o ponto de falha do cromossomo e o tipo de alarme que ocorre nesse intervalo. Indivíduos com pontos de falha mais tardios deverão ser priorizados sobre indivíduos onde o alarme ocorre nos primeiros intervalos de atuação, da mesma forma que o tipo de alarme detectado no ponto de falha também deve ser considerado no critério de escolha dos indivíduos. Alarmes de pressão máxima, velocidade máxima e nível máximo são considerados de maior severidade por poder ocasionar danos aos dutos ou poluição ambiental.

Ao invés de selecionar as soluções não-dominadas da população para compor a população externa, deverão ser selecionadas as soluções não-dominadas viáveis. Caso a dimensão da população externa não atinja o limite estabelecido, as soluções que restaram na população corrente deverão ser ordenadas considerando a viabilidade, o critério de dominância, a aptidão das soluções, o ponto de falha e a severidade da restrição. Os critérios são os seguintes: as soluções viáveis vêm sempre no topo, ordenadas em ordem crescente de *Fitness*, seguida das inviáveis não-dominadas e logo após as inviáveis dominadas. Entre as soluções inviáveis, consideram-se como mais aptas aquelas que têm o ponto de falha mais próximo do final do cromossomo. Havendo empate, considera-se como mais apta aquela que violou o alarme de menor severidade no ponto de falha, segundo classificação do Quadro 3; caso o empate persista, considera-se como mais apta a que tiver o menor valor de *Fitness*.

Quadro 3 – Severidade das restrições violadas.

<b>Restrição Violada</b>	<b>Severidade</b>
Tanque atinge o nível máximo	Alta
Tanque atinge o nível mínimo	Baixa
Duto atinge pressão máxima	Alta
Duto atinge pressão mínima	Baixa
Fluido atinge velocidade mínima em um duto	Baixa
Fluido atinge velocidade máxima em um duto	Alta

A viabilidade e a dominância podem ser consideradas simultaneamente de duas maneiras. A primeira inicia a análise separando os indivíduos não-dominados dos dominados para, em seguida, verificar os conceitos de viabilidade em cada sub-grupo. Ao final, serão formados quatro grupos de soluções, cujo grupo composto pelas soluções não-dominadas viáveis será transferido integralmente para a população externa (arquivo), e, caso necessário, essa população será preenchida com indivíduos do grupo de dominados viáveis, seguido do grupo de não-dominados inviáveis e dominados inviáveis. Através dessa análise, um indivíduo é dito não-dominado viável se não houver, em toda a população, nenhum indivíduo que o domine e se não violar qualquer restrição operacional do sistema (não possuir alarmes). Esse procedimento de consideração da viabilidade está esquematizado na Figura 11 (pág. 75)

Na segunda forma, inicialmente separam-se os indivíduos viáveis dos inviáveis em dois sub-grupos, para depois serem avaliadas as relações de dominância (Figura 12, pág. 75). Dessa forma, as relações de dominância são consideradas separadamente em cada sub-grupo, e não no conjunto todo, fazendo com que, os valores de *Strentgh*, *Raw Fitness* e *Fitness* também sejam avaliados em separado para cada sub-grupo. Logo, um indivíduo é dito viável não dominado se não violar nenhuma restrição operacional e não houver, no sub-grupo dos indivíduos viáveis, nenhum indivíduo que o domine. Após a separação dos grupos, a ordem de preenchimento da população externa se mantém inalterada: viáveis não dominados (integralmente) e, na quantidade necessária: viáveis dominados, inviáveis não-dominados e inviáveis dominados.

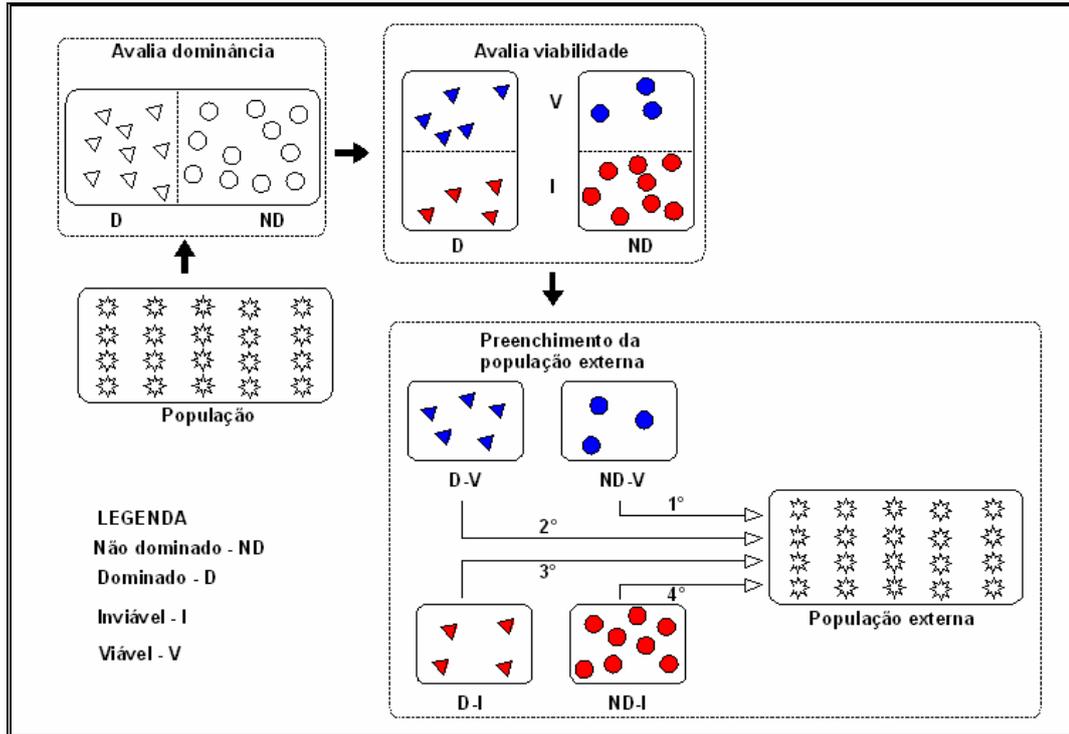


Figura 11 – Classificação dos indivíduos considerando inicialmente as relações de dominância.

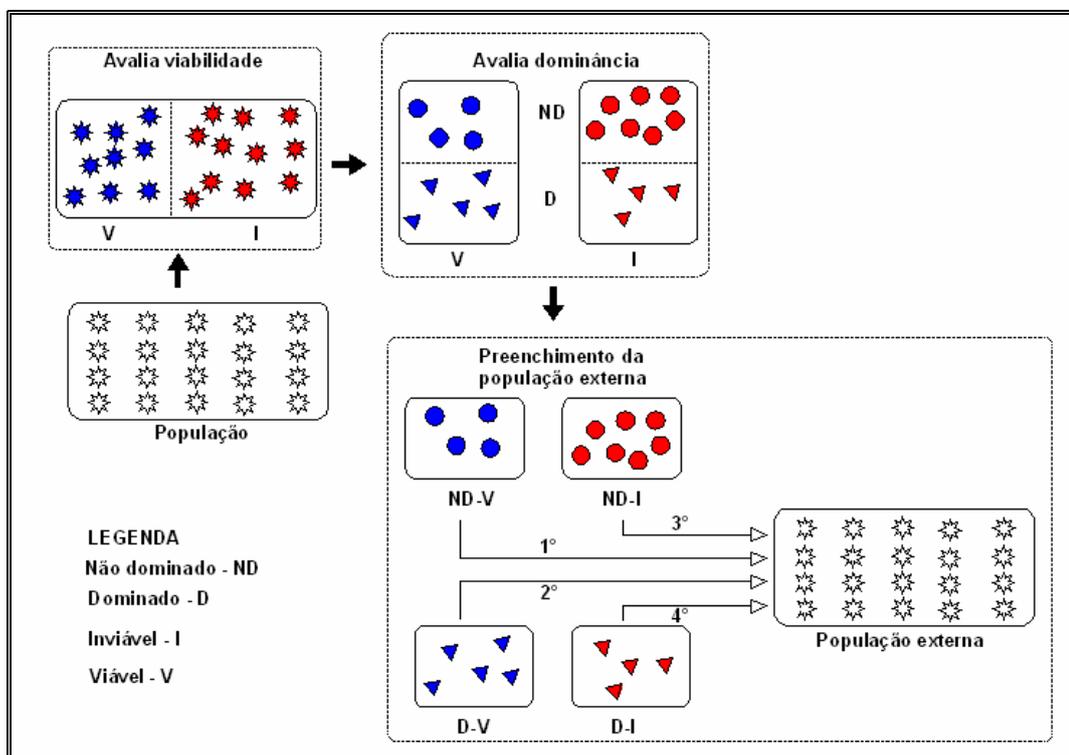


Figura 12 – Classificação dos indivíduos considerando inicialmente o conceito de viabilidade.

### Seleção dos indivíduos para reprodução

O algoritmo original do SPEA2 utiliza o método de seleção por torneio, cujo campeão é a solução de menor *Fitness*. Foi avaliada nesse trabalho a introdução da viabilidade na seleção por torneio, da seguinte forma: 1) entre um indivíduo viável e um inviável, seleciona-se o indivíduo viável; 2) entre dois indivíduos viáveis, seleciona-se aquele de menor *Fitness*; e 3) entre dois indivíduos inviáveis, seleciona-se aquele em que o ponto de falha está mais próximo do final do horizonte de operação e, caso ocorra empate, seleciona-se o indivíduo que violou o alarme de menor severidade; persistindo o empate seleciona-se o indivíduo de menor valor de *Fitness*.

Alternativamente, foi avaliada também uma analogia à metodologia de seleção utilizada em Brasileiro (2005), a qual consiste em selecionar os indivíduos utilizando o Método da Amostragem Estocástica Universal (*Stochastic Universal Sampling – SUS*), considerando uma aptidão relativa à posição do indivíduo após terem sido ordenados.

Utilizando essa metodologia alternativa, inicialmente os indivíduos são ordenados do menos apto para o mais apto, considerando os mesmos critérios definidos anteriormente: um indivíduo viável é sempre mais apto do que um inviável; entre dois viáveis, o mais apto será o de menor valor de *Fitness*; e, entre dois inviáveis, o mais apto será o de maior ponto de falha, em caso de empate, o de menor severidade do alarme e, persistindo o empate, o de menor valor de *Fitness*. Após o ordenamento, uma aptidão relativa à sua posição é atribuída utilizando-se o método do ordenamento linear (Equação 1, pág. 25), com valores de  $Max = 2,0$  e  $Min = 0,0$ .

### 4.3.3 Representação das soluções e geração da população inicial

Cada solução para o problema consiste em um escalonamento das bombas no horizonte de operação e será representado na forma binária, a qual é considerada por Mackle *et al.* (1995) como uma escolha óbvia, uma vez que cada valor binário representa uma bomba que será ligada ou desligada em determinado período de tempo.

O cromossomo formado representa uma matriz bi-dimensional tempo versus bomba, como representado na Figura 13, onde cada bit assume o valor 0 para uma bomba *B* desligada durante determinado intervalo de atuação *t* e 1 para bomba ligada. Esse tipo de representação

binária na forma matricial foi adotado por Brasileiro (2005) para preservar a semântica do problema e permitir a preservação do sentido temporal da estrutura.

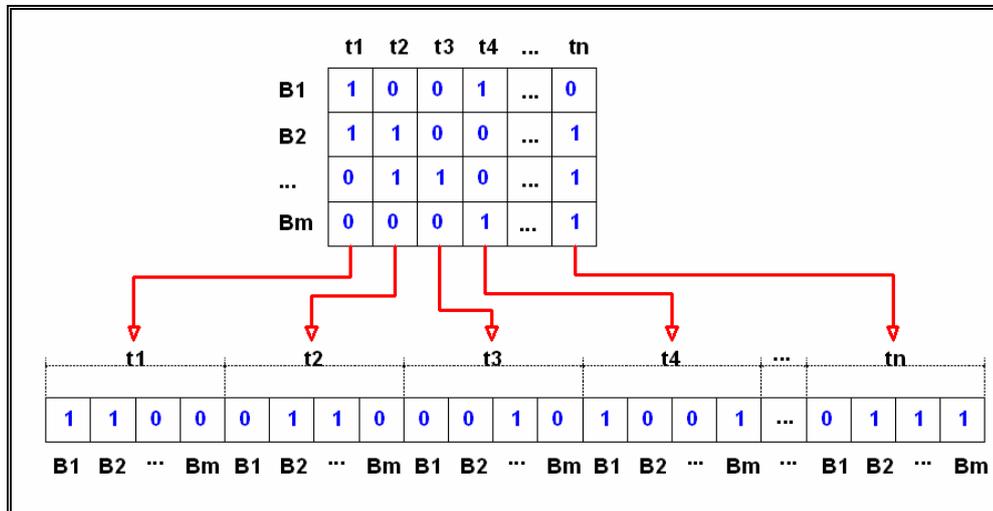


Figura 13 – Representação do cromossomo.

A população inicial é gerada randomicamente sendo associada à técnica de *seeding*, a qual insere a solução gerada utilizando o calculador de solução viável – CSV definido por Brasileiro (*op. cit.*). Caso a solução gerada pelo calculador de solução viável apresente alguma inviabilidade, ainda assim será inserida na população inicial, onde se espera que a alta aptidão dessa solução acelere a busca por uma solução viável.

Para cada intervalo de atuação, o algoritmo do CSV define uma configuração inicial das bombas baseada no nível atual dos tanques. Cada tanque produtor é dividido em três partes iguais, conforme sua capacidade de volume desde a base do tanque até seu nível máximo de controle. Se o nível do tanque estiver no primeiro terço da divisão e o tanque, portanto, estiver com um nível baixo de fluido, as bombas associadas a esse tanque serão desligadas. Se o nível estiver no último terço, e o tanque, portanto, estiver próximo a sua capacidade máxima, as bombas serão ligadas. E, finalmente, se o nível do tanque estiver no segundo terço, a decisão é baseada no nível do tanque receptor da rede da estação de tratamento. Caso este tanque esteja com o nível abaixo ou acima da metade da sua capacidade, as bombas são ligadas ou desligadas, respectivamente.

Depois de estabelecida a configuração das bombas, é realizada a simulação do intervalo de atuação, e, caso ocorra algum alarme, indicando que alguma restrição do sistema foi

violada e que, portanto, a solução é inviável, são efetuadas modificações na configuração das bombas de acordo com as regras de operação do Quadro 4.

Para evitar que o algoritmo fique preso em um laço infinito, com a aplicação sucessiva das estratégias de reparo, as ações tomadas para solucionar o alarme, em um dado intervalo de atuação, são registradas. Portanto, quando a simulação de um escalonamento resulta em um alarme, mas não é possível corrigi-lo, pois todas as operações de liga/desliga das bombas já foram testadas, o calculador considera o intervalo atual como concluído e avança para o intervalo seguinte. Depois de finalizada a busca, a solução encontrada, mesmo que não seja viável, é introduzida na população inicial.

Quadro 4 – Estratégias de reparo do calculador de solução viável.

<b>Restrição Violada</b>	<b>Ação de reparo</b>
Tanque produtor atinge o nível máximo	Liga-se uma bomba associada a esse tanque
Tanque produtor atinge o nível mínimo	Desliga-se uma bomba associada a esse tanque
Tanque receptor atinge o nível máximo	Desliga-se uma bomba do tanque produtor de menor nível
Tanque receptor atinge o nível mínimo	Liga-se uma bomba do tanque produtor de maior nível
Duto atinge pressão máxima	Desliga-se uma bomba a montante do duto
Duto atinge pressão mínima	Liga-se uma bomba a montante do duto
Fluido atinge velocidade mínima em um duto	Liga-se uma bomba a montante do duto
Fluido atinge velocidade máxima em um duto	Desliga-se uma bomba a montante do duto

#### **4.3.4 Operadores de reprodução direcionados**

##### **Operadores de reprodução direcionados propostos por Brasileiro (2005)**

Em conjunto com os operadores tradicionais de cruzamento de um ponto e de mutação, Brasileiro (2005) propôs utilizar, em um problema semelhante de escalonamento de bombas de um sistema de escoamento de petróleo, operadores de reprodução inteligentes denominados de mutação direcionada e cruzamento direcionado. Esses operadores utilizam informações referentes aos pontos de falha das soluções para definir a posição de recombinação ou de mutação e tentar gerar indivíduos mais aptos e com mais chances de viabilidade.

O cruzamento direcionado compara o ponto de falha dos dois cromossomos selecionados para reprodução, toma a posição referente ao ponto de falha mais prematuro entre os dois cromossomos, e realiza a permutação dois intervalos de atuação anteriores a esse ponto de falha selecionado, conforme indicado na Figura 14. A decisão de retroceder duas posições é arbitrária e foi adotada por Brasileiro (2005) para tentar corrigir a falha no cromossomo e aumentar as chances de gerar um descendente viável. No entanto, o número de intervalos a serem retrocedidos pode ser estimado em outro valor, inclusive considerando a duração adotada para o intervalo de atuação. Após o cruzamento, é aplicada a mutação tradicional em uma porcentagem de bombas de um intervalo de tempo escolhido aleatoriamente.

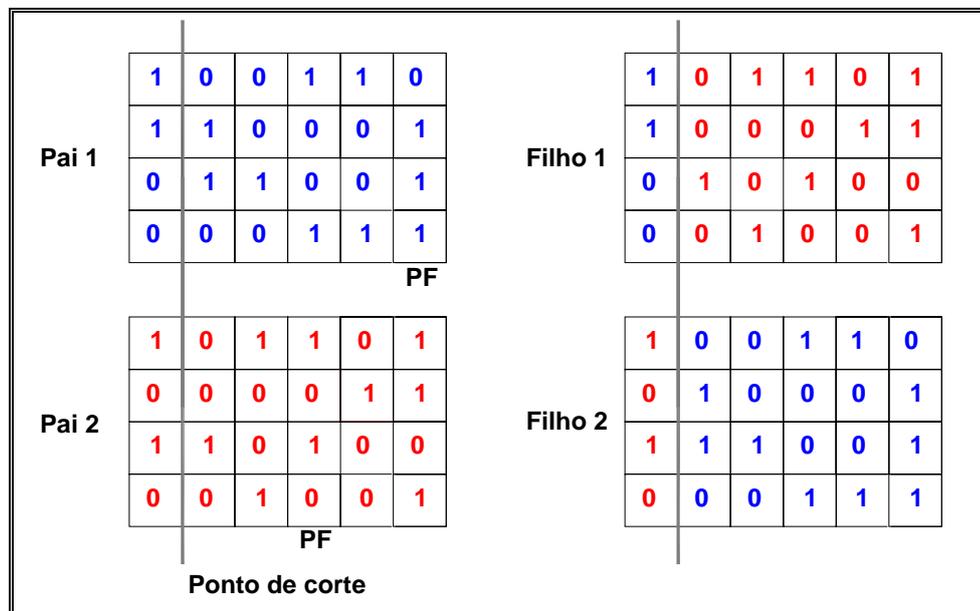


Figura 14 – Cruzamento direcionado proposto por Brasileiro (2005).

Quando o ponto de falha mais prematuro dos cromossomos selecionados para reprodução ocorre nos dois primeiros intervalos de tempo, o cruzamento direcionado é substituído pela mutação direcionada seguida de um cruzamento tradicional. Nesse caso, a mutação direcionada inverte o estado de bombas em porcentagem estabelecida no primeiro intervalo de tempo. A mutação direcionada seguida de um cruzamento tradicional também ocorre quando os pontos de falha dos dois cromossomos selecionados para reprodução estiverem situados no mesmo intervalo de tempo, sendo aplicada duas posições anteriores a esse ponto de falha.

### Operadores de reprodução direcionados propostos por Machado *et al.* (2005)

Uma mutação direcionada alternativa foi utilizada em Machado *et al.* (2005) para o escalonamento de bombas em adutoras visando a otimização de uma função-objetivo de custo de energia. A principal diferença entre os operadores de reprodução propostos por Brasileiro (2005) e os definidos em Machado *et al.* (2005) reside na operação da mutação e na ordem de aplicação dos operadores direcionados em conjunto com os operadores tradicionais.

A mutação direcionada alternativa possui duas peculiaridades básicas: é aplicada apenas em alguns indivíduos inviáveis com ponto de falha diferente de zero (pois o intervalo de atuação zero corresponde à configuração inicial do sistema e é imutável) e a escolha dos prováveis bits, que sofrerão mutação, é baseada nos pontos de falha dos indivíduos e no tipo de alarme violado, servindo assim como uma espécie de reparo dos indivíduos. Dessa forma pretende-se tornar a mutação direcionada mais eficaz, pois, além de se basear no ponto de falha do cromossomo, sugere inversões nos bits ideais para o tipo de falha encontrado.

A mutação direcionada alternativa é aplicada individualmente aos pais selecionados, seguindo os critérios descritos na Tabela 10. A primeira coluna da tabela indica o tipo de alarme encontrado no ponto de falha, a segunda coluna representa a posição do ponto de falha no cromossomo; a terceira coluna, por sua vez, indica os bits nas quais a probabilidade de mutação direcionada deve ser avaliada, e a quarta, por fim, indica o reparo a ser realizado caso a probabilidade de mutação seja atendida.

Tabela 10 – Critérios para aplicação da mutação direcionada alternativa.

Caso	Restrição violada (alarme)	Ponto de falha	Bits avaliados	Ação
1	Velocidade máxima ou pressão máxima,	$\geq 1$	= 1 do PF <sup>I</sup>	Inverte para 0
2	Velocidade mínima ou pressão mínima	$\geq 1$	= 0 do PF	Inverte para 1
3	Nível máximo do tanque receptor ou nível mínimo do tanque produtor	1 ou 2	= 1 do PF	Inverte para 0
4	Nível máximo do tanque receptor ou nível mínimo do tanque produtor	$\geq 3$	= 1 do PAF <sup>II</sup>	Inverte para 0
5	Nível máximo do tanque produtor	1 ou 2	= 0 do PF	Inverte para 1
6	Nível máximo do tanque produtor ou nível mínimo do tanque receptor	$\geq 3$	= 0 do PAF	Inverte para 1

I – intervalo de atuação do ponto de falha.

II – intervalo de atuação que correspondente ao retrocesso de dois intervalos do ponto de falha.

Em cromossomos com alarmes de velocidade ou de pressão no ponto de falha (Casos 1 e 2 da Tabela 10) a mutação direcionada vai atuar no próprio ponto de falha, invertendo os valores dos bits 1 para 0, no caso de pressão ou velocidade máxima, ou de 0 para 1, no caso de pressão ou velocidade mínima. Antes de cada inversão de bit é avaliada a probabilidade de mutação direcionada definida, através da geração de uma porcentagem aleatória para cada bit a ser avaliado; se a porcentagem for menor do que a probabilidade de mutação, a inversão será efetivada.

Se o alarme detectado for de nível máximo ou mínimo (Casos 3 a 6 da Tabela 10), a mutação direcionada deverá atuar no intervalo de atuação que corresponde ao retrocesso de dois intervalos do ponto de falha. O retrocesso é adotado porque inversões de bits no próprio ponto de falha não acarretarão mudanças no nível nesse intervalo, que é resultado do balanço hídrico do intervalo anterior e, portanto, da configuração das bombas do estado anterior. Caso o ponto de falha seja o primeiro ou o segundo intervalo de atuação (Casos 3 e 5), a mutação direcionada é aplicada no próprio ponto de falha, o que, em casos específicos, pode solucionar o alarme de nível do tanque.

Um alarme de nível máximo é detectado no SmartPumping cada vez que o tanque atinge o nível máximo de controle e que a vazão de entrada do tanque é superior à vazão de saída, o que indica que a tendência é provocar o transbordo. No entanto, caso a vazão de saída seja maior do que a vazão de entrada, o alarme não é detectado pois, teoricamente, a configuração atual das bombas já está adequada. A mesma analogia é feita para o alarme de nível mínimo. Desse modo, a atuação da mutação direcionada no próprio ponto de falha, apesar de não ser ideal, pode eliminar o alarme de nível de um tanque.

Nos operadores de reprodução propostos por Machado *et al.* (2005), a ordem de aplicação dos operadores para geração da nova população foi modificada em relação à proposta por Brasileiro (2005). Afinal, tinha-se o objetivo de intensificar a ação da mutação direcionada, que passa a ser aplicada também em todos os indivíduos enviados para o operador tradicional de cruzamento.

Na Figura 15, é mostrado um fluxograma com a ordem de aplicação desses operadores de reprodução. Dos indivíduos selecionados para a reprodução, pares de cromossomos em quantidade definida previamente seguem para o operador de cruzamento direcionado e os demais para o operador tradicional de cruzamento de um ponto.

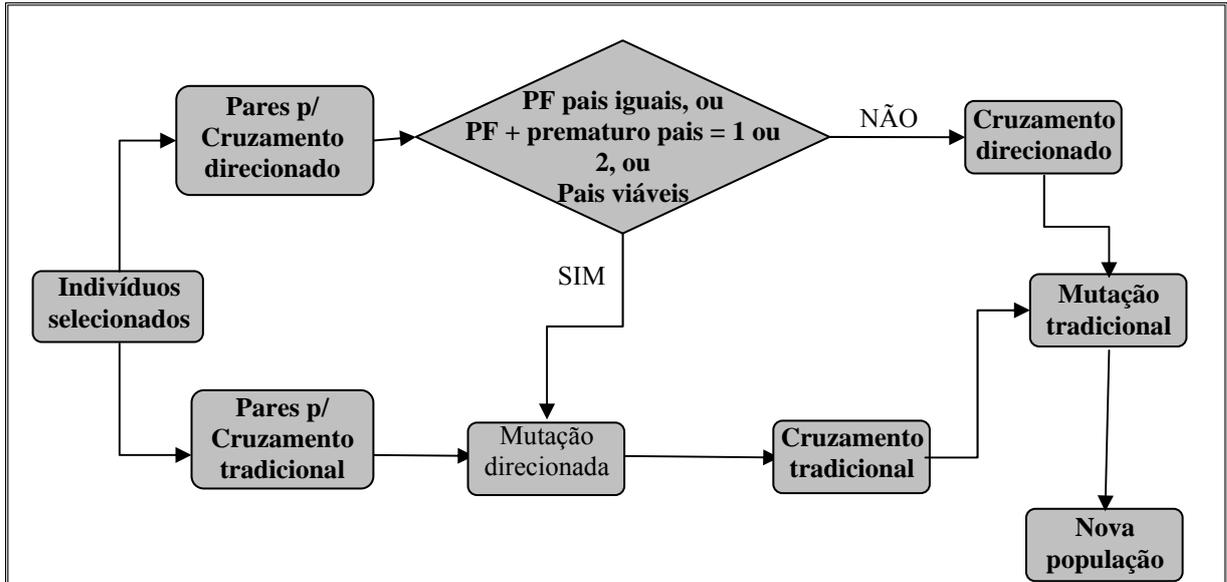


Figura 15 – Fluxograma de aplicação dos operadores para geração da nova população.

Os pares enviados para o cruzamento tradicional são submetidos inicialmente ao operador de mutação direcionada, para só então ser aplicado o operador tradicional de cruzamento. O fato de a mutação direcionada ser aplicada antes do cruzamento é devido à utilização, naquele operador, de informações características do cromossomo, as quais são perdidas após qualquer alteração no mesmo.

Dos pares que seguem para o cruzamento direcionado, apenas alguns irão realmente sofrer a ação desse operador. Aqueles pares cujos indivíduos possuem pontos de falhas iguais, ou cujo ponto de falha mais prematura entre os pais for igual a 1 ou 2, ou ainda os pares compostos por soluções viáveis, seguirão a seqüência de operações definidas anteriormente: mutação direcionada seguida de cruzamento tradicional.

Finalmente, após a aplicação do operador de cruzamento, seja ele direcionado ou tradicional, todos os indivíduos sofrem a atuação do operador tradicional de mutação bit a bit, para enfim compor os indivíduos da nova população.

#### 4.3.5 Descarte e reparo de indivíduos inviáveis

A regra de descarte desenvolvida por Brasileiro (2005) objetiva avaliar as soluções antes mesmo que a simulação da operação ocorra e fundamenta-se no descarte de soluções

que resultem em alarmes de nível máximo nos tanques produtores. A avaliação é simples: a partir da mínima vazão de entrada prevista para os tanques produtores, calcula-se o tempo máximo necessário para encher cada tanque, considerando o volume útil dos mesmos, caso todas as bombas associadas a ele estejam desligadas. As soluções serão descartadas se apresentarem as bombas associadas àquele tanque desligadas por um número de intervalos de atuação superior ou igual ao tempo de enchimento calculado através da Equação 40.

$$t_{\min} = \left\lceil \frac{(NC_{\max} - NC_{\min}) \cdot AB}{(Qe_{\min} \cdot \Delta t)} \right\rceil \quad \text{Equação 40}$$

onde:

$t_{\min}$  é o número mínimo de intervalos de atuação para violar a regra caso todas as bombas conectadas ao tanque permaneçam desligadas;

$NC_{\max}$  e  $NC_{\min}$  são os níveis de controle do tanque, [m];

$\Delta t$  é a duração do intervalo de atuação, [s];

$Qe_{\min}$  é a mínima vazão de entrada no tanque durante o horizonte de operação, [m<sup>3</sup>/s].

A regra de descarte será introduzida no algoritmo multi-objetivo em dois lugares: 1) na geração da população inicial, no qual novos indivíduos serão gerados aleatoriamente para substituir os indivíduos descartados; e 2) após a aplicação dos operadores de reprodução, onde, caso seja detectada a violação da regra, novos pais serão selecionados para a reprodução. Na geração da população inicial, será estipulado o número máximo de tentativas igual ao número de bits do cromossomo, para cada indivíduo avaliado. Ultrapassado esse valor máximo, caso o indivíduo gerado aleatoriamente continue violando a regra de descarte, mesmo assim será introduzido na população inicial. Na reprodução, o número máximo de tentativas será limitado a cinco. Caso o indivíduo gerado persista violando a regra, os pais, no caso do cruzamento, ou o indivíduo original, no caso da mutação, serão introduzidos na nova população.

Alternativamente à regra de descarte deverá ser avaliada a regra de reparo, segundo a qual, ao invés de descartar simplesmente, repara o indivíduo que viola o critério do nível máximo dos tanques produtores, ligando bombas em intervalos de atuação estratégicos para evitar essa inviabilidade: ligam-se todas as bombas conectadas ao tanque a cada  $t_{\min}$  bits na seqüência onde foi detectada a inviabilidade. Dessa forma, pretende-se agilizar a conversão de

uma solução inviável em uma solução viável, e diminuir o número de tentativas necessárias para gerar uma população.

A Figura 16 mostra o exemplo de atuação da regra de reparo em um indivíduo cujo tanque está conectado a três bombas e possui  $t_{\min}$  igual a 3.

Antes do reparo														
	t1	t2	t3	t4	t5	t6	t7	t8	t9	t10	t11	t12	t13	t14
<b>B1</b>	0	0	0	0	0	0	0	0	0	0	1	0	0	1
<b>B2</b>	1	1	0	0	0	0	0	0	0	0	1	1	1	1
<b>B3</b>	0	0	0	0	0	0	0	0	0	0	0	0	0	0

Depois do reparo														
	t1	t2	t3	t4	t5	t6	t7	t8	t9	t10	t11	t12	t13	t14
<b>B1</b>	0	0	0	0	1	0	0	1	0	0	1	0	0	1
<b>B2</b>	1	1	0	0	1	0	0	1	0	0	1	1	1	1
<b>B3</b>	0	0	0	0	1	0	0	1	0	0	0	0	0	0

Figura 16 – Exemplo de atuação da regra de reparo.

#### 4.3.6 Redução do conjunto final e escolha da solução

O SPEA2, assim como a maioria dos métodos evolucionários multi-objetivo, utiliza uma dimensão de população externa geralmente em torno 100 indivíduos para manter a boa evolução do método e suprir a complexidade do problema. Na prática, em uma otimização de um cenário real, o usuário está interessado em um conjunto muito inferior de soluções para seu problema; segundo Deb (2001), na maioria dos casos, 5 a 10 soluções finais são suficientes. O que se espera do SPEA2 é que, ao final da otimização, toda ou boa parte da população externa esteja preenchida por indivíduos não-dominados (nesse caso, não-dominados viáveis). Daí a necessidade de adotar uma técnica de redução desse conjunto final para um conjunto reduzido, ou uma única solução final, auxiliando a tomada de decisão do usuário.

No presente trabalho, propõe-se reduzir o conjunto de soluções finais obtido eliminando-se inicialmente as soluções repetidas, as inviáveis e as dominadas. Após esse tratamento inicial, serão removidas desse conjunto e alocadas em um conjunto final reduzido, obrigatoriamente, as soluções que representam os extremos mínimos globais de cada função-objetivo. As demais soluções escolhidas para preencher o conjunto reduzido, em um total de cinco soluções, deverão ser representativas das soluções que restaram, e será adotada, como recomendado por Deb (2001), a técnica do algoritmo de agrupamento (*Clustering Method*), utilizado em Zitzler e Thiele (1998), para escolhê-las.

No algoritmo de agrupamento, inicialmente, cada solução é atribuída a um grupo individual, e, a cada passo do algoritmo, são escolhidos os dois grupos com as mínimas distâncias entre seus elementos para formarem um grupo maior. A distância entre dois grupos ( $C_k$  e  $C_p$ ) é dada pela média da distância euclidiana de todos os pares de soluções pertencentes a cada um dos grupos ( $\ell \in C_k$  e  $\delta \in C_p$ ), ou matematicamente, conforme Equação 41.

$$dc_{kp} = \frac{1}{|C_k||C_p|} \sum_{\ell \in C_k, \delta \in C_p} \sigma_{\ell}^{\delta} \quad \text{Equação 41}$$

onde:

$\sigma_{\ell}^{\delta}$  é a distância euclidiana entre o indivíduo  $\ell$ , do grupo  $C_k$  e o indivíduo  $\delta$ , do grupo  $C_p$  ;  
 $|\cdot|$  representa a cardinalidade do conjunto, ou seja, o número de indivíduos do grupo.

Quando a quantidade de grupos atingir o número de soluções desejadas, a solução que estiver mais próxima do centróide do grupo, ou seja, aquela que possuir a mínima distância para todas as outras soluções do grupo, será a escolhida para ser a representante do grupo.

Do conjunto final reduzido, caso seja necessário escolher uma única solução para aplicação no problema, pode-se utilizar uma das duas alternativas sugeridas a seguir. A primeira consiste em normalizar os valores das funções-objetivo e calcular o valor da função ponderada (Equação 42) atribuindo os pesos desejados para cada objetivo. Ao final, a solução que possuir o mínimo valor da função ponderada, será a escolhida.

$$FP_{\ell} = (peso_1.FO1_{\ell}^{Nor}) + (peso_2.FO2_{\ell}^{Nor}) + (peso_3.FO3_{\ell}^{Nor}) \quad \text{Equação 42}$$

$$FO1_{\ell}^{Nor} = \frac{FO1_{\ell} - FO1_{\text{mínimo}}}{FO1_{\text{máximo}} - FO1_{\text{mínimo}}} \quad \text{Equação 43}$$

$$FO2_{\ell}^{Nor} = \frac{FO2_{\ell} - FO2_{\text{mínimo}}}{FO2_{\text{máximo}} - FO2_{\text{mínimo}}} \quad \text{Equação 44}$$

$$FO3_{\ell}^{Nor} = \frac{FO3_{\ell} - FO3_{\text{mínimo}}}{FO3_{\text{máximo}} - FO3_{\text{mínimo}}} \quad \text{Equação 45}$$

onde:

$FP_{\ell}$  é o valor da função ponderada para o indivíduo  $\ell$  ;

$peso_1$  ,  $peso_2$  ,  $peso_3$  são os pesos atribuídos a cada função-objetivo para ponderação;

$FO1_{\ell}^{Nor}$  ,  $FO2_{\ell}^{Nor}$  ,  $FO3_{\ell}^{Nor}$  são os valores normalizados das funções-objetivo para o indivíduo  $\ell$  ;

$FO1_{\text{mínimo}}$  ,  $FO2_{\text{mínimo}}$  ,  $FO3_{\text{mínimo}}$  são os valores mínimos para as funções-objetivo considerando o conjunto final reduzido;

$FO1_{\text{máximo}}$  ,  $FO2_{\text{máximo}}$  ,  $FO3_{\text{máximo}}$  são os valores máximos para as funções-objetivo considerando o conjunto final reduzido.

Quando não se deseja priorizar qualquer objetivo em relação aos demais, propõe-se utilizar, em alternativa à função ponderada, um parâmetro que busque uma solução com mínima variação entre todos os valores normalizados da função-objetivo, sendo adotado nesse trabalho o parâmetro estatístico da variância (Equação 46). Nesse caso, a solução que possuir o mínimo valor da variância, será a escolhida.

$$Var_{\ell} = \frac{\sum_{f=1}^M \left( FO_f^{Nor} - \overline{FO_f^{Nor}} \right)^2}{M - 1} \quad \text{Equação 46}$$

onde:

$Var_{\ell}$  é o valor da variância dos valores normalizados das funções-objetivo do indivíduo  $\ell$  ;

$FO_f^{Nor}$  é o valor normalizado da função-objetivo  $f$  para o indivíduo  $\ell$  ;

$\overline{FO_f^{Nor}}$  é a média dos valores normalizados das funções-objetivo do indivíduo  $\ell$  ;

$M$  é número de funções-objetivo utilizadas no processo de otimização, na aplicação em estudo, 3 funções.

## **4.4. Avaliação do modelo de otimização multi-objetivo**

### **4.4.1 Experimentos de avaliação**

A avaliação do modelo de otimização multi-objetivo e das alternativas propostas foi realizada através de quatro etapas bem definidas. Na primeira etapa, foi realizada uma busca exaustiva em uma rede piloto simplificada para avaliar todas as soluções possíveis de um cenário específico e definir a fronteira Pareto. Na segunda etapa, foram avaliadas, na rede piloto simplificada, todas as alternativas de incorporação da viabilidade no método SPEA2 e de utilização de operadores genéticos inteligentes, utilizando nessa avaliação, os resultados da busca exaustiva. Tendo caracterizado o desempenho de cada alternativa metodológica, aquelas que obtiveram melhores resultados foram aplicadas em um problema real de otimização, no caso, a rede piloto definida, constituindo a terceira etapa deste trabalho. Finalmente, a quarta etapa constitui na análise da viabilidade de utilização da melhor combinação metodológica, definida baseada nos resultados das etapas anteriores, em campo, ou seja, considerando a restrição temporal como critério de parada do algoritmo.

#### **Primeira etapa: Busca exaustiva**

A busca exaustiva é um método enumerativo que consiste em realizar uma varredura completa de todas as soluções possíveis do espaço de busca. Portanto, no escalonamento de bombas em uma rede com a dimensão da rede piloto, que possui 6 bombas, em uma operação típica de 24 horas, adotando-se um intervalo de atuação de 60 minutos, tem-se um total de  $2,23 \times 10^{43}$  soluções (dado por  $2^{6_{bombas} \times 24_{intervalos}}$ ). Torna-se inviável, portanto, a utilização dessa metodologia.

Para que seja possível a avaliação da eficácia e eficiência do método de otimização e das alternativas propostas através da definição da fronteira Pareto, a rede piloto foi simplificada através da conversão das duas bombas de cada estação em uma apenas, mantendo-se a mesma previsão da produção e os limites de operações da rede. A conversão das bombas é feita dividindo-se o coeficiente  $b$  da curva característica de cada bomba por dois. Desse modo, uma bomba ligada na rede piloto simplificada equivale a duas bombas ligadas na rede piloto.

A rede piloto simplificada para a busca exaustiva está representada na Figura 17, na qual foram tomadas como condições iniciais de simulação o nível dos tanques produtores igual a 3,00 m, o nível do tanque receptor igual a 6,00 m e apenas a bomba da estação de Lorena ligada.

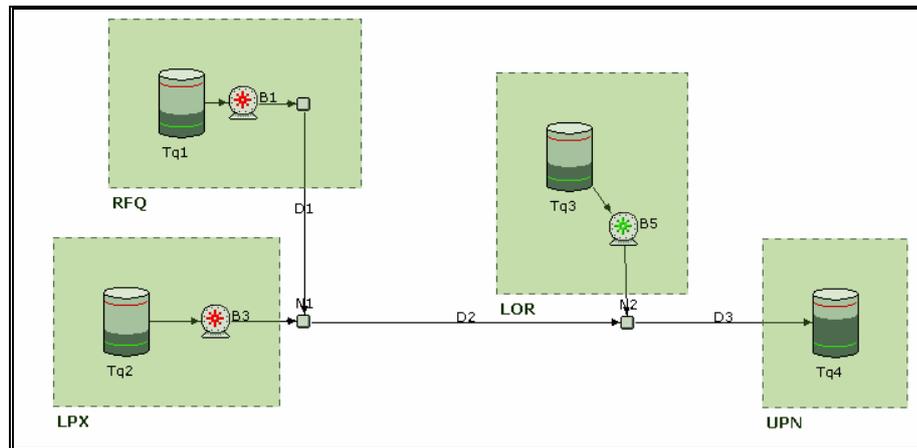


Figura 17 – Modelagem da rede piloto simplificada para busca exaustiva.

A busca exaustiva foi realizada para um horizonte de operação de 12 horas, com intervalos de atuação de 2 horas e intervalos de cálculo de 30 minutos. O início da simulação foi às 09:00h, estendendo-se, portanto, até às 21:00h, o que permite abranger os horários de ponta e fora de ponta de energia elétrica. As simulações foram realizadas para um dia útil do período seco. O espaço de busca para esse cenário é composto de 262.144 soluções possíveis dado por  $2^{3bombas \times 6intervals}$ .

Após aplicação da busca exaustiva, foi possível extrair algumas informações do espaço de busca do cenário, como a porcentagem de indivíduos viáveis, e, dentre esses, a porcentagem dos indivíduos não-dominados, que são componentes da fronteira Pareto. A partir dessas informações, foi possível avaliar a complexidade do cenário adotado para então aplicar o método de otimização e as alternativas propostas, e avaliar o desempenho da metodologia.

### **Segunda etapa: Experimentos sobre a rede piloto simplificada**

Inicialmente foi avaliado o desempenho do algoritmo original do SPEA2 considerando a inviabilidade dos indivíduos unicamente na seleção por torneio. Seu desempenho foi

comparado com as duas formas de avaliação da população do SPEA2 propostas para inclusão do conceito de viabilidade associado com o conceito de dominância, considerando-se inicialmente as relações de dominância (Figura 11, pág. 75) ou o conceito de viabilidade (Figura 12, pág. 75). Dessa análise preliminar, pretende-se escolher uma metodologia base na qual deverá ser introduzida cada uma das alternativas descritas para o método (operadores direcionados e regra de descarte/reparo dos indivíduos). O Quadro 5 mostra a descrição de cada uma das metodologias avaliadas nesta etapa.

Cada metodologia foi aplicada 30 vezes na rede piloto simplificada<sup>6</sup>, com critério de parada igual a encontrar todas as soluções da fronteira Pareto ou, caso não encontre, adotado como número máximo de geração um valor que permita avaliar aproximadamente a mesma quantidade de indivíduos do espaço de busca do problema (262.144). Logo, para a população adotada de 30 indivíduos, foi utilizado um número máximo de gerações igual a 8.800.

Quadro 5 – Metodologias avaliadas na otimização da rede piloto simplificada.

Metodologia	Descrição
<b>Metodologia A</b>	Método SPEA2 original; seleção por torneio considerando o conceito de viabilidade; utilização do <i>seeding</i> com calculador de solução viável.
<b>Metodologia B</b>	Método SPEA2 original; seleção por torneio considerando o conceito de viabilidade; utilização do <i>seeding</i> com o calculador de solução viável; preenchimento da população externa considerando os conceitos de viabilidade e dominância como esquematizado na Figura 11.
<b>Metodologia C</b>	Método SPEA2 original; seleção por torneio considerando o conceito de viabilidade; utilização do <i>seeding</i> com o calculador de solução viável; preenchimento da população externa considerando os conceitos de viabilidade e dominância como esquematizado na Figura 12.
<b>Metodologia 1</b>	Método Base (o de melhor desempenho entre as Metodologias A, B ou C) com exclusão da técnica de <i>seeding</i> .
<b>Metodologia 2</b>	Método Base com substituição do método de seleção por torneio pelo método de seleção SUS, considerando o conceito de viabilidade com ordenamento linear da função de aptidão.
<b>Metodologia 3</b>	Método Base com utilização do descarte dos indivíduos que provocam alarmes de nível máximo dos tanques produtores na geração da população inicial e na reprodução.

<sup>6</sup> Nos trabalhos correlatos as repetições variam entre 10 e 30 para cada metodologia. Optou-se por 30 por ser considerado estatisticamente uma “grande amostra” (SPIEGEL, 1977), cujos resultados podem ser analisados através de uma distribuição normal.

<b>Metodologia</b>	<b>Descrição</b>
<b>Metodologia 4</b>	Método Base com utilização do descarte dos indivíduos que provocam alarmes de nível máximo nos tanques produtores na geração da população e reparo desses indivíduos durante a reprodução.
<b>Metodologia 5</b>	Método Base com utilização dos operadores direcionados definidos por Brasileiro (2005) em conjunto com os operadores tradicionais, na proporção de 70% direcionados x 30% tradicionais.
<b>Metodologia 6</b>	Método Base com utilização dos operadores direcionados definidos por Machado <i>et al.</i> (2005) em conjunto com os operadores tradicionais, na proporção de 70% direcionados x 30% tradicionais.
<b>Metodologia 7</b>	Método Base com utilização dos operadores direcionados definidos por Brasileiro (2005) em conjunto com os operadores tradicionais, na proporção de 30% direcionados x 70% tradicionais.
<b>Metodologia 8</b>	Método Base, utilização dos operadores direcionados definidos por Machado <i>et al.</i> (2005) em conjunto com os operadores tradicionais, na proporção de 30% direcionados x 70% tradicionais.

### **Terceira etapa: Experimentos sobre a rede piloto**

Após avaliar o desempenho de cada metodologia aplicada na rede piloto simplificada, foram adotadas as que mais se destacaram para aplicação na rede piloto, momento em que se realizou a terceira etapa do presente trabalho. Ou seja, as primeiras etapas, nas quais a análise se deu em uma rede simplificada, representou uma espécie de filtro, sobre o qual foi realizada toda a análise estatística para seleção das metodologias mais indicadas para aplicação em uma rede real.

A operação a ser otimizada na rede piloto ocorreu durante um horizonte de 24 horas com intervalo de cálculo de 30 minutos, intervalo de atuação de 1 hora e início às 00:00h, no mesmo dia utilizado na rede piloto simplificada, e utilizando a mesma previsão da produção e restrições operacionais.

A granularidade do intervalo de atuação em 1 hora foi adotada por ser a mais freqüentemente utilizada nos trabalhos correlatos e por ser considerada praticável para a rede piloto, onde o tempo mínimo de enchimento dos tanques é superior a 5 horas. Quanto ao intervalo de cálculo, simulações foram executadas mantendo-se todas as bombas ligadas por um período de 24 horas com intervalos de cálculo de 5 minutos e de 30 minutos, e o somatório da diferença percentual dos níveis dos tanques, entre as simulações, foi inferior a 0,5%. Logo, foi adotado o intervalo de cálculo maior, o qual proporciona um melhor

desempenho computacional sem prejuízos significativos para os resultados. As condições iniciais do sistema são: níveis dos tanques produtores iguais a 3,00 m, nível do tanque receptor igual a 6,00 m e uma bomba de cada estação ligada.

Foi adotada, tanto para a aplicação na rede piloto simplificada quanto na rede piloto, dimensão de população igual a 1,67 vezes o número de bits do cromossomo, valor contido no intervalo considerado satisfatório por Alander (1992), ou seja, entre uma e duas vezes o número de bits do cromossomo. Desse modo, uma vez que o tratamento estatístico tenha sido realizado nos resultados da rede piloto simplificada e servido de base para a definição do critério de parada das aplicações na rede piloto, considerou-se suficiente apenas duas execuções de cada metodologia escolhida para a rede piloto.

#### **Quarta etapa: Experimentos na rede piloto com restrição temporal**

Uma vez selecionada a melhor combinação de metodologias a ser aplicada em problemas de dimensão real, foram conduzidos novos experimentos considerando a restrição temporal para verificar a viabilidade da utilização efetiva desta metodologia na operação de uma rede de escoamento de petróleo.

Para aplicar o problema operacionalmente em campo, o critério de parada foi restrito a um valor no máximo igual ao intervalo de atuação, adotado em 1 hora, para que fosse possível aplicar a solução fornecida pelo modelo de otimização, a cada nova atuação no sistema. Desse modo, utilizou-se um critério de parada de 55 minutos, ficando 5 minutos de folga para permitir que o algoritmo encerre a população que está sendo avaliada no momento em que se atingiu o critério de parada.

Sabe-se que o maior tempo de processamento gasto com a metodologia exposta se refere ao processo de simulação hidráulica. Desse modo, a população do algoritmo será diminuída para permitir a avaliação de um número maior de gerações no pouco tempo disponível.

O SmartPumping permite paralelizar o algoritmo genético enviando para diversas máquinas de uma grade computacional<sup>7</sup> a tarefa de simular cada cromossomo (GALVÃO *et al.*, 2004a). Esse recurso foi utilizado nos experimentos das etapas anteriores sem, contudo,

---

<sup>7</sup> Todos os experimentos dessa pesquisa foram conduzidos utilizando o software OurGrid, versão 3.2.1. Esse software é livre, desenvolvido pela UFCG em parceria com a Hewlett-Packard do Brasil, e pode ser obtido em <http://www.ourgrid.org>.

restringir os tipos e a quantidade de máquinas utilizadas. E como se pretende avaliar a qualidade das soluções encontradas com tempo e recursos computacionais reduzidos, os experimentos da quarta etapa utilizaram uma grade computacional composta de quatro computadores iguais (Características: 1.024 RAM, HD 160GB, INTEL® PENTIUM® 4 HT, CPU 3.00GHz, Sistema operacional Linux Debian Sarge).

A Tabela 11 mostra um resumo dos parâmetros do algoritmo genético utilizados nas aplicações na rede piloto e na rede piloto simplificada. Em todas as aplicações, foram utilizadas as três funções-objetivo definidas, sendo adotada para a função-objetivo 3 a minimização do valor de BS&W no interior do tanque da estação de Upanema (considerando como desejável o valor de 10%) e considerada a função de variação absoluta com valor de  $\kappa$  igual a 1.

Tabela 11 – Parâmetros do algoritmo genético.

Parâmetro	Rede piloto simplificada	Rede piloto	Rede piloto com restrição temporal
Dimensão da população	30	240	50 e 100
Dimensão da população externa	30	240	50 e 100
Critério de parada	Encontrar a fronteira Pareto ou 8.800 gerações	Número de gerações a definir <sup>I</sup>	55 minutos
Execuções de cada método	30	2	2
Probabilidade de cruzamento (tradicional e direcionado)	90%		
Probabilidade de mutação no bit <sup>II</sup> (tradicional)	5%		
Probabilidade de mutação no bit <sup>II</sup> (direcionada)	20%		
Probabilidade de mutação no intervalo <sup>III</sup> (tradicional)	30%		
Porcentagem de bombas mutadas na mutação por intervalo <sup>III</sup> (tradicional e direcionada)	10% ou 1 bomba		

I – definido através dos resultados obtidos na rede piloto simplificada.

II – utilizada nos operadores de reprodução definidos por Machado *et al.* (2005).

III – utilizada nos operadores de reprodução definidos por Brasileiro (2005).

#### **4.4.2 Métricas de desempenho para as metodologias aplicadas sobre a rede piloto simplificada**

Os resultados de um método de otimização devem atender a três requisitos básicos: eficiência, eficácia e diversidade. A eficiência e a eficácia são comuns a qualquer método de otimização, e consistem, respectivamente, na capacidade de encontrar uma resposta rápida para o problema, e na capacidade de encontrar a (ou se aproximar da) solução ótima global, a qual é composta de múltiplas soluções da fronteira Pareto, no caso da otimização ser multi-objetivo.

A diversidade é um objetivo próprio dos métodos multi-objetivo, e é a habilidade de encontrar um conjunto de soluções tão diversas quanto possível, para que se garanta que esse conjunto tenha boas soluções de compromisso para todos os objetivos.

Para avaliar o desempenho das metodologias aplicadas na rede piloto simplificada, foram utilizadas as métricas definidas a seguir.

##### **Métrica de desempenho 1**

Realiza-se segundo o número de gerações necessárias para encontrar uma solução da fronteira Pareto. Cada uma das 30 execuções das metodologias será classificada como “falha” se não conseguir encontrar nenhuma solução da fronteira Pareto real ao final da otimização. Ao final das execuções, será definida a proporção de sucessos da metodologia, e, nos casos de sucesso, a média do número de gerações necessárias para encontrar uma solução qualquer da fronteira Pareto.

##### **Métrica de desempenho 2**

Constitui-se do número de gerações necessárias para encontrar as soluções da fronteira Pareto que correspondem aos extremos mínimos das funções-objetivo. A execução será classificada como “falha” se não conseguir encontrar, ao final da otimização, ao menos uma solução extrema mínima de cada função-objetivo. Ao final das execuções, será definida a proporção de sucessos da metodologia e a média das soluções extremas encontradas. Apenas nos casos de sucesso, deverá ser calculada a média do número de gerações necessárias para encontrar as soluções extremas.

### Métrica de desempenho 3

Dá-se a partir do número de soluções da fronteira Pareto real encontradas no final da otimização. A execução será classificada como “falha” se não conseguir encontrar 100% da fronteira Pareto, ao final da otimização. Terminadas as execuções, será definida a proporção de sucessos de cada metodologia e a média do número de soluções encontradas ao final da otimização. Apenas nos casos de sucesso, deverá ser calculada a média do número de gerações necessárias para encontrar a fronteira Pareto.

### Métrica da dispersão dos resultados

A média é uma medida de tendência central que não considera a influência da dispersão das variáveis, a qual deve ser avaliada por outras medidas estatísticas como o desvio padrão, a variância, o coeficiente de variação, entre outras. A dispersão dos resultados para uma metodologia deve ser considerada, auxiliando a análise dos resultados, por permitir que, na comparação de metodologias com médias semelhantes ou pouco variáveis, seja possível priorizar aquela em que seus resultados são mais homogêneos, ou seja, possuem pouca dispersão em relação à média.

Neste trabalho, é definido o intervalo de confiança de todas as médias analisadas, para um nível de confiança de 95%, o qual define um intervalo em que, em qualquer execução posterior da metodologia, pode-se esperar com 95% de certeza que a variável considerada estará nesse intervalo.

O intervalo de confiança para a média de uma amostra com um nível de confiança de 95% pode ser dado pela Equação 47 quando a amostra é considerada de distribuição normal, o que geralmente ocorre quando sua dimensão é maior ou igual a 30 (SPIEGEL, 1977). Neste trabalho, a amostra tomada é o número de repetições para cada método.

$$IC(\mu, 95\%) = \bar{x} \pm 1,96 \frac{DP}{\sqrt{n}} \quad \text{Equação 47}$$

onde:

$IC(\mu, 95\%)$  são os limites de confiança da média populacional, a um nível de 95% de confiança;

$\bar{x}$  é a média amostral;

$n$  é a dimensão da amostra;

$DP$  é o desvio padrão da população, o qual pode ser aproximado pelo desvio padrão amostral quando a amostra tiver dimensão igual ou superior a 30.

As médias do número de gerações, nas três métricas de desempenho, são definidas considerando-se apenas as execuções que obtiveram sucesso. Então, se ao menos uma execução não tiver obtido sucesso, o tamanho da amostra será inferior a 30 e, portanto, considerada como uma pequena amostra. Nesses casos, deve-se utilizar a distribuição de *Student* para definir o intervalo de confiança da média amostral com um nível de significância de 95%, dado pela Equação 48.

$$IC(\mu, 95\%) = \bar{x} \pm st \frac{\Delta S}{\sqrt{n-1}} \quad \text{Equação 48}$$

onde:

$st$  é o coeficiente de *Student*, variável com a dimensão da amostra;

$\Delta S$  é o desvio padrão da amostra.

#### 4.4.3 Métricas de desempenho para as metodologias aplicadas sobre a rede piloto

Como não se tem informações sobre as soluções da fronteira Pareto para as simulações da rede piloto, foram definidas métricas de desempenho que independem dessa informação, aqui denominadas: 1) Métrica de convergência; 2) Métrica de diversidade; e 3) Métrica de otimização.

##### Métrica de convergência

Quando não se tem informação sobre as soluções reais da fronteira Pareto, uma métrica utilizada para comparar a eficiência da convergência entre otimizações distintas, consiste em calcular a proporção das soluções não-dominadas encontradas em uma otimização que dominam as soluções não-dominadas encontradas em outra otimização, a qual caracteriza-se

como uma métrica de análise binária. Com isso, tendo cada otimização fornecido um conjunto de soluções de compromisso (não-dominadas viáveis) para o problema, todas essas soluções serão armazenadas em um único conjunto e, desse conjunto, serão extraídas apenas as soluções não-dominadas. Portanto, o método que tiver encontrado o maior número dessas soluções não-dominadas do conjunto total será considerado de melhor desempenho nesta métrica.

### Métrica de diversidade

Schott (1995 *apud* Deb, 2001) sugere uma métrica de diversidade baseada no espaçamento entre as soluções, que calcula a distância relativa média entre soluções consecutivas no conjunto não-dominado obtido, dada pela Equação 49. Quando as soluções são uniformemente espaçadas, essa medida de diversidade será igual a zero. A metodologia, cujo conjunto de soluções viáveis não-dominadas obtiver o menor valor desta métrica, será considerado de melhor desempenho com respeito à diversidade entre as soluções encontradas.

$$MS = \sqrt{\frac{1}{|PV^*|} \cdot \sum_{\ell=1}^{|PV^*|} (md_{\ell} - \overline{md})^2} \quad \text{Equação 49}$$

onde:

$MS$  é o valor da métrica de espaçamento;

$PV^*$  é o conjunto de soluções não-dominadas viáveis;

$md_{\ell}$  é a medida de distância do indivíduo  $\ell$ , dada pelo mínimo valor da soma da diferença absoluta dos valores das funções-objetivo entre a solução  $\ell$  e qualquer outra solução do conjunto  $PV^*$ ;

$\overline{md}$  é a média das medidas de distâncias de todos os indivíduos do conjunto  $PV^*$ .

### Métrica de otimização

A métrica de otimização das funções-objetivo será representada através dos valores mínimos obtidos para cada função-objetivo no final da otimização. O método que obtiver os menores valores de funções-objetivo no final da otimização será considerado de melhor desempenho nessa métrica.

#### **4.5. Processo de desenvolvimento do método**

O processo de desenvolvimento do *software* SmartPumping é conduzido através de uma metodologia denominada *Extreme Programming – XP* (BECK, 1999), a qual, dentre outros princípios, enfatiza a participação direta e contínua do usuário final, que especifica as funcionalidades e elabora os testes de aceitação para os produtos em desenvolvimento. A especificação é o processo de detalhamento do algoritmo a ser implementado enquanto que o teste de aceitação define os critérios de aceitação necessários para que o produto seja considerado apto para ser utilizado e abrange, senão todos, a maioria dos casos possíveis em que o produto será utilizado.

O desenvolvimento do método de otimização utilizado nessa pesquisa foi conduzido através da especificação do algoritmo e realização dos testes de aceitação, pela autora, e implementação na linguagem de programação JAVA<sup>TM</sup> pela equipe de desenvolvimento do projeto SmartPumping. Essa equipe é composta por quatro membros, responsáveis pelo desenvolvimento do *software*, o qual, atualmente possui aproximadamente 166.709 linhas de código com 26% dessas linhas correspondente ao código da ferramenta de otimização.

Interações contínuas entre a equipe de desenvolvimento e a autora, inclusive com contribuição de ambas as partes nas etapas de especificação do método e de sua implementação, possibilitaram a definição de uma metodologia mais elaborada e na ampliação das possibilidades de combinações das técnicas avaliadas.

## 5. Resultados e discussão

### 5.1. Espaço de busca do problema

A análise do espaço de busca com os resultados da busca exaustiva sobre a rede piloto simplificada indicou um cenário onde 99,69% das soluções são inviáveis. No conjunto de soluções viáveis, de um total de 812 soluções, apenas 44 são não-dominadas (5,42% das viáveis) e, portanto compõem a fronteira Pareto do cenário (Gráfico 1).

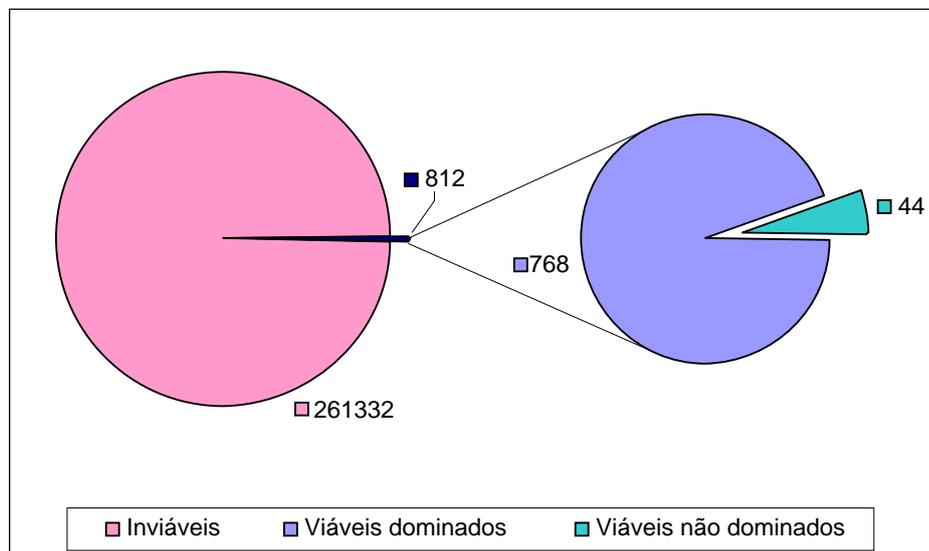


Gráfico 1 – Caracterização do espaço de busca para a rede piloto simplificada.

As soluções inviáveis possuem em média 19 alarmes, sendo que o primeiro alarme ocorre, em média, no primeiro intervalo de atuação e é principalmente de nível mínimo dos tanques (41,66%). A Tabela 12 a seguir mostra os resultados referentes aos pontos de falha dos indivíduos inviáveis, onde se pode observar que 62,69% destas soluções possuem ponto de falha no primeiro intervalo de atuação, com essa porcentagem decrescendo gradativamente até atingir 0,12% dos indivíduos com ponto de falha no sexto e último intervalo de atuação. Os demais alarmes identificados no ponto de falha dessas soluções são de pressão máxima (39,08%) e de nível máximo nos tanques (19,27%).

Tabela 12 – Caracterização dos pontos de falha das soluções inviáveis.

Característica	% do total					
	1	2	3	4	5	6
Posição	62,69	25,08	8,03	3,31	0,77	0,12
Alarme <sup>I</sup>	Nmax	Nmin	Pmax	Pmin	Vmax	Vmin
	19,27	41,66	39,08	0,00	0,00	0,00

I: Nmax – nível máximo, Nmin – nível mínimo, Pmax – pressão máxima, Pmin – pressão mínima, Vmax – velocidade máxima, Vmin – velocidade mínima.

O Gráfico 2 mostra a distribuição dos indivíduos viáveis e inviáveis entre as 262.144 soluções do espaço de busca com as soluções ordenadas no sistema de numeração binário. A solução de índice 1 corresponde ao cromossomo que mantém todas as bombas desligadas durante todo o horizonte de operação (000000000000000000) e a de índice 262.144 ao cromossomo que mantém todas as bombas ligadas (11111111111111111111).

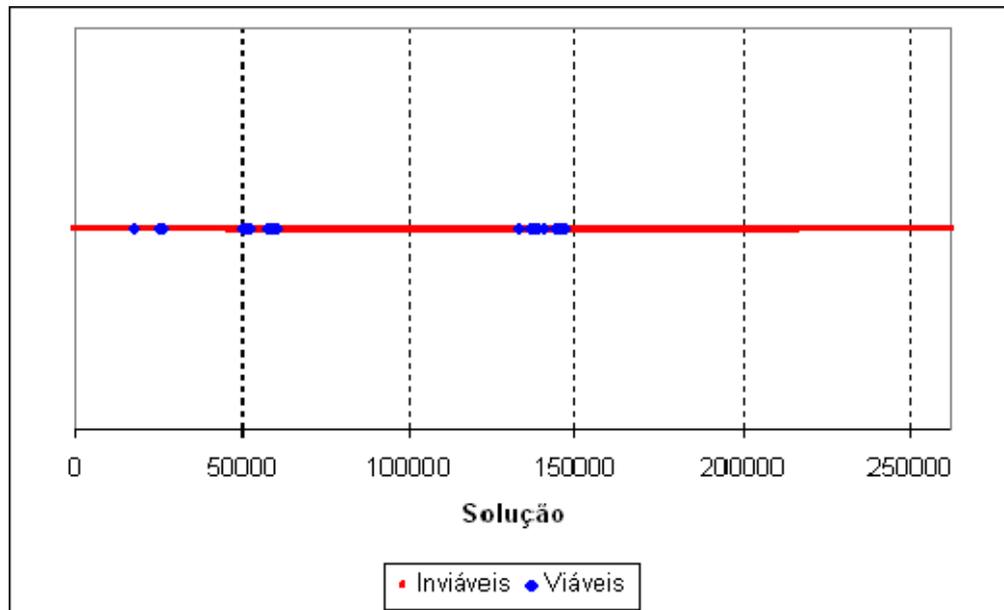


Gráfico 2 – Distribuição das soluções no espaço de busca.

Apesar do cenário avaliado apresentar uma capacidade de bombeio superior à produção dos poços e atender à demanda da estação final, observou-se uma alta incidência de indivíduos inviáveis e uma alta porcentagem do ponto de falha desses indivíduos no primeiro intervalo de atuação. Isso ocorre justamente devido à capacidade de bombeio ser superior à

produção dos poços. Logo, soluções que mantêm essas bombas ligadas por um período de tempo elevado acarretam o esvaziamento dos tanques produtores e o eventual enchimento do tanque receptor. Além disso, se todas as bombas forem ligadas no mesmo intervalo, pode ocasionalmente provocar alarmes de pressão máxima no sistema. Essa análise se comprova nos resultados obtidos, nos quais os alarmes detectados no ponto de falha são de nível dos tanques e de pressão máxima, e nos quais todas as soluções viáveis do sistema são encontradas até a solução de índice 150.000, portanto, mantendo as bombas ligadas durante menos tempo.

O Gráfico 3 mostra os valores das três funções-objetivo avaliadas no espaço de busca, onde se observa sub-conjuntos bem definidos de soluções viáveis e bem distribuídos entre as soluções inviáveis. As soluções inviáveis apresentam valores mínimos de funções-objetivo de 0,0795 R\$/m<sup>3</sup> para o objetivo 1, 0 chaveamentos para o objetivo 2, e uma variação acumulada de BS&W no tanque receptor de 15,48 %; e valores máximos de 0,4092 R\$/m<sup>3</sup>, 9 chaveamentos e variação acumulada de BS&W de 181,47 %. Entre as soluções viáveis, os valores mínimos são maiores em relação às inviáveis, possuindo no entanto, uma variação menor entre si, estando concentradas nas regiões inferiores das funções-objetivo (mínimos: 0,0875 R\$/m<sup>3</sup>, 4 chaveamentos e variação de BS&W de 22,31 %; máximos de 0,1155 R\$/m<sup>3</sup>, 9 chaveamentos e variação de BS&W de 60,21 %).

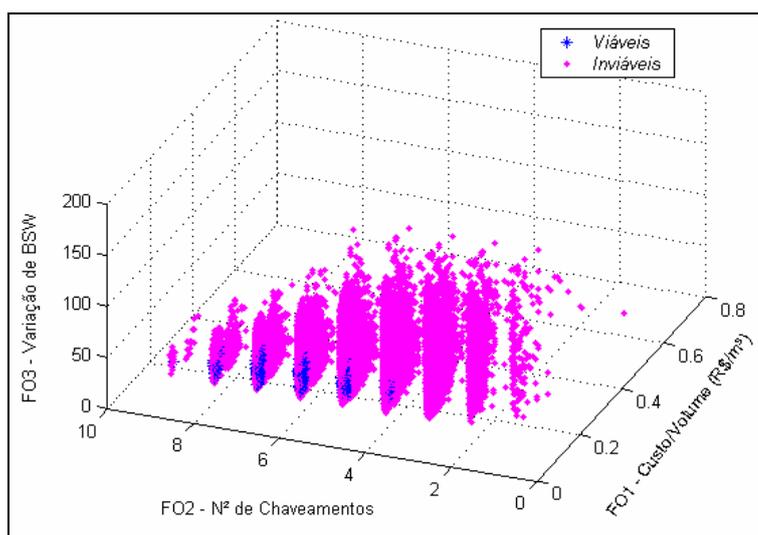


Gráfico 3 – Valores de funções-objetivo das soluções do espaço de busca.

A distribuição das soluções viáveis no espaço de busca é mostrada no Gráfico 4 a seguir, com destaque para as soluções da fronteira Pareto (viáveis não-dominadas), da solução obtida através do calculador de solução viável, que, apesar de ser viável, é dominada, e das soluções que representam o mínimo viável de cada função-objetivo no espaço de busca. Assim como as soluções viáveis em relação às inviáveis, no conjunto de soluções viáveis, as soluções não-dominadas estão bem distribuídas na fronteira em relação às dominadas. Isto justifica a utilização de um método de otimização robusto como o algoritmo genético, que possui como uma de suas principais vantagens a capacidade de percorrer simultaneamente pontos distintos do espaço de busca.

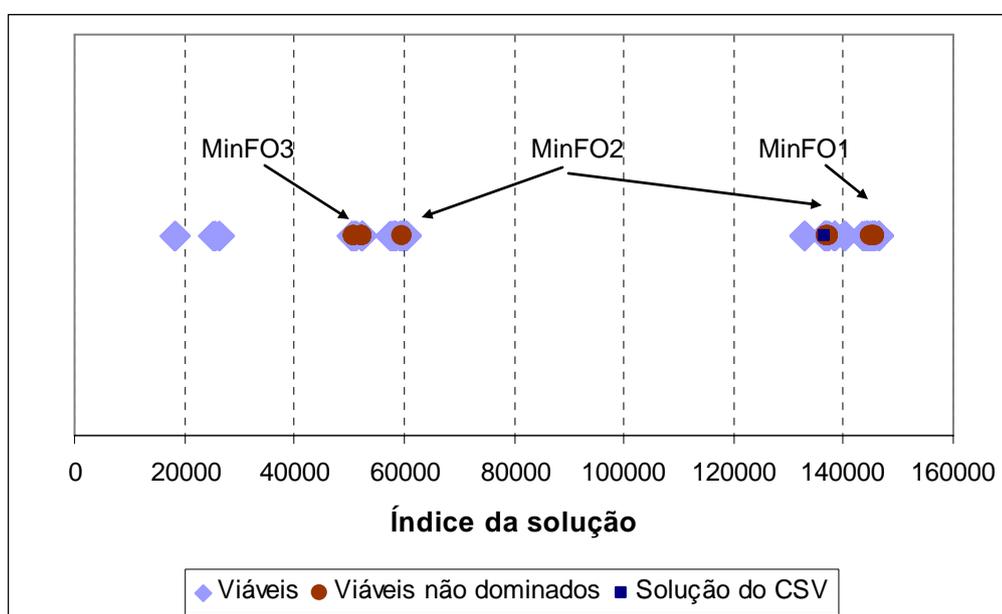


Gráfico 4 – Distribuição das soluções viáveis no espaço de busca.

Na Tabela 13, vide página 103, são mostrados o índice, o cromossomo e os valores das funções-objetivo de todas as soluções da fronteira Pareto. Algumas soluções podem apresentar valores idênticos para cada função-objetivo, contudo, com cromossomos diferentes. Isso ocorre porque, no último intervalo de cálculo no SmartPumping, o cálculo do consumo de energia e a regra da mistura nos tanques são resultados do intervalo de cálculo anterior. Portanto, a programação das bombas para o último intervalo não interfere nesses resultados, fazendo com que, para cada valor das funções-objetivo 1 e 3 haja seis cromossomos distintos. Exceção será feita na função-objetivo 1, se o máximo valor de demanda de energia estiver no último intervalo de cálculo, e por ser essa uma propriedade

pontual, é considerada no cálculo tarifário do próprio intervalo. A função-objetivo 2, número de chaveamentos, naturalmente, sofre a influência dos bits do último intervalo de cálculo.

Agrupando as soluções da fronteira Pareto que apresentam valores iguais para os três objetivos, restam 18 grupos de soluções não-dominadas viáveis, os quais serão considerados na análise da eficácia e da eficiência das metodologias analisadas. O método será considerado totalmente eficaz se conseguir encontrar, no final da otimização, uma solução representante de cada um desses 18 grupos; a eficiência será medida na rapidez com que soluções distintas da fronteira Pareto (de grupos diferentes) são encontradas, e a diversidade será avaliada pela capacidade de encontrar soluções bem distribuídas no espaço de busca, conforme as métricas de desempenho definidas.

O Gráfico 5 mostra os valores das funções-objetivo das soluções viáveis, onde se pode visualizar, bem definida, a fronteira Pareto.

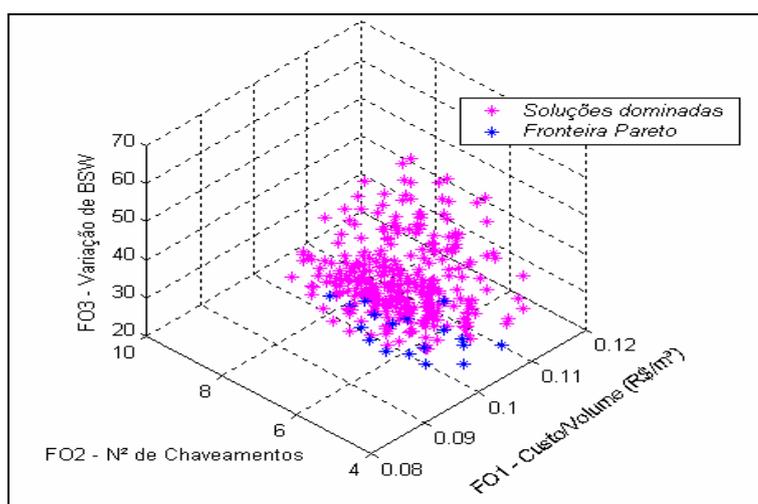


Gráfico 5 – Funções-objetivo das soluções viáveis no espaço de busca.

Tabela 13 – Funções-objetivo das soluções da fronteira Pareto da rede piloto simplificada.

<b>Grupos</b>	<b>Cromossomo</b>	<b>Índice</b>	<b>FO1</b>	<b>FO2</b>	<b>FO3</b>
<b>Grupo 1</b>	001100011100010000	50961	0,0937	6	28,34
	001100011100010010	50963	0,0937	6	28,34
<b>Grupo 2</b>	001100011100011000	50969	0,0989	7	22,31
	001100011100011001	50970	0,0989	7	22,31
	001100011100011010	50971	0,0989	7	22,31
	001100011100011011	50972	0,0989	7	22,31
<b>Grupo 3</b>	001100011100110000	50993	0,0968	6	23,02
	001100011100110010	50995	0,0968	6	23,02
<b>Grupo 4</b>	001100110001011000	52313	0,1041	5	23,72
	001100110001011001	52314	0,1041	5	23,72
	001100110001011010	52315	0,1041	5	23,72
	001100110001011011	52316	0,1041	5	23,72
<b>Grupo 5</b>	001100110010011000	52377	0,0936	4	49,28
	001100110010011001	52378	0,0936	4	49,28
	001100110010011010	52379	0,0936	4	49,28
	001100110010011011	52380	0,0936	4	49,28
<b>Grupo 6</b>	001100110011001000	52425	0,1043	4	28,62
	001100110011001001	52426	0,1043	4	28,62
<b>Grupo 7</b>	001100110011010000	52433	0,0936	4	41,58
	001100110011010010	52435	0,0936	4	41,58
<b>Grupo 8</b>	001100110011100000	52449	0,0967	5	29,04
<b>Grupo 9</b>	001110100011010000	59601	0,0938	5	39,32
	001110100011010010	59603	0,0938	5	39,32
<b>Grupo 10</b>	100001011100010000	136977	0,0939	5	29,77
	100001011100010010	136979	0,0939	5	29,77
<b>Grupo 11</b>	100001011100110000	137009	0,0970	5	24,60
	100001011100110010	137011	0,0970	5	24,60
<b>Grupo 12</b>	100001011110100000	137121	0,0972	4	29,63
<b>Grupo 13</b>	100001011110110000	137137	0,0969	4	36,40
	100001011110110010	137139	0,0969	4	36,40
	100001011110110100	137141	0,0969	4	36,40
	100001011110110110	137143	0,0969	4	36,40
<b>Grupo 14</b>	100011011100010000	145169	0,0875	5	45,17
	100011011100010010	145171	0,0875	5	45,17
<b>Grupo 15</b>	100011011100011000	145177	0,0926	6	39,57
	100011011100011001	145178	0,0926	6	39,57
	100011011100011010	145179	0,0926	6	39,57
	100011011100011011	145180	0,0926	6	39,57
<b>Grupo 16</b>	100011011100110000	145201	0,0909	5	40,27
	100011011100110010	145203	0,0909	5	40,27
<b>Grupo 17</b>	100011100011010000	145617	0,0900	6	40,42
	100011100011010010	145619	0,0900	6	40,42
<b>Grupo 18</b>	100011100011110000	145649	0,0931	7	35,24
	100011100011110010	145651	0,0931	7	35,24

O Gráfico 6 mostra um exemplo da aplicação dos critérios de escolha de uma solução final, como definido anteriormente, selecionando a solução com menor valor ponderado dos objetivos (considerando pesos iguais) ou a solução com menor variância entre os objetivos. Percebe-se que os valores ponderados apresentaram pouca variação entre si, sendo a solução do grupo 12 a que contém o mínimo parâmetro considerando esse critério. No critério de menor variância, a solução recomendada é a do grupo 10. Pode-se observar que o melhor parâmetro quando se consideram todos os objetivos com a mesma importância é o critério da variância, uma vez que a solução do grupo 12 é a única que apresenta, para todos os objetivos, valores normalizados inferiores a 0,40.

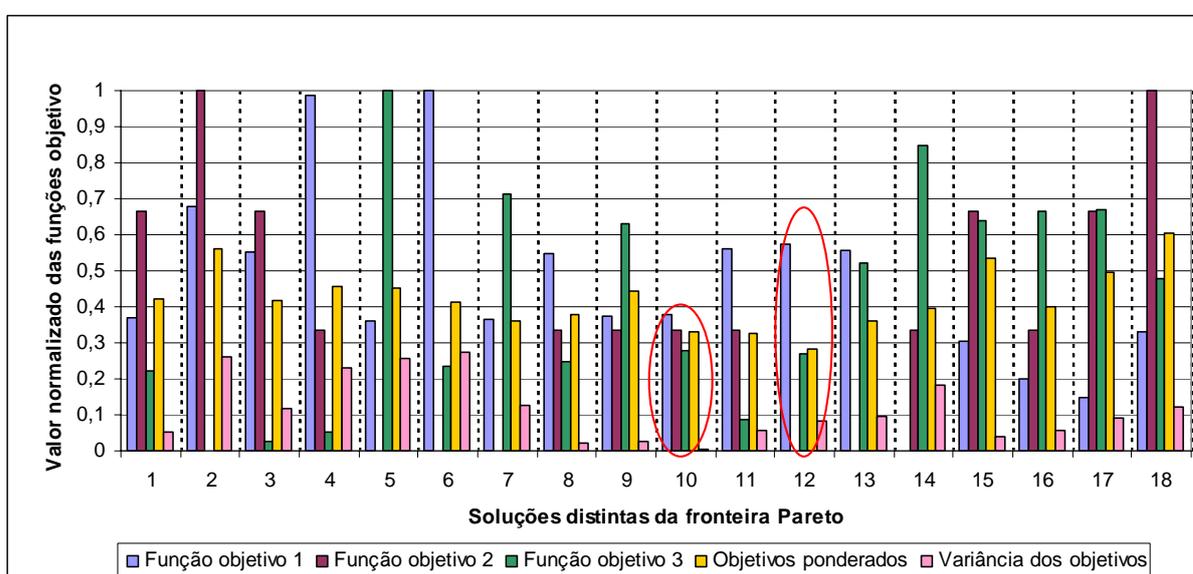


Gráfico 6 – Caracterização das soluções da fronteira Pareto.

A análise do espaço de busca, mesmo em uma rede simplificada e para um cenário específico, possibilita concluir que:

- ♣ A porcentagem de indivíduos inviáveis no espaço de busca do problema é considerável, logo não devem ser totalmente descartados sob o risco de impossibilitar a evolução do algoritmo genético;
- ♣ Os indivíduos viáveis estão distribuídos em grupos no espaço de busca, portanto deve-se utilizar alternativas que facilitem a varredura no espaço de soluções;

- ♣ Os indivíduos inviáveis geralmente dominam os indivíduos viáveis, logo, é justificável utilizar o conceito de viabilidade em conjunto com o conceito de dominância para impedir que o resultado da otimização seja composto de soluções não aplicáveis;
- ♣ Quando não se tem preferência entre os objetivos, uma boa alternativa para escolha da solução final é a solução que apresenta a menor variância entre todos os valores normalizados dos seus objetivos.

## 5.2. Aplicação sobre a rede piloto simplificada

### 5.2.1 Avaliação das alternativas de preenchimento da população externa

#### Resultados

As tabelas 14 a 16 mostram um resumo das métricas de desempenho para as metodologias A, B e C.

Tabela 14 – Métrica de desempenho 1 para as metodologias A, B e C.

Métrica de desempenho 1	% Sucesso	Média geração	IC <sup>I</sup> geração	
			Mínimo	Máximo
Metodologia A	13,33	5,50	2,90	8,10
Metodologia B	100,00	11,07	8,97	13,17
Metodologia C	100,00	10,83	9,31	12,36

I – intervalo de controle para um nível de confiança de 95%.

Tabela 15 – Métrica de desempenho 2 para as metodologias A, B e C.

Métrica de desempenho 2	% Sucesso	Média solução	Média geração	IC solução		IC geração	
				Mínimo	Máximo	Mínimo	Máximo
Metodologia A	0,00	0,00	-	0,00	0,00	-	-
Metodologia B	20,00	1,23	3.637,00	1,03	1,44	999,13	6.274,87
Metodologia C	56,67	2,37	788,94	2,11	2,62	120,87	1.457,01

Tabela 16 – Métrica de desempenho 3 para as metodologias A, B e C.

Métrica de desempenho 3	% Sucesso	Média solução	Média geração	IC solução		IC geração	
				Mínimo	Máximo	Mínimo	Máximo
Metodologia A	0,00	0,00	-	0,00	0,00	-	-
Metodologia B	0,00	3,73	-	3,24	4,23	-	-
Metodologia C	10,00	9,67	479,00	8,54	10,80	271,02	686,98

A evolução para a fronteira Pareto pode ser avaliada através do Gráfico 7, que mostra a porcentagem acumulada da fronteira Pareto por geração nas metodologias analisadas, considerando o valor médio das 30 execuções. Através da análise das primeiras 100 gerações, pode ser observada a rapidez da evolução no início da otimização.

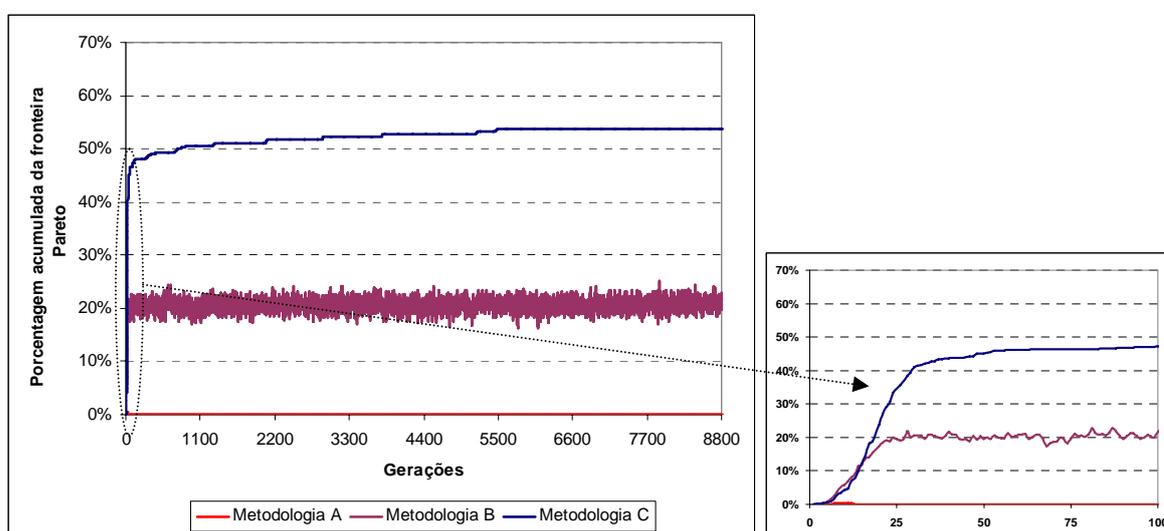


Gráfico 7 – Evolução para a fronteira Pareto das metodologias A, B e C.

A Metodologia A mostrou-se inadequada ao problema por não conseguir convergir para a região de viabilidade. Na métrica de desempenho 1, a metodologia apenas obteve sucesso em 13,33% das execuções, encontrando uma solução da fronteira Pareto em apenas quatro das 30 execuções, e na métrica de desempenho 2 não obteve sucesso em 100,0% das execuções. As soluções da fronteira Pareto que foram encontradas, bem como a solução viável definida pelo calculador de solução viável e inserida por *seeding*, são perdidas por serem dominadas pelas soluções inviáveis, dado que, no final da otimização, não há nenhuma solução da fronteira Pareto na população externa em 100,0% das execuções.

A Metodologia B apresentou uma rápida convergência para a região de viabilidade, encontrando uma solução da fronteira, em média, com 11,0 gerações. No entanto, essa

metodologia não apresentou comportamento estável, pois as soluções da fronteira são perdidas ao longo da evolução. Como pode ser observado no Gráfico 7 (pág. 106), houve uma grande oscilação na porcentagem da fronteira Pareto encontrada, chegando ao final da otimização com, em média, 3,7 soluções distintas ou 20,6% da fronteira. Em 80,0% das execuções a metodologia mostrou-se falha em encontrar, na mesma população externa, soluções que correspondem aos extremos mínimos dos objetivos, sendo que as execuções que obtiveram sucesso requerem em média 3.637,0 gerações.

Resultado satisfatório foi encontrado com a aplicação da Metodologia C, cujas três métricas de desempenho obtiveram resultados melhores: 100,0% de sucesso segundo a métrica de desempenho 1; 56,67% de sucesso segundo a métrica de desempenho 2; e 10,0% de sucesso segundo a métrica de desempenho 3. A população converge rapidamente para a região de Pareto encontrando, em média, uma solução da fronteira com 10,83 gerações. São encontradas em média 2,37 funções-objetivo com soluções extremas mínimas. Nos casos de as soluções mínimas das três funções-objetivo serem encontradas, são requeridas 788,94 gerações.

Aplicando-se a Metodologia C, as soluções da fronteira encontradas não são perdidas durante a evolução. Em média, essa metodologia encontra 9,67 soluções da fronteira Pareto, o que corresponde a 53,70% da fronteira. Nas execuções em que a metodologia obteve sucesso ao encontrar toda a fronteira Pareto, ou seja, encontrar ao menos uma solução de cada um dos 18 grupos, o número médio de gerações requerido foi de 479,0.

### **Análise dos resultados**

O esquema de preenchimento da população externa, utilizado no método SPEA2, consiste em preenchê-la inicialmente por todas as soluções não-dominadas da população corrente, e, caso a dimensão máxima não seja atingida, a mesma é completada pelos indivíduos dominados ordenados de acordo com a aptidão. Aplicando-se a Metodologia A, que utiliza esse procedimento, as soluções viáveis têm dificuldade de entrarem na população externa, pois, como foram demonstradas na busca exaustiva para o cenário analisado, as soluções inviáveis geralmente possuem valores de funções-objetivo menor do que as soluções viáveis, dominando-as.

Mesmo com a introdução de uma solução viável por *seeding* e da consideração da viabilidade na seleção por torneio, a Metodologia A encontrou dificuldade em manter as

soluções viáveis ao longo das otimizações. Em quatro das 30 execuções, essa metodologia conseguiu atingir sucesso segundo a métrica de desempenho 1, ou seja, encontrou uma solução da fronteira Pareto real. Percebe-se, entretanto, pelo baixo valor da média do número de gerações requeridas para atingir esse sucesso, que essas soluções foram encontradas no início das otimizações, ou seja, quando a população externa ainda não estava totalmente preenchida por indivíduos não-dominados e, portanto, permitia a entrada de indivíduos dominados.

Aplicando-se a Metodologia B, inicialmente os indivíduos da população corrente são avaliados com relação aos critérios de dominância, para depois serem verificadas as relações de viabilidade (Figura 11, pág. 75), preenchendo a população externa inicialmente com todas as soluções não-dominadas viáveis e, quando necessário, completando-a com soluções na seguinte ordem: dominadas viáveis, não-dominadas inviáveis e dominadas inviáveis. Apesar de priorizar as soluções viáveis com relação às inviáveis, esse modo de considerar as relações de dominância pode priorizar soluções não-dominadas viáveis que não pertencem à fronteira Pareto em relação às soluções não-dominadas viáveis da fronteira Pareto. Isso ocorre devido à fronteira Pareto real ser composta pelo sub-conjunto de soluções não-dominadas do conjunto de soluções viáveis do espaço de busca; ou seja, de todas as soluções possíveis, as relações de dominância são avaliadas apenas no conjunto das soluções factíveis.

Como a Metodologia B avalia as relações de dominância considerando indistintamente as soluções viáveis e inviáveis, é possível que uma solução não-dominada viável no âmbito das soluções factíveis, portanto uma solução da fronteira, passe a ser dominada no âmbito do conjunto global, ficando, desse modo, no segundo grupo de prioridade no preenchimento da população externa. Em outras palavras, ao utilizar a Metodologia B, não se pode garantir que todas as soluções da fronteira Pareto estejam no grupo com máxima prioridade no preenchimento da população externa, o que causa, segundo os experimentos, a instabilidade do número de soluções da fronteira na população externa ao longo da otimização.

A Metodologia C utiliza a mesma ordem de prioridades no preenchimento da população externa. No entanto os indivíduos da população corrente são classificados considerando inicialmente o conceito de viabilidade, para, só então, em cada sub-grupo, serem consideradas as relações de dominância (Figura 12, pág. 75). Este procedimento promove a convergência para a fronteira Pareto real, pois garante que essas soluções, quando surgirem na população corrente, sejam classificadas no grupo de prioridade 1 no preenchimento. Desse modo, as

características de eficiência idealizadas no método SPEA2 são resguardadas, segundo os resultados dos experimentos.

Utilizando esta metodologia, freqüentemente surgem no início da otimização, quando a população externa não está totalmente preenchida por soluções viáveis, algumas soluções inviáveis nessa população. Acontece que, como o valor *fitness* dos indivíduos é atribuído considerando separadamente os grupos de soluções viáveis e inviáveis, é possível haver, em uma mesma população, indivíduos inviáveis com valor de *fitness* inferior ao valores dos indivíduos viáveis. Tanto o método de seleção por torneio quanto o SUS com ordenamento das soluções tratam essa contradição priorizando sempre as soluções viáveis em relação às inviáveis, fazendo com que o valor do *fitness* seja utilizado apenas entre indivíduos viáveis, e como último critério de desempate entre indivíduos inviáveis.

Dos resultados expostos e da análise realizada, é possível concluir que:

- ♣ Em um espaço de busca com alta incidência de indivíduos inviáveis que dominam os indivíduos da fronteira Pareto, a consideração da inviabilidade apenas no operador de seleção por torneio não é suficiente para a progressão para a fronteira Pareto, quando se utiliza o método SPEA2;
- ♣ A consideração da inviabilidade na classificação dos indivíduos, em conjunto com o conceito de dominância, produz bons resultados no desempenho do método SPEA2 para o problema em análise;
- ♣ O procedimento ideal é considerar as relações de dominância e o cálculo da aptidão do SPEA2 em separado nos sub-conjuntos de indivíduos viáveis e inviáveis da população corrente. Portanto, a Metodologia C foi tomada como metodologia base nos experimentos posteriores.

### **5.2.2 Avaliação das alternativas incorporadas individualmente à metodologia base**

Essa etapa tem como objetivo incorporar à metodologia base definida (Metodologia C) variações nos operadores genéticos para verificar se ocorrem melhorias no seu desempenho para a solução do problema em análise. As variações abrangem a utilização de operadores de

seleção distintos, de operadores de reprodução direcionados, e variações na forma de descartar ou reparar certos indivíduos inviáveis, conforme descrito no Quadro 5 (pág. 89).

As alternativas serão consideradas inicialmente de forma separada, e, adiante, as que obtiveram melhores desempenhos serão combinadas na tentativa de definição de uma única metodologia com alto desempenho.

## Resultados

As tabelas 17 a 19 mostram um resumo dos resultados obtidos para cada métrica de desempenho nas metodologias avaliadas, sendo que os resultados da Metodologia C são os mesmos obtidos anteriormente.

Tabela 17 – Métrica de desempenho 1 para as metodologias C e 1 a 8.

Métrica de desempenho 1	% Sucesso	Média geração	IC geração	
			Mínimo	Máximo
Metodologia C	100,00	10,83	9,31	12,36
Metodologia 1	100,00	12,80	9,73	15,87
Metodologia 2	100,00	10,67	8,99	12,34
Metodologia 3	100,00	9,50	7,91	11,09
Metodologia 4	100,00	11,93	10,53	13,34
Metodologia 5	100,00	10,20	8,53	11,87
Metodologia 6	100,00	9,67	8,24	11,09
Metodologia 7	100,00	9,83	8,30	11,37
Metodologia 8	100,00	10,07	8,28	11,85

Tabela 18 – Métrica de desempenho 2 para as metodologias C e 1 a 8.

Métrica de desempenho 2	% Sucesso	Média solução	Média geração	IC solução		IC geração	
				Mínimo	Máximo	Mínimo	Máximo
Metodologia C	56,67	2,37	788,94	2,11	2,62	120,87	1.457,01
Metodologia 1	30,00	2,00	595,22	1,72	2,28	0,00	1.236,99
Metodologia 2	50,00	2,20	1.044,40	1,90	2,50	0,00	2.264,21
Metodologia 3	63,33	2,47	1.485,84	2,19	2,74	551,77	2.419,91
Metodologia 4	36,67	2,10	1.537,91	1,83	2,37	386,12	2.689,70
Metodologia 5	23,33	2,13	22,14	1,93	2,34	18,99	25,29
Metodologia 6	40,00	2,23	1.556,68	1,97	2,49	437,56	2.675,62
Metodologia 7	40,00	2,30	29,58	2,07	2,53	22,80	36,37
Metodologia 8	53,33	2,33	1.155,3	2,06	2,60	179,41	2.131,22

Tabela 19 – Métrica de desempenho 3 para as metodologias C e 1 a 8.

Métrica de desempenho 3	% Sucesso	Média solução	Média geração	IC solução		IC geração	
				Mínimo	Máximo	Mínimo	Máximo
Metodologia C	10,00	9,67	479,00	8,54	10,80	271,02	686,98
Metodologia 1	20,00	9,93	1.829,17	8,34	11,52	1.240,20	2.417,91
Metodologia 2	26,67	10,97	1.585,63	9,37	12,57	624,96	2.546,29
Metodologia 3	0,00	8,60	-	7,73	9,47	-	-
Metodologia 4	13,33	9,87	2.532,25	8,55	11,19	1.074,93	3.989,57
Metodologia 5	6,67	8,17	481,00	7,08	9,25	311,98	650,02
Metodologia 6	13,33	9,47	2.171,00	8,12	10,81	1.250,58	3.091,42
Metodologia 7	13,33	9,57	311,50	8,28	10,86	245,19	377,81
Metodologia 8	33,33	11,43	1.625,10	9,69	13,18	813,87	2.436,33

O Gráfico 8 mostra a porcentagem acumulada da fronteira Pareto por geração segundo as metodologias C e 1, em que a diferença básica é que, na segunda metodologia, a técnica de *seeding* não foi utilizada. Segundo a métrica de desempenho 1, ambas as metodologias obtiveram 100% de sucesso, sendo que a metodologia sem a utilização do *seeding* requer, em média, mais gerações para encontrar a primeira solução. Gráficamente, percebe-se que a metodologia base possui uma ascensão mais rápida para a fronteira Pareto, com uma evolução melhor, no que diz respeito à porcentagem de soluções da fronteira, até próximo da geração 2.800, quando é superada pela Metodologia 1.

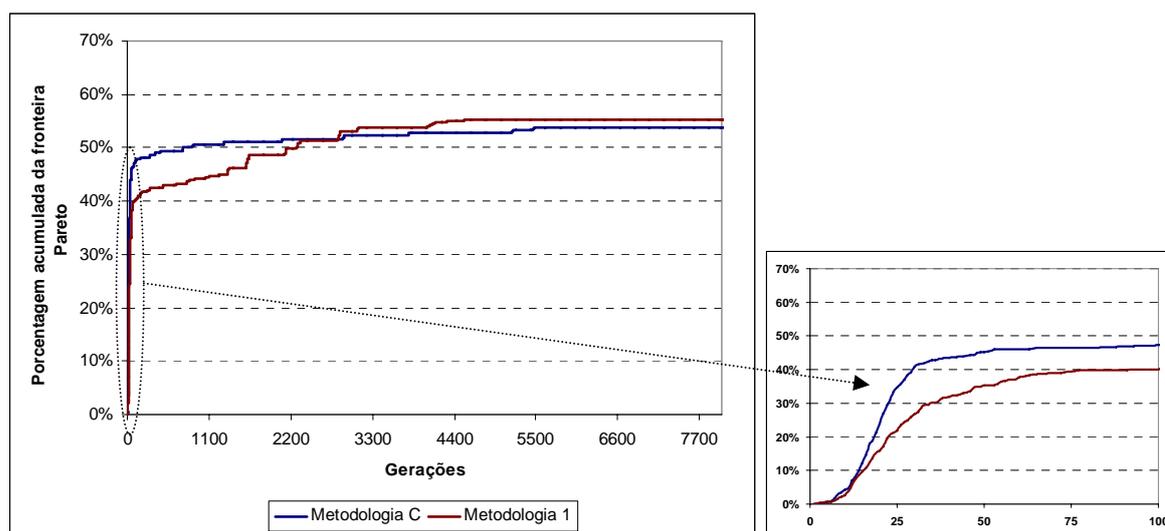


Gráfico 8 – Evolução para a fronteira Pareto das metodologias C e 1.

Segundo a métrica de desempenho 2, a Metodologia 1 obteve apenas 30% de sucesso, contra 56,67% de sucesso da metodologia base, apesar de requerer um número de gerações

menor, em média, para obter o sucesso. A métrica de desempenho 3 foi a única em que a metodologia sem o *seeding* obteve uma proporção maior de sucesso, embora a quantidade de soluções distintas da fronteira encontradas no final da otimização tenha sido pouco variável entre essas metodologias (9,67 soluções na metodologia C e 9,93 soluções na metodologia 1) e o número médio de gerações para atingir o sucesso tenha sido significativamente superior.

Com relação ao método de seleção, a Metodologia C, a qual utiliza a seleção por torneio, possui desempenho melhor do que a Metodologia 2, que utiliza a seleção por SUS, no número médio de gerações requeridas nas métricas 2 e 3, havendo, no entanto, uma equivalência entre as metodologias quanto ao número de gerações da métrica 1. Com relação à proporção de sucessos, a metodologia base obteve desempenho superior na métrica 2, porém, pouco variável: 56,67% de sucesso na Metodologia C contra 50,00% de sucesso na Metodologia 2, resultado que se reproduz no número médio de soluções extremas mínimas encontradas.

Segundo a métrica de desempenho 3, a Metodologia 2 possui uma probabilidade maior de sucesso do que a metodologia base, encontrando a fronteira Pareto completa em 26,67% das execuções contra 10,00% da Metodologia C, e encontrando, em média, 10,97 soluções ao final da otimização. O Gráfico 9 mostra a evolução dessas duas metodologias, onde se pode perceber certo equilíbrio entre as metodologias nas 50 gerações iniciais, com ultrapassagem significativa da Metodologia 2, mantida até o final da otimização.

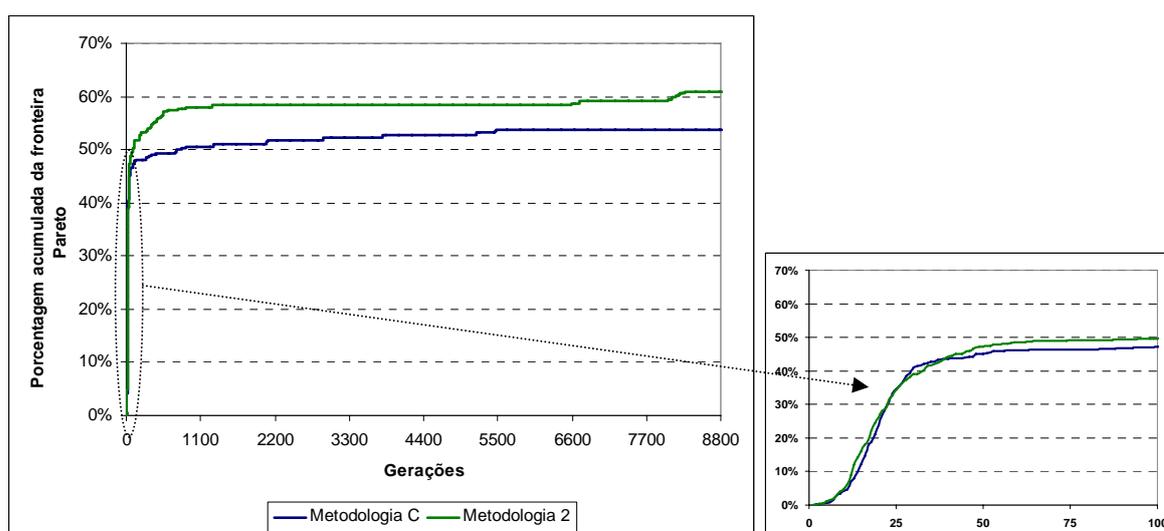


Gráfico 9 – Evolução para a fronteira Pareto das metodologias C e 2.

Com relação ao descarte e reparo dos indivíduos, a Metodologia 3 utiliza o procedimento do descarte na geração da população inicial e na reprodução dos indivíduos, enquanto que a Metodologia 4 substitui o descarte durante a reprodução pelo procedimento de reparo. Os resultados indicam que a Metodologia 3 possui desempenho melhor do que a metodologia base e do que a Metodologia 4 na métrica de desempenho 1, e na proporção de sucesso e número de soluções da métrica de desempenho 2; no entanto, requer um número médio de gerações maior do que a metodologia base na métrica de desempenho 2 e obteve o pior resultado na métrica de desempenho 3, quando não atingiu o sucesso em 100% das execuções. A Metodologia 4 apenas apresentou resultados levemente melhores do que a metodologia base na proporção de sucessos e no número médio de soluções da métrica de desempenho 3.

O Gráfico 10 apresenta os resultados segundo a métrica de desempenho 3 para as Metodologias 3 e 4 em comparação com a metodologia base. Percebe-se a superioridade da Metodologia 3 no início da otimização mas, por volta da geração 25, essa metodologia é superada pela metodologia base e, por volta da geração 75, pela Metodologia 4. A metodologia base segue superior às outras por quase toda a otimização, sendo superada, então, pela Metodologia 4 por volta da geração 8.500.

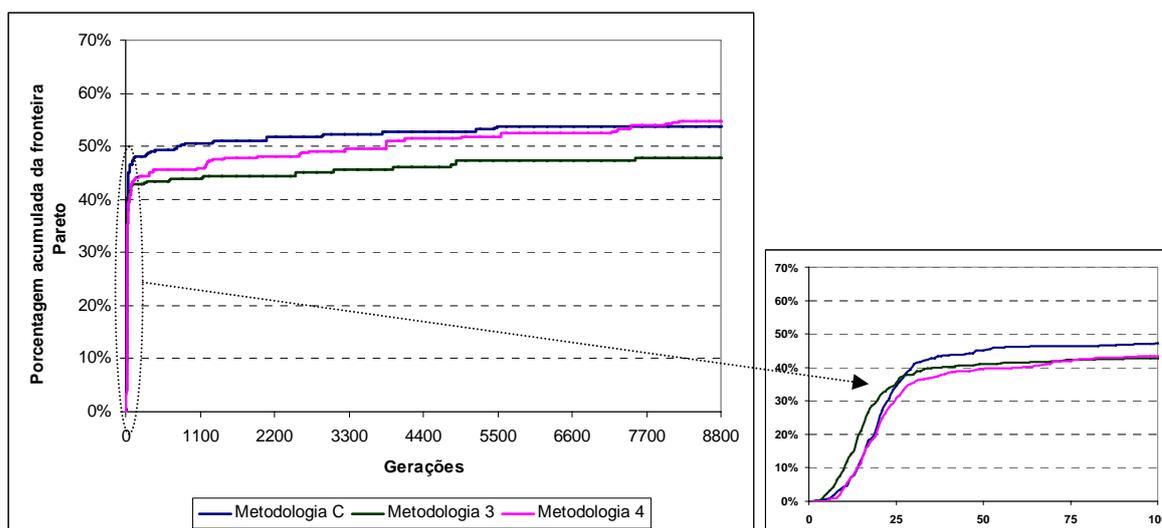


Gráfico 10 – Evolução para a fronteira Pareto das metodologias C, 3 e 4.

Os operadores de reprodução foram avaliados de cinco formas diferentes: a metodologia base utiliza os operadores tradicionais (cruzamento de um ponto e de mutação bit a bit); a

Metodologia 5 utiliza os operadores direcionados definidos por Brasileiro (2005) em conjunto com os tradicionais, na proporção de 70% direcionado e 30% tradicional; e a Metodologia 6 utiliza os operadores direcionados definidos por Machado *et al.* (2005) em conjunto com os tradicionais na mesma proporção. As metodologias 7 e 8 avaliam respectivamente os operadores direcionados definidos por Brasileiro (2005) e por Machado *et al.* (2005), mas com as proporções invertidas: 30% direcionado contra 70% tradicional.

Segundo a métrica de desempenho 1, todas as variações dos operadores direcionados apresentaram resultados melhores do que o método base, com o melhor resultado obtido na metodologia 6, a qual requer, em média, 9,70 gerações; todavia, de um modo geral, os resultados nessa métrica foram pouco variáveis.

As metodologias que utilizam os operadores direcionados apresentaram proporções de sucesso e média de soluções inferiores à metodologia base segundo a métrica de desempenho 2, em todas as suas variações, onde a pior probabilidade de sucesso foi atingida pela Metodologia 5, com 23,33%. Na média do número de gerações necessárias para atingir o sucesso, no entanto, a metodologia base apenas foi superior às variações propostas por Machado *et al.* (2005), pois as Metodologias 5 e 7, que utilizam os operadores direcionados propostos por Brasileiro (2005), apresentaram médias expressivamente melhores.

Segundo a métrica de desempenho 3, percebe-se que a Metodologia 5, das que utilizam os operadores direcionados, foi a única que apresentou proporção de sucesso inferior à metodologia base. Contudo houve nas Metodologias 6 e 7, apesar das proporções ligeiramente melhores, uma média de soluções da fronteira Pareto bem pouco variável, girando em torno de 9,50 soluções da fronteira encontrada.

A Metodologia 8, a qual utiliza os operadores direcionados definidos por Machado *et al.* (2005), na proporção de 30% tradicional contra 70% direcionado, foi a que apresentou melhor desempenho nessa métrica, tanto na proporção de sucessos (33,33%) quanto no número de soluções da fronteira Pareto, 11,40 soluções. As Metodologias 5 e 7, mais uma vez, apresentaram os melhores valores médios do número de gerações para atingir o sucesso, com o melhor resultado permanecendo na Metodologia 7 que, quando consegue encontrar a fronteira Pareto, o faz em média com 311,50 gerações.

No Gráfico 11 percebe-se a maior rapidez da ascensão das Metodologias 5 e 7, confirmadas numericamente pelos valores médios das gerações, e a superioridade da

Metodologia 8, confirmada numericamente pela média do número de soluções e proporção de sucessos segundo a métrica de desempenho 3.

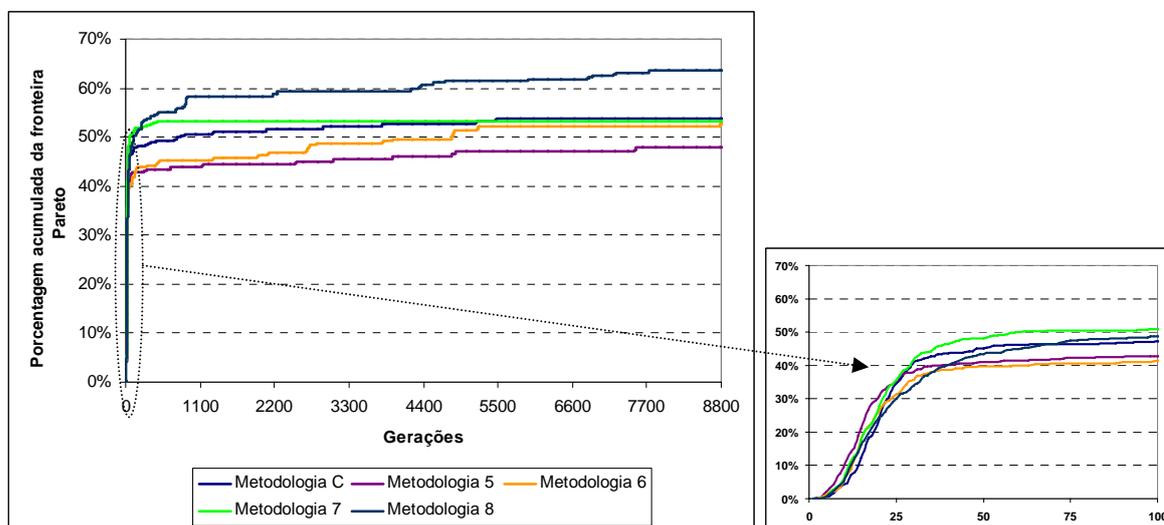


Gráfico 11 – Evolução para a fronteira Pareto das metodologias C, 5, 6, 7 e 8.

Em relação às proporções de operadores direcionados e tradicionais, a proporção em que se utiliza 70% de operadores tradicionais contra 30% de operadores direcionados mostrou-se mais satisfatória na maioria das métricas. Apenas os operadores direcionados definidos por Machado *et al.* (2005) foram melhores na outra proporção na média da métrica 1 (9,67 contra 10,07), e os operadores definidos por Brasileiro (2005), na média da métrica 2 (22,14 contra 29,58), mas pouco significativos quando comparados às proporções de sucessos.

Na análise global das métricas, percebe-se que a métrica de desempenho 1, dada pelo número de gerações para encontrar uma solução da fronteira Pareto, apresentou resultados equivalentes ou pouco variáveis entre as metodologias, sendo o mínimo valor da média dessa métrica encontrado na Metodologia 3 (9,50 gerações), seguida de perto pelas Metodologias 6 (9,70 gerações) e 7 (9,83 gerações). O máximo valor para essa métrica foi encontrado na Metodologia 1 (12,80 gerações), a qual é a única que não utiliza a técnica de *seeding*.

Segundo a métrica de desempenho 2, a metodologia que obteve o melhor resultado, em termos de proporção de sucesso e número de soluções, foi a Metodologia 3, com 63,33% de sucesso e 2,47 funções-objetivo com as soluções mínimas, em média. Algumas metodologias obtiveram uma proporção de sucessos abaixo de 50% como as Metodologias 1, 4, 5, 6 e 7,

sendo o pior resultado obtido para a Metodologia 5, com apenas 23,33% de sucesso e o pior resultado da média de soluções obtido para a Metodologia 1, com 2,00 soluções.

Na análise da média do número de gerações necessárias para atingir o sucesso, considerando apenas os casos em que foi atingido, a Metodologia 5 destaca-se como a de menor valor da média, com apenas 22,14 gerações, seguida pela Metodologia 7 (29,58 gerações), a qual é idêntica à Metodologia 5 mas com proporções diferentes dos operadores de reprodução. Os valores médios obtidos para essas duas metodologias se destacam entre os demais, os quais possuem limites superiores do intervalo de confiança sempre maior do que 1.000 gerações.

O sucesso definido para a métrica de desempenho 3 é o mais difícil de ser atingido, pois requer que a metodologia encontre, durante a otimização, 100% da fronteira Pareto. De um modo geral, as metodologias que obtiveram melhores desempenhos nas outras métricas falham nesse critério, o que é o caso da Metodologia 3, que obteve os melhores resultados nas métricas de desempenho 1 e 2, mas obteve 0,00% de sucesso na métrica de desempenho 3.

A metodologia que obteve o melhor resultado segundo a métrica de desempenho 3 foi a Metodologia 8, (33,33% de sucesso e em média 11,43 soluções) a qual havia apresentado bons resultados nas outras métricas, mas não chegou a apresentar melhor desempenho nelas. Outros bons resultados obtidos na terceira métrica, em termos de proporção de sucesso e número de soluções ocorreram nas metodologias 2 e 1, respectivamente com 26,67% e 20,00%. Os piores resultados, tanto em termos de sucesso quanto em termos do número de soluções da fronteira Pareto encontradas, ocorreram nas Metodologias 3 e 5, as quais apresentaram bons resultados nas métricas anteriores. Os melhores resultados em termos do número médio de gerações foram apresentados nas Metodologias 5 e 7.

### **Análise dos resultados**

A eficiência de cada metodologia será avaliada considerando os resultados da média do número de gerações necessárias para se atingir o sucesso nas métricas definidas. Quanto menor for o valor médio do número de gerações, maior será a sua eficiência. A eficácia será medida exclusivamente utilizando os resultados da métrica de desempenho 3: quanto maior for a proporção de sucesso e o número médio de soluções da fronteira encontrados nessa métrica, mais eficaz será considerada a metodologia.

No cenário avaliado, percebeu-se que as soluções da fronteira estão agrupadas em grupos bem distribuídos entre as soluções viáveis (Gráfico 2, pág. 99), que, por sua vez, estão agrupadas em grupos bem definidos e distribuídos entre as inviáveis (Gráfico 4, pág. 101). Isso significa que, para encontrar as soluções que correspondem aos valores extremos mínimos de cada função-objetivo em uma mesma otimização, é necessário que a metodologia seja capaz de varrer o espaço de busca e ultrapassar as barreiras formadas pelas regiões inviáveis. Logo, a presença dessas soluções no resultado da metodologia é um bom indicador da capacidade da metodologia encontrar soluções diversas. Sendo assim, a diversidade das soluções será avaliada através da proporção de sucesso da métrica de desempenho 2, onde, quanto maior for a proporção de sucesso nesse métrica, melhor será qualificada a metodologia no critério da diversidade das soluções.

O algoritmo genético é bastante flexível e permite introduzir nos seus operadores duas técnicas necessárias para melhorar o desempenho de qualquer método de otimização: a técnica de *exploration*, que consiste em explorar pontos distintos no espaço de busca, e a técnica de *exploitation*, que consiste em utilizar as informações presentes nas soluções já encontradas para guiar a busca. Na metodologia base, como em um algoritmo genético tradicional, a técnica de *exploration* é encontrada no operador de seleção, que utiliza a informação da aptidão dos indivíduos para guiar a busca, enquanto que a técnica de *exploitation* é utilizada nos operadores de reprodução, que introduzem variações nos cromossomos explorando novos pontos do espaço de busca.

Embora todas as alternativas introduzidas na metodologia base tenham como finalidade considerar e/ou tratar a inviabilidade das soluções, portanto caracterizando-se como técnicas de *exploitation*, as metodologias enfatizam essa técnica em magnitudes distintas, e essa influência pode ser relacionada aos resultados obtidos.

A inserção de uma solução viável na população inicial através da técnica de *seeding* é uma evidência da utilização da técnica de *exploitation* no início da otimização. Os resultados indicam que a exclusão do *seeding* faz com que a otimização perca em eficiência, no que se refere a encontrar mais rápido as soluções da fronteira. Por outro lado, o aumento do *exploration* obtido com a exclusão do *seeding* permite uma busca mais diversificada, fazendo com que mais soluções da fronteira Pareto, em média, sejam encontradas.

Na comparação do procedimento de descarte com o procedimento de reparo dos indivíduos que provocam transbordo nos tanques durante a reprodução, temos o seguinte: enquanto a primeira simplesmente descarta o indivíduos e seleciona outros pais para

reproduzir, a segunda corrige o cromossomo onde foi detectada essa inviabilidade, tentando impor a progressão mais rápida para uma solução viável, utilizando a informação da solução avaliada. Como a porcentagem de indivíduos do espaço de busca que produzem essa inviabilidade é considerável, isto é 55,00%, deduz-se que este reparo tenha sido realizado inúmeras vezes, o que enfatiza a técnica de *exploitation*.

Foi observado nos resultados que a utilização do procedimento de descarte tende a produzir os melhores resultados em termos de eficiência e em termos de distribuição das soluções encontradas. No entanto, possivelmente esta metodologia não conseguirá progredir para a totalidade da fronteira real de Pareto.

A melhor combinação dos operadores direcionados com os tradicionais, tanto quando da utilização dos definidos por Brasileiro (2005) quanto da utilização dos definidos por Machado *et al.* (2005), foi encontrada na proporção de 30% direcionado contra 70% tradicional. Daí conclui-se que o excesso do *exploitation*, utilizado na proporção em que se intensifica o uso do operador direcionado (70% direcionado contra 30% tradicional) tornou a busca muito guiada, não oferecendo vantagens.

Em comparação com a metodologia base, os operadores de reprodução com a proporção de 30% direcionado contra 70% tradicional melhoram o desempenho do método base nos seguintes aspectos: encontram mais rápido uma solução da fronteira e possuem uma probabilidade maior de encontrar 100% da fronteira Pareto, o que reforça a análise feita anteriormente de que a técnica de *exploitation*, quando utilizada de forma moderada, pode trazer benefícios de eficácia para a metodologia. Segundo o critério de diversidade os operadores direcionados obtiveram desempenho inferior ao método base, o que pode ser justificado pelo aumento do *exploration* da metodologia base, o que facilita uma varredura maior do espaço de busca.

Mesmo tendo obtido probabilidade menor de sucesso segundo a métrica de desempenho 2, a metodologia que utiliza os operadores direcionados definidos por Brasileiro (2005), na proporção de 30% direcionado contra 70% tradicional, obteve resultados excelentes em termos de eficiência, o que nos permite concluir que a utilização desse operador produz bons resultados rapidamente, mas tem dificuldade em progredir para os ótimos globais. A metodologia que utiliza os operadores direcionados definidos por Machado *et al.* (2005), na mesma proporção, possui potencialidades complementares, já que enfatiza a eficácia.

Nesse caso, pode-se dizer também que o aumento do *exploitation* contribuiu para a eficácia do método, penalizando a sua eficiência e a diversidade das soluções, pois a mutação direcionada utilizada nos operadores direcionados propostos por Machado *et al.* (*op. cit*), considera não apenas o ponto de falha do cromossomo mas, também, o tipo de alarme que ocorre nesse intervalo, invertendo o bit de maneira coerente com este tipo de alarme, ou seja, enfatizado a técnica de *exploitation*. Além disso, esta mutação possui frequência de atuação maior do que a definida por Brasileiro (*op. cit*), pois é avaliada em todos os indivíduos destinados ao operador tradicional de cruzamento e em alguns indivíduos destinados ao operador de cruzamento direcionado, enquanto que a mutação direcionada definida por Brasileiro (*op. cit*) apenas atua em casos específicos nos indivíduos enviados para o operador de cruzamento direcionado.

A utilização da seleção por SUS oferece vantagens para a eficácia do método, sem comprometer muito os critérios de diversidade e de eficiência. Ambos os métodos de seleção por SUS e por torneio utilizam os conceitos de dominância, viabilidade, ponto de falha e severidade dos alarmes, mas a técnica do SUS, por sua própria definição, permite um certo equilíbrio entre as soluções selecionadas. Além disso, a metodologia com o SUS está sendo utilizada em conjunto com uma função de escalonamento linear da aptidão, a qual fornece uma probabilidade de seleção maior aos melhores indivíduos. A metodologia com torneio apenas impõe a vitória do indivíduo mais apto no torneio, mas a escolha dos pares do torneio é totalmente randômica, o que reduz a técnica de *exploitation* e permite uma certa aleatoriedade na evolução.

Contrapondo as análises da relação entre a técnica de *exploitation* e a técnica de *exploration* nas metodologias com os resultados dos experimentos, é possível inferir que:

- ♣ As metodologias que acentuam a utilização da técnica de *exploitation* durante a evolução do algoritmo tendem a priorizar a eficácia do método, permitindo que mais soluções da fronteira Pareto sejam encontradas;
- ♣ A eficiência e a diversidade das soluções obtidas são mais facilmente conseguidas, ao utilizar-se metodologias que utilizam menos intensamente o *exploitation*;
- ♣ É recomendável utilizar a técnica do *seeding* em qualquer ocasião, pois a sua exclusão prejudica significativamente as propriedades de eficiência e diversidade das metodologias, e oferece poucas melhorias na eficácia do método;

- ♣ A metodologia com o SUS deve ser aplicada quando se deseja priorizar a eficácia do algoritmo sem penalizar muito a sua eficiência e diversidade;
- ♣ A metodologia com torneio deve ser utilizada quando se deseja priorizar a eficiência da metodologia sem penalizar muito a sua eficácia e diversidade;
- ♣ O procedimento de descarte no início da otimização e na reprodução dos indivíduos deve ser utilizado com restrições, pois melhora significativamente o desempenho quanto à diversidade, mas penaliza muito a eficácia da metodologia;
- ♣ A utilização do procedimento de descarte no início da otimização e reparo na reprodução melhora apenas suavemente a eficácia do algoritmo, mas penaliza muito a sua eficiência e diversidade;
- ♣ A proporção recomendada para se utilizar os operadores direcionados é de 70% tradicional e 30% direcionado;
- ♣ Os operadores direcionados definidos por Brasileiro (2005) são recomendados quando se deseja priorizar a eficiência do método, e obter resultados moderados em termos de eficácia e diversidade;
- ♣ Os operadores direcionados definidos por Machado *et al.* (2005) são recomendados quando se deseja priorizar a eficácia do método e obter resultados moderados em termos de eficiência e diversidade.

### **5.2.3 Avaliação das alternativas incorporadas conjuntamente à metodologia base**

Como esse trabalho se propôs a estudar diversas alternativas metodológicas para tratar o problema, com o objetivo principal de obter uma metodologia genérica aplicável e adaptável a qualquer situação, novos experimentos foram conduzidos com o objetivo de tentar se definir um método eficiente, aplicável a problemas que requeiram uma resposta em um curto espaço de tempo, e outro método eficaz, quando se deseja chegar mais próximo do ótimo global do sistema.

Desta forma, os operadores definidos por Machado *et al.* (2005), associados à metodologia que utiliza o SUS, demonstram ser uma combinação que pode proporcionar

ganhos adicionais de eficácia, já que essas metodologias individualmente mostraram ser eficazes. No entanto, foi observado, também, que o excesso de *exploitation* pode não ser vantajoso; logo, é necessário conduzir novos experimentos para averiguar se a junção de metodologias que, individualmente mostraram eficácia, resultará em um método mais eficaz. Deste modo, novos experimentos foram conduzidos utilizando os operadores Machado *et al.* (*op. cit*) (na proporção de 70% tradicional e 30% direcionado) com o operador de seleção SUS, denominado de Metodologia 9.

O procedimento de reparo dos indivíduos, por ter-se mostrado um pouco vantajoso no critério de eficácia, apesar do desempenho insatisfatório nos outros critérios, foi associado à Metodologia 9 em um outro experimento, denominado Metodologia 10.

As melhores combinações para a eficiência, além do método de seleção por torneio em conjunto com os operadores direcionados definidos por Brasileiro (2005) (na proporção de 30% direcionado e 70% tradicional), que já foi avaliada anteriormente na Metodologia 7, foram avaliados em um novo experimento, com a introdução do procedimento de descarte, pois esse procedimento, individualmente, mostrou grande vantagem em termos de eficiência. Este novo experimento foi denominado de Metodologia 11, e espera-se que o mesmo seja satisfatório também no critério da diversidade.

## Resultados

As tabelas 20 a 22 mostram um resumo dos resultados obtidos para cada métrica de desempenho segundo as novas metodologias avaliadas e o Gráfico 12, vide página seguinte, mostra a evolução para a fronteira Pareto dessas metodologias.

Tabela 20 – Métrica de desempenho 1 para as metodologias 9, 10 e 11.

Métrica de desempenho 1	% Sucesso	Média geração	IC geração	
			Mínimo	Máximo
Metodologia 9	100,00	10,10	8,52	11,68
Metodologia 10	100,00	9,93	7,95	11,91
Metodologia 11	100,00	8,97	6,90	11,03

Tabela 21 – Métrica de desempenho 2 para as metodologias 9, 10 e 11.

Métrica de desempenho 2	% Sucesso	Média solução	Média geração	IC solução		IC geração	
				Mínimo	Máximo	Mínimo	Máximo
Metodologia 9	43,33	2,30	865,69	2,02	2,55	72,81	1.658,58
Metodologia 10	56,67	2,43	2.463,59	2,17	2,69	1.118,37	3.808,81
Metodologia 11	50,00	2,40	25,80	2,16	2,64	18,27	33,33

Tabela 22 – Métrica de desempenho 3 para as metodologias 9, 10 e 11.

Métrica de desempenho 3	% Sucesso	Média solução	Média geração	IC solução		IC geração	
				Mínimo	Máximo	Mínimo	Máximo
Metodologia 9	20,00	10,10	720,67	8,59	11,61	499,31	942,02
Metodologia 10	23,33	10,83	1.031,57	9,33	12,33	462,48	1.600,67
Metodologia 11	0,00	8,70	-	8,11	9,29	-	-

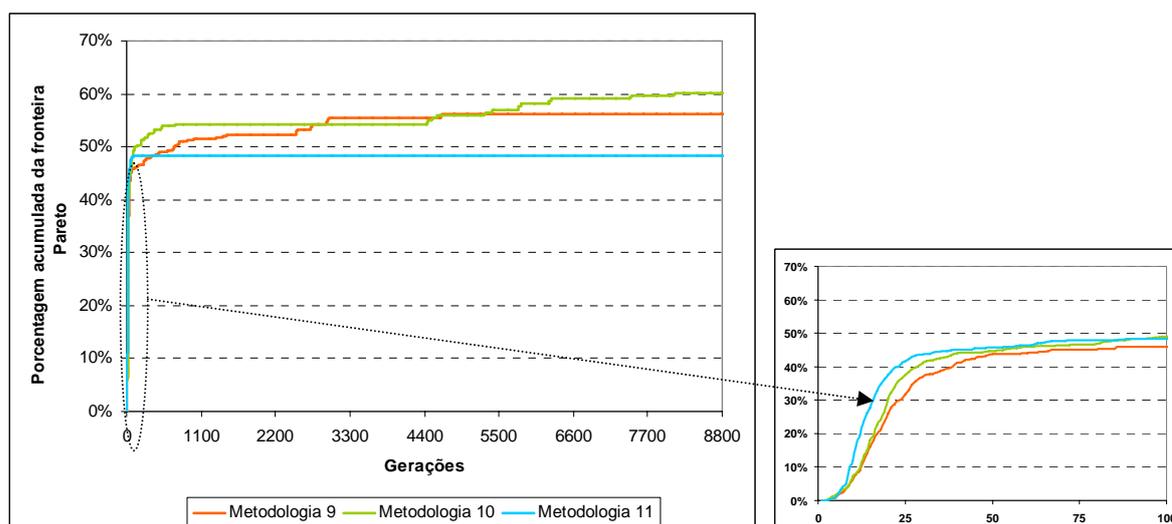


Gráfico 12 – Evolução para a fronteira Pareto das metodologias 9, 10 e 11.

### Análise dos resultados

Observa-se que no critério eficácia a Metodologia 10, que combina os operadores de Machado *et al.* (2005) com o procedimento de reparo e o método SUS, obteve uma leve vantagem sobre a metodologia sem o procedimento de reparo (Metodologia 9), tendo sido inclusive, melhor também na métrica de desempenho 1 e na proporção de sucesso da métrica de desempenho 2. No entanto, ambas as metodologias obtiveram proporção de sucesso na métrica de desempenho 3 inferior à Metodologia 8, que obteve 33,33% de sucesso, e da Metodologia 2, com 26,67% de sucesso. Isto é, a combinação das metodologias que individualmente mostraram melhorias na eficácia, em relação à metodologia base, não

resultaram em um ganho na eficácia. A vantagem da Metodologia 10 sobre a 9 também pode ser observada graficamente.

Segundo o critério do número médio de gerações necessárias para atingir o sucesso nas três métricas de desempenho, a Metodologia 9, que combina apenas o SUS com os operadores definidos por Machado *et al.* (*op. cit.*), mostrou melhores resultados do que metodologias mais eficazes (Metodologias 2, 4, 8 e 10), perdendo em eficiência apenas para as metodologias destacadas como mais eficientes. Segundo a métrica de desempenho 3, por exemplo, as Metodologias 2, 8 e 10 possuem uma proporção de sucesso maior, mas, no entanto, requerem em média 1.044,40, 1.155,30 e 1.031,57 gerações, contra 720,67 da Metodologia 9.

Analisando a métrica de desempenho 2, observa-se o mesmo resultado, onde a Metodologia 9 tem uma proporção de sucesso inferior às metodologias 10, 8 e 2, mas possui uma média de 865,59 gerações, enquanto que todas as outras estão acima de 1.000,0. Pode-se, então, concluir que, apesar de não ter conseguido encontrar uma metodologia mais eficaz em termos de proporção de sucesso da métrica de desempenho 3, a combinação da Metodologia 9, realizada para esse fim, resultou em uma metodologia equilibrada.

A Metodologia 11, a qual combinou metodologias com bom desempenho no critério de eficiência, confirmou ser de alto desempenho para esse critério, pois obteve a menor média dentre todos os métodos na métrica de desempenho 1 (8,97), e, na métrica de desempenho 2 foi superior apenas à Metodologia 5 (25,80 contra 22,14). A Metodologia 5, por sua vez, apresentou proporção de sucesso baixo na métrica de desempenho 2 (23,33%) enquanto a Metodologia 11 mostrou uma proporção satisfatória (50,0%). No entanto, a Metodologia 11 mostrou-se totalmente ineficaz, por não ter obtido o sucesso em nenhuma execução na métrica de desempenho 3.

Da análise dos resultados da incorporação das alternativas metodológicas combinadas, pode-se concluir que:

- ♣ A combinação de metodologias que individualmente se mostraram eficazes não resultou em um ganho de eficácia, mas resultou em um método equilibrado;
- ♣ A combinação de metodologias que individualmente se mostraram eficientes resultou em um ganho de eficiência e prejuízo maior ainda na eficácia.

### 5.3. Aplicação sobre a rede piloto

Foram aplicadas três metodologias na rede piloto: a Metodologia 8 (caracterizada como mais eficaz), a Metodologia 11 (caracterizada como mais eficiente) e a Metodologia 9 (com características de eficácia e eficiência equilibradas). O critério de parada adotado foi de 1.000 gerações, por estar contido no intervalo de confiança do número médio de gerações para se atingir o sucesso em todas as métricas daquelas metodologias, quando aplicadas na rede piloto simplificada.

#### Resultados

A Tabela 23 mostra a quantidade de soluções não-dominadas viáveis encontradas na população externa em cada otimização na rede piloto e a quantidade de soluções não-dominadas resultantes após a junção dos conjuntos de soluções de compromisso obtidas em cada execução de todas as metodologias.

Tabela 23 – Métrica de convergência para os experimentos sobre a rede piloto.

Metodologia	NDV individual	NDV conjunto
8 (1ª execução)	111	0
8 (2ª execução)	96	0
9 (1ª execução)	118	0
9 (2ª execução)	121	0
11 (1ª execução)	240	159
11 (2ª execução)	240	194
TOTAL	926	353

Observa-se que a Metodologia 11 consegue chegar ao final da otimização com toda a população externa preenchida de indivíduos não dominados viáveis (240 indivíduos), e que, na junção dos resultados de todas as execuções, das 480 soluções não-dominadas viáveis resultantes dessa metodologia, 353 permanecem não-dominadas e dominam todas as outras soluções obtidas pelas Metodologias 8 e 9. Desse modo, a Metodologia 11 obteve os melhores resultados segundo a métrica de convergência.

A Tabela 24 mostra o valor da métrica de diversidade calculada para cada otimização na rede piloto. Quanto menor o valor dessa métrica, mais espaçadas estão as soluções não-

dominadas viáveis resultantes de cada execução, sendo zero o valor ideal. Observa-se que, também segundo o critério de diversidade, a Metodologia 11 obteve desempenho significativamente melhor do que as outras metodologias.

Tabela 24 – Métrica de diversidade para os experimentos sobre a rede piloto.

<b>Metodologia</b>	<b>Métrica de espaçamento</b>
8 (1ª execução)	0,0452
8 (2ª execução)	0,0466
9 (1ª execução)	0,0455
9 (2ª execução)	0,0529
11 (1ª execução)	0,0235
11 (2ª execução)	0,0232

A Tabela 25 mostra os valores mínimos de cada função-objetivo encontrado ao final de cada otimização executada sobre a rede piloto. Observa-se que os valores finais das funções-objetivo nas execuções da Metodologia 11 foram inferiores aos valores das Metodologias 8 e 9, com exceção de apenas um valor: o valor mínimo da função-objetivo 2 na primeira execução da Metodologia 8 foi de 9 chaveamentos, enquanto que o valor da primeira execução da Metodologia 11 foi de 10 chaveamentos.

Tabela 25 – Métrica de otimização para os experimentos sobre a rede piloto.

<b>Metodologia</b>	<b>Mínimo FO1</b>	<b>Mínimo FO2</b>	<b>Mínimo FO3</b>
8 (1ª execução)	0,07915	9	29,28
8 (2ª execução)	0,07923	10	28,62
9 (1ª execução)	0,07933	10	31,47
9 (2ª execução)	0,07935	11	28,74
11 (1ª execução)	0,07894	10	25,37
11 (2ª execução)	0,07891	5	25,70

Os gráficos 13 a 15 mostram a evolução das funções-objetivo ao longo das gerações. Graficamente, observa-se também a superioridade dos resultados obtidos utilizando-se a Metodologia 11 durante toda a evolução. Pode-se observar também que, além de obter melhores resultados no final da otimização, a queda do valor das funções-objetivo é muito brusca no início da otimização, e varia muito lentamente depois de 300 gerações.

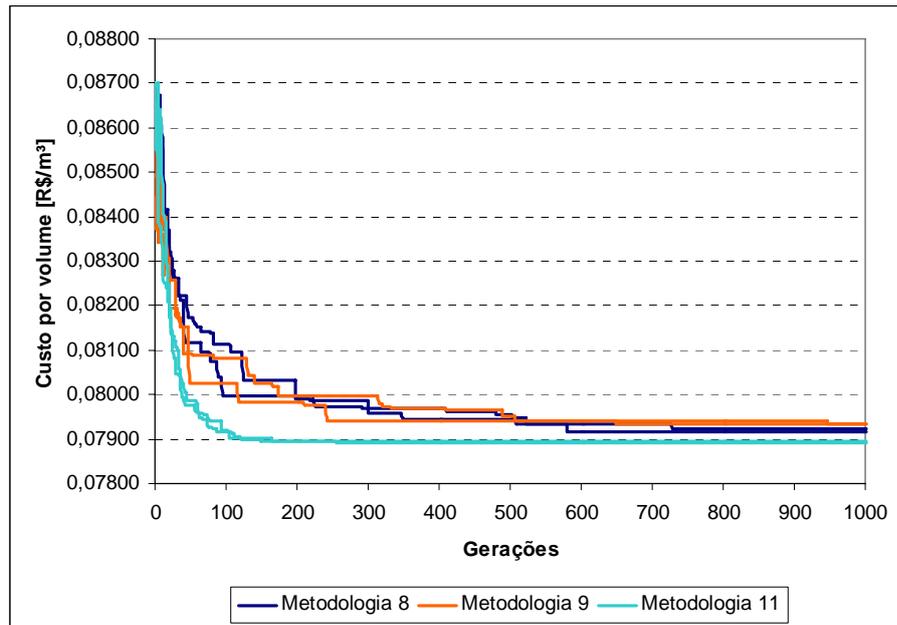


Gráfico 13 – Evolução da função-objetivo 1 das metodologias aplicadas sobre a rede piloto.

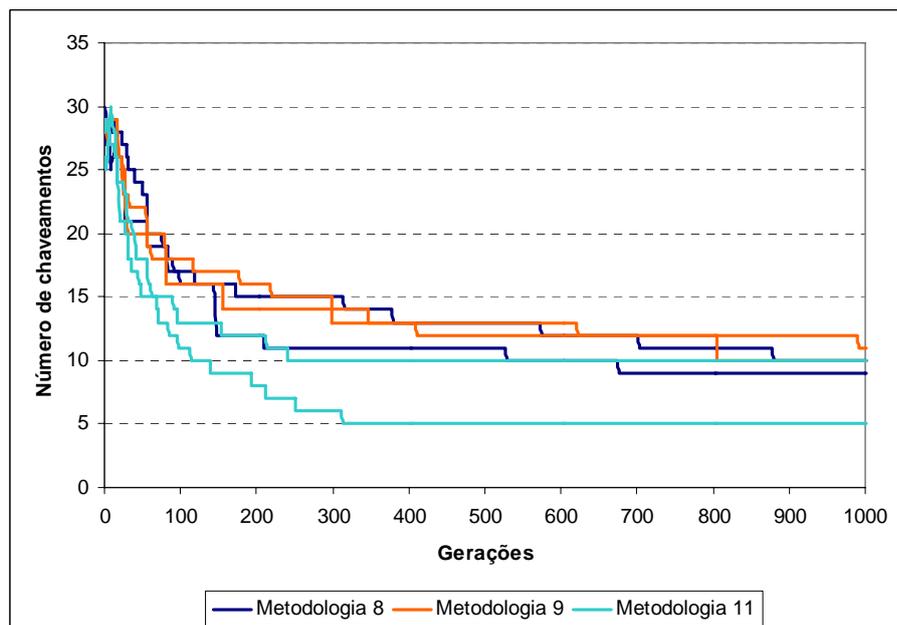


Gráfico 14 – Evolução da função-objetivo 2 das metodologias aplicadas sobre a rede piloto.

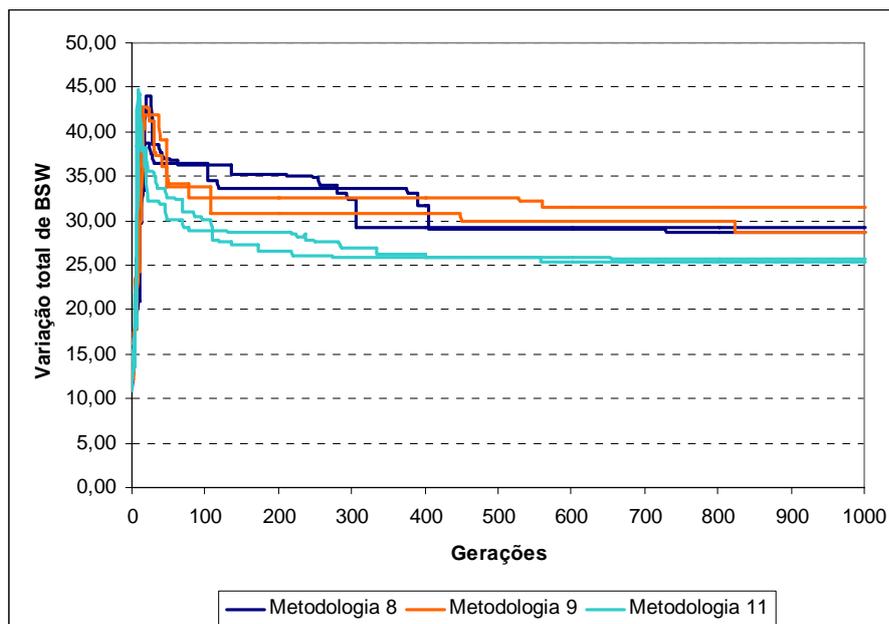


Gráfico 15 – Evolução da função-objetivo 3 das metodologias aplicadas sobre a rede piloto.

### Análise dos resultados

As características de eficiência e diversidade, já comprovadas com a aplicação sobre a rede piloto simplificada, foram confirmadas para a Metodologia 11 quando aplicada em uma rede de dimensão real. As outras metodologias, que demonstraram ser mais eficazes na rede piloto simplificada, não mostraram bons resultados para o número de gerações adotado. Embora o requisito de eficácia não possa ser efetivamente medido através da aplicação na rede piloto, observa-se que a Metodologia 11 obteve desempenho significativamente melhor nas três métricas consideradas, o que sugere a sua utilização em redes de dimensões reais.

Talvez seja requerido um número de gerações maior para que as Metodologias 8 e 9 possam oferecer alguma vantagem de eficácia sobre a Metodologia 11, pois pode ser observado nos gráficos da evolução das funções-objetivo, que os valores referentes às Metodologias 8 e 9 continuam decrescendo mesmo após ultrapassar 500 gerações, enquanto que os valores da Metodologia 11 já se estabilizaram. Porém, devido ao alto custo computacional e tempo de processamento requerido para analisar os resultados em um número maior de gerações, esta análise não foi realizada.

Desta forma, conclui-se que a Metodologia 11 é a mais indicada para ser aplicada em problemas de dimensão real, sendo necessário analisar apenas a qualidade das soluções

obtidas quando não se dispuser de tempo suficiente para analisar o mesmo número de gerações apresentadas nessa análise.

#### **5.4. Aplicação sobre a rede piloto com restrição temporal**

Foram executadas quatro otimizações utilizando a Metodologia 11 por ter mostrado melhor desempenho na etapa anterior. As duas primeiras execuções foram conduzidas com populações de 100 indivíduos e foram denominadas de 12/1 e 12/2, as duas últimas, com populações de 50 indivíduos, denominadas de 12/3 e 12/4.

#### **Resultados**

As tabelas 26 a 28 a seguir mostram os resultados das métricas de convergência, diversidade e otimização obtidas com os experimentos realizados sobre a rede piloto com restrição temporal, enquanto que os gráficos 16 a 18, vide páginas 129 e 130, mostram a evolução de cada função-objetivo nesses experimentos.

Tabela 26 – Métrica de convergência para os experimentos utilizando restrição temporal.

<b>Metodologia</b>	<b>NDV individual</b>	<b>NDV conjunto</b>
12 (1ª execução)	44	0
12 (2ª execução)	37	1
12 (3ª execução)	36	33
12 (4ª execução)	42	6
TOTAL	159	40

Tabela 27 – Métrica de diversidade para os experimentos utilizando restrição temporal.

<b>Metodologia</b>	<b>Métrica de espaçamento</b>
12 (1ª execução)	0,1105
12 (2ª execução)	0,1104
12 (3ª execução)	0,0693
12 (4ª execução)	0,0468

Tabela 28 – Métrica de otimização para os experimentos utilizando restrição temporal.

Metodologia	Mínimo FO1	Mínimo FO2	Mínimo FO3
12 (1ª execução)	0,08306	27	35,59
12 (2ª execução)	0,08323	24	38,97
12 (3ª execução)	0,08230	23	33,32
12 (4ª execução)	0,08298	26	31,23

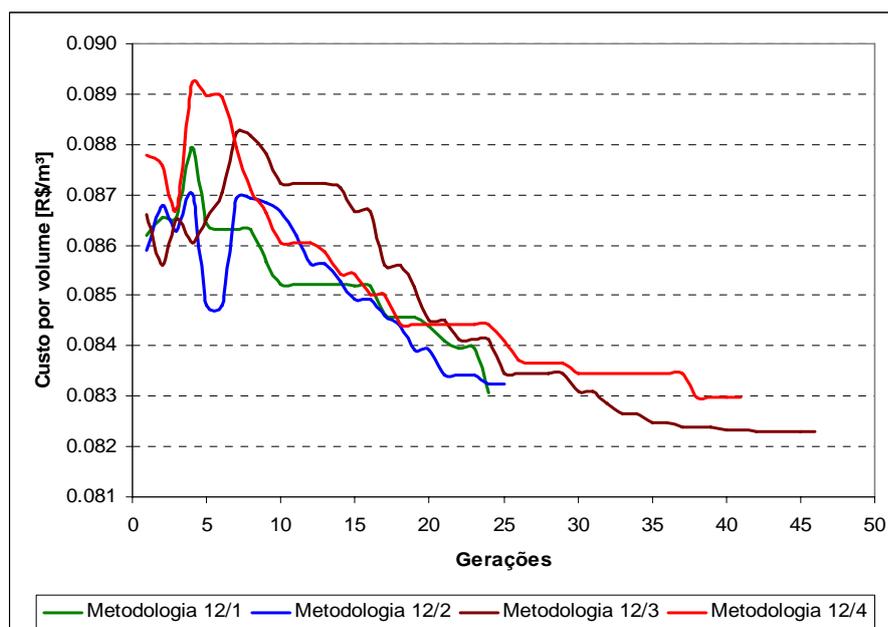


Gráfico 16 – Evolução da função-objetivo 1 dos experimentos utilizando restrição temporal.

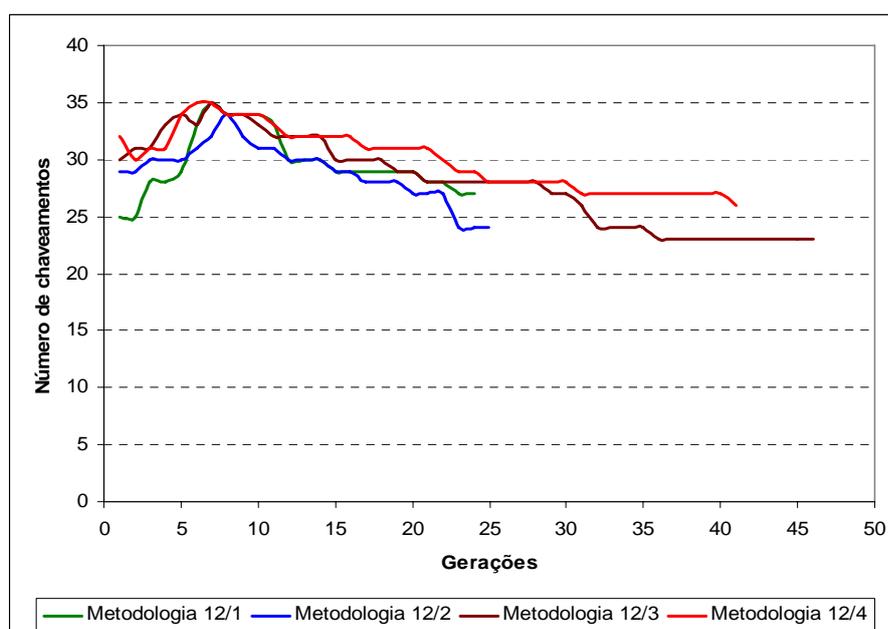


Gráfico 17 – Evolução da função-objetivo 2 dos experimentos utilizando restrição temporal.

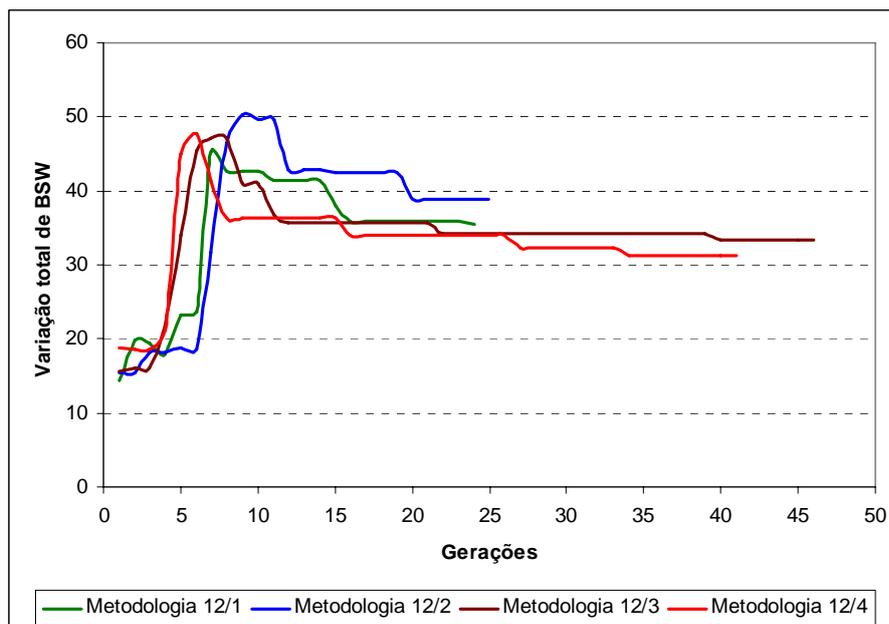


Gráfico 18 – Evolução da função-objetivo 3 dos experimentos utilizando restrição temporal.

### Análise dos resultados

As Metodologias 12/1 e 12/2 se referem à utilização de uma população de 100 indivíduos e evoluíram, respectivamente, por 24 e 25 gerações, enquanto que as Metodologias 12/3 e 12/4, ambas com 50 indivíduos, evoluíram por 46 e 41 gerações, respectivamente. Os resultados obtidos para os experimentos 12/3 e 12/4 foram ligeiramente melhores nos critérios avaliados quando comparados com os resultados dos experimentos segundo as metodologias 12/1 e 12/2, de onde se conclui que é mais vantajoso utilizar populações menores e avaliar mais gerações do que populações maiores, quando há uma restrição temporal.

Comparando-se os resultados obtidos para a rede piloto “sem” e “com” a restrição temporal, respectivamente etapas 3 e 4 desse trabalho, observa-se que o ganho obtido nos valores extremos mínimos das funções-objetivo 1 e 3 por não considerar a restrição temporal são, respectivamente, em torno de 4,3% para a função-objetivo 1 e, em torno de 23,0% para a função-objetivo 3. Sendo o principal ganho obtido sem a restrição temporal associado à função-objetivo 2, a qual refere-se ao número de chaveamentos do sistema, pois, foi encontrado um número mínimo de chaveamentos igual a 5, e, com a restrição, o mínimo valor encontrado foi de 23 chaveamentos.

No critério de diversidade, percebe-se também que o valor da métrica de espaçamento obtido sem a restrição temporal, no melhor resultado, foi de 0,0232, enquanto que ao limitar o

tempo, o melhor resultado obtido foi de 0,0468. No entanto, o resultado obtido com a restrição temporal também é considerado satisfatório, visto que é um valor próximo a zero.

Ao comparar as soluções não-dominadas encontradas nas execuções com a restrição temporal com as encontradas sem essa restrição, percebe-se que, as do segundo grupo dominam as demais. O que sugere que as soluções encontradas com a restrição temporal podem não estar tão próximas da fronteira Pareto como provavelmente as encontradas sem a restrição temporal estão.

Contudo, considera-se de um modo geral que os resultados obtidos com a restrição temporal foram satisfatórios, visto que, ao final do tempo disponível, foi possível preencher toda a população externa com 100% de indivíduos viáveis e, entre essa população, definir um bom número de soluções não-dominadas, ou seja, soluções que representam um compromisso para todos os objetivos e não violam nenhuma restrição, podendo, portanto, ser aplicadas. Ressalta-se ainda que esses resultados foram obtidos com apenas quatro computadores dedicados, logo, esperam-se melhorias nesses resultados com o aumento do poder computacional.

Um outro requisito a ser atendido para aplicação da metodologia selecionada nas operações de campo, consiste na possibilidade de escolha de uma única solução para ser aplicada e, para isso foi proposto, na seção 4.3.6, uma metodologia para redução e escolha de uma única solução final. Para ilustrar a aplicação dessa metodologia, escolheu-se a execução 12/3 por ter apresentado o maior número de soluções não-dominadas. A Tabela 29, vide página seguinte, mostra o conjunto final selecionado entre todas as soluções viáveis não-dominadas fornecidas na otimização, enquanto que o Gráfico 19, mostra essas soluções graficamente com os valores normalizados das funções-objetivo. Destaca-se a solução 6, provável indicada como solução do problema, em se considerando o critério da menor variância entre os valores das funções-objetivo.

Tabela 29 – Soluções finais para a rede piloto considerando a restrição temporal.

Soluções finais	FO1	FO2	FO3
1	0,08230	30	47,79
2	0,08626	23	50,85
3	0,08753	34	33,32
4	0,08893	30	42,81
5	0,08556	33	38,27
6	0,08513	26	55,72
7	0,08303	27	85,29

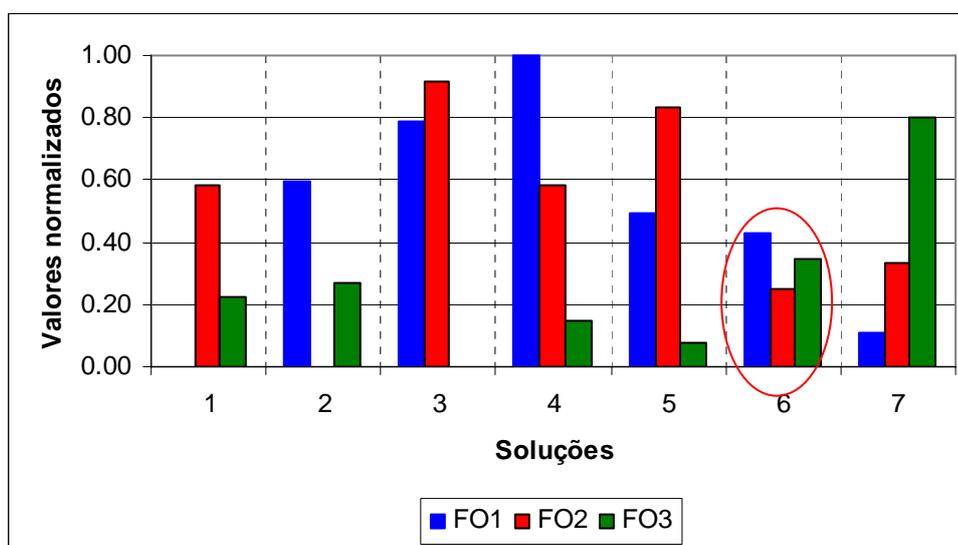


Gráfico 19 – Soluções finais normalizadas da otimização considerando a restrição temporal.

## 6. Conclusões e recomendações para estudos futuros

O trabalho realizado atendeu ao objetivo proposto, pois, após extensa revisão da literatura, foram extraídas, adaptadas e analisadas técnicas que definiram uma metodologia de otimização eficiente e aplicável a problemas reais em campo para a operação de redes de escoamento de petróleo. A metodologia foi definida da maneira mais genérica possível, com sugestões de funções-objetivo maleáveis e adaptáveis a critérios específicos da rede, sendo inclusive aplicáveis a redes de escoamento de água.

Algumas contribuições mais relevantes podem ser extraídas dos resultados desse trabalho:

- ♣ A caracterização do espaço de busca do escalonamento de bombas demonstrou a complexidade do problema da operação desses sistemas, evidenciada pelo alto número de alternativas inviáveis e pela distribuição das melhores soluções em todo o espaço de busca;
- ♣ O método SPEA2 pode ser considerado eficiente e eficaz para determinação do escalonamento de bombas ideal, desde que as restrições sejam consideradas de forma que auxiliem a evolução do método para a região de viabilidade;
- ♣ A utilização de técnicas específicas e a introdução de conhecimento durante a evolução do algoritmo genético são atitudes importantes para acelerar o desempenho do algoritmo, mas devem ser implementadas de maneira cuidadosa, pois o aumento da técnica de *exploitation* aumenta a eficácia do método, mas pode oferecer prejuízos em eficiência e diversidade.

Para utilização em problemas reais com redes semelhantes à analisada nessa pesquisa, a metodologia recomendada consiste em: 1) considerar, no preenchimento da população externa, os conceitos de viabilidade e dominância, separando os indivíduos viáveis dos inviáveis e analisando a dominância em cada sub-grupo separadamente; 2) utilizar os operadores direcionados propostos por Brasileiro (2005) em conjunto com os tradicionais na proporção de 30% direcionado e 70% tradicional; 3) utilizar o procedimento de descarte de indivíduos que provocam transbordo nos tanques proposto por Brasileiro (2005); 4) utilizar a técnica de *seeding*, gerando uma solução através do calculador de solução viável; e 5) utilizar

seleção por torneio com consideração dos conceitos de viabilidade, de ponto de falha e de severidade da restrição violada.

Com poucos recursos computacionais e tempo limitado, a metodologia descrita acima é capaz de encontrar boas soluções para o problema, e, com o aumento dos recursos computacionais espera-se conseguir resultados próximos aos obtidos nos experimentos sem restrição temporal, ou permitir a aplicação da metodologia em redes com dimensões maiores.

Outras técnicas avaliadas na presente pesquisa, como os operadores definidos por Machado *et al.* (2005), a regra de reparo dos indivíduos que provocam transbordo dos tanques produtores, e o procedimento de seleção utilizando SUS em conjunto com uma função de escalonamento da aptidão, foram excluídas da metodologia recomendada por não terem demonstrado resultados mais eficientes. No entanto, métodos que combinam essas metodologias obtiveram os melhores resultados de eficácia nos experimentos conduzidos na rede piloto simplificada, os quais não puderam ser avaliados na rede piloto devido ao alto tempo computacional requerido para elevar o número de gerações avaliadas.

Uma vez conhecidas as potencialidades dessas técnicas, estudos futuros podem avaliar a viabilidade da sua utilização em conjunto com as utilizadas na metodologia recomendada. Pode-se iniciar, por exemplo, com as técnicas reconhecidamente mais eficientes, e substituir progressivamente, ao longo da evolução, os tipos de operadores direcionados ou o procedimento de descarte pelo reparo dos indivíduos.

A variação dos parâmetros de controle do algoritmo genético foi realizada de forma muito discreta nesse trabalho, mas mesmo assim, propiciou grandes alterações nos resultados, inclusive sendo fundamental em algumas decisões. Dessa forma, recomenda-se um estudo futuro específico para a variação, análise e definição dos melhores parâmetros a serem adotados, ou a viabilidade da utilização de parâmetros de controle variáveis no tempo.

Para escolha da melhor solução para operação das redes entre as múltiplas soluções de compromisso encontradas, foi sugerido nesse trabalho o critério de mínima função ponderada, que escolhe a solução que melhor atende aos pesos fornecidos para cada objetivo, e o critério de mínima variância, que escolhe a solução que apresenta resultados equilibrados para todos os objetivos. No entanto, trabalhos futuros podem ser conduzidos com o intuito de desenvolver uma metodologia mais abrangente para a tomada de decisão, inclusive adotando métodos de análise multi-criterial, os quais permitem utilizar uma visão holística do

problema, considerando além dos critérios técnicos e econômicos, também os critérios ambientais, sociais e políticos nessa escolha.

A possibilidade de representação da variável de forma explícita ao invés da codificação binária, como proposto no trabalho de López-Ibáñez *et al.* (2005), também é uma alternativa a ser avaliada em trabalhos posteriores, o que pode permitir que as bombas do sistema tenham uma programação mais refinada e talvez oferecer ganhos na eficiência.

Embora, de uma maneira geral, os resultados de uma mesma metodologia tenham sido pouco variáveis, especificamente para a métrica de convergência aplicada na rede piloto, o resultado das duas execuções sem restrição temporal da metodologia recomendada mostrou que ambas execuções recomendam um bom número de soluções diferentes para o problema. Esse fato sugere a análise da utilização do paralelismo nas execuções do algoritmo, para que seja possível, ao longo da evolução, migrar essas boas soluções entre execuções diferentes, diversificando as buscas. Mas, em aplicações com restrições temporais, o uso do paralelismo acentua a necessidade de refinamento do modelo hidráulico, de modo que seja possível simular diversas soluções no intervalo de tempo disponível.

Uma última observação interessante sobre os resultados dessa pesquisa é o fato de que, mesmo com um número elevado de gerações, poucos experimentos na rede piloto simplificada conseguiram encontrar 100% da fronteira Pareto definida. Essa deficiência talvez seja resultado da própria concepção do método SPEA2, o qual seleciona indivíduos para reprodução unicamente da população externa. Desse modo, os indivíduos não enviados para a população externa não contribuem com o seu material genético na geração da nova população. Essa contribuição talvez seja relevante devido à dispersão das soluções da fronteira no espaço de busca, e à necessidade de transpor as regiões de inviabilidade para se atingir uma nova solução não-dominada. Sendo assim, uma metodologia de seleção alternativa, que considere na reprodução tanto os indivíduos da população externa quanto os da população corrente, pode vir a ser analisada em um trabalho posterior.

Toda essa pesquisa foi conduzida em um cenário específico, baseado em uma rede real. No entanto, para caracterizar a robustez da metodologia proposta recomenda-se realizar uma análise de sensibilidade utilizando variações no cenário base, tanto na complexidade operacional, quanto na dimensão da rede.

## Referências Bibliográficas

- ALANDER, J. (1992). **On optimal population size of genetic algorithms**. In Proceedings of CompEuro 92, Computer Systems and Software Engineering, 6th Annual European Computer Conference, p. 65 – 70.
- de ALMEIDA, M; HAMACHER, S.; PACHECO, M.; VELLASCO, M. (2001). **The energy minimization method: a multiobjective fitness evaluation technique and its application to the production scheduling in a petroleum refinery**. Proceedings of the Congress on Evolutionary Computation, volume 1, p. 560 – 567.
- ÁVILA, S.; LIMA, C.; CARPES JÚNIOR, W.; VASCONCELOS, J. (2003). **Otimização – Conceitos básicos, ferramentas e aplicações**. Revista de Automação e Tecnologia da Informação, CTAI-SENAI, volume 2, número 1, Florianópolis, p. 70 – 75.
- BAKER, J. (1987). **Reducing bias and inefficiency in the selection algorithm**. In Proceedings of the Second International Conference on Genetic Algorithms, p. 14 – 21. {*apud Lacerda e Carvalho, 1999, p. 133*}
- BARÁN, B.; LÜCKEN, C.; SOTELO, A. (2005). **Multi-objective pump scheduling optimisation using evolutionary strategies**. Advances in Engineering Software volume 36, p. 39 – 47.
- BARCELLOS, J. (2000). **Algoritmos genéticos adaptativos: Um estudo comparativo**. Dissertação (Mestrado em Engenharia) – Escola Politécnica da Universidade de São Paulo, São Paulo, 2000.
- BATYRSHIN, I.; SHEREMETOV, L.; MARKOV, M.; PANOVA, A. (2005). **Hybrid method for porosity classification in carbonate formations**. Journal of Petroleum Science & Engineering, volume 47, p. 35 – 50.
- BEASLEY, D.; BULL, D.; MARTIN, R. (1993). **An overview of genetic algorithm: Part 1, Fundamentals**. University Computing, volume 15, number 2, p. 58 – 69.
- BEASLEY, D.; BULL, D.; MARTIN, R. (1993a). **An overview of genetic algorithm: Part 2, Research Topics**. University Computing, volume 15, number 4, p. 170 – 181.

- BECK, K. (1999). **Extreme Programming explained: embrace change**. Addison-Wesley, 190p.
- BOSCHETTI, F. (1995). **Application of genetic algorithms to the inversion of geophysical data**. PhD thesis in Mathematical Geophysics. University of Western Australia, Perth. *{apud Velez-Langs, 2005, p. 6}*
- BOULOS, P.; WU, Z.; ORR, C.; MOORE, M.; HSIUNG, P.; THOMAS, D. (2001). **Optimal pump operation of water distribution systems using genetic algorithms**. Proceedings of AWWA DSS Conference.
- BUSH, M.; CARTER, J. (1996). Application of a modified genetic algorithm to parameter estimation in the petroleum industry. In DAGLI, C.; AKAY, E.; PHILIP-CHEN, C.; FERNANDEZ, B.; GHOSH, J. (editors), **Intelligent engineering systems through artificial neural networks**. Volume 6, ASME Pres, New York. *{apud Velez-Langs, 2005, p. 5}*
- BRASILEIRO, E. (2005). **Um algoritmo genético para otimização do controle em tempo real de redes de escoamento de petróleo**. Dissertação (Mestrado em Ciência da Computação) – Pós-Graduação em ciência da computação da Universidade Federal de Campina Grande, Campina Grande, fevereiro de 2005.
- BRASILEIRO, F.; GALVÃO, C.; BRASILEIRO, E.; CATAO, B.; SOUTO, C.; MACHADO, E.; MUNIZ, M.; SOUZA, A.; GOMES, A.; ALOISE, D.; OLIVEIRA, A.; GOMES, C.; ROLIM, T.; BOQUIMPANI, C. (2003). **Monitoramento e controle em tempo real de redes de escoamento de petróleo**. In Rio Pipeline Conference & Exposition, Rio de Janeiro, Outubro de 2003.
- CARRIJO, I. (2004). **Extração de regras operacionais ótimas de sistemas de distribuição de água através de algoritmos genéticos multiobjetivo e aprendizado de máquina**. Tese (Doutorado em Hidráulica e Saneamento) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2004.
- CARTER, J. (2002). Introduction to using genetic algorithms. In: NIKRAVESH, M.; AMINZADEH, F.; ZADEH, L. (editors), **Developments in Petroleum Science**. Elsevier Science B. V., p. 51 – 76.

- COELLO, C. (2000). **An updated survey of GA-based multiobjective optimization techniques.** ACM Computing Surveys, volume 32, number 2, p. 110 – 143.
- COELLO, C. (2006). **Evolutionary multi-objective optimization: a historical view of the field.** IEEE Computational Intelligence Magazine, volume 1, number 1, p. 28 – 36.
- COELLO, C.; VELDHUIZEN, D.; LAMONT, G. (2002). **Evolutionary Algorithms for Solving Multi-Objective Problems.** Kluwer academic / Plenum publishers, 576 p.
- CORNE, D.; KNOWLES, J.; OATES, M. (2000). **The Pareto envelope-based selection algorithm for multiobjective optimization.** In Proceedings of the Sixth International Conference on Parallel Problem Solving from Nature VI (PPSN-VI), p. 839 – 848.
- DEB, K. (2000). **An efficient constraint handling method for genetic algorithm.** Computer Methods in Applied Mechanics and Engineering. *{apud Deb, 2001, p. 291}*
- DEB, K. (2001). **Multi-objective optimization using evolutionary algorithms.** John Wiley & Sons, Ltd., Chichester (England), 518 p.
- DEB, K.; PRATAP, A.; AGARWAL, S.; MEYARIVAN, T. (2002). **A fast and elitist multiobjective genetic algorithm: NSGA-II.** IEEE Transactions on Evolutionary Computation. Volume 6, number 2, p. 182 – 197.
- ESHELMAN, L.; CARUANA, R.; SCHAFFER, J. (1989). **Biases in the crossover landscape.** In Proceedings of the Third International Conference on Genetic Algorithms, p. 10 – 19. *{apud Beasley, 1993a, p. 133}*
- EIBEN, A.; HINTERDING, R.; MICHALEWICZ, Z. (1999) **Parameter control in evolutionary algorithm.** IEEE Transactions on Evolutionary Computation, volume 3, number 2, p. 124 – 141.
- FONSECA, C.; FLEMING, P. (1993). **Genetic algorithms for multiobjective optimization: Formulation, discussion, and generalization.** In Proceedings of the Fifth International Conference on Genetic Algorithms, p. 416 – 423.

- GALVÃO, C.; BRASILEIRO, F.; SANTANA, C.; MACHADO, E.; BRASILEIRO, E.; CATAO, B.; GOMES, A.; IZU, A.; LUCENA, K.; ALOISE, D. (2004). **Sistema computacional para o monitoramento e controle em tempo real de redes de escoamento**. In Seminário Hispano-Brasileño sobre Planificación, Proyecto y Operación de Redes de Abastecimiento de Agua, 2004, Valencia (España), junho de 2004.
- GALVÃO, C.; CIRNE FILHO, W.; BRASILEIRO, F.; BRASILEIRO, E.; ARAÚJO, E. (2004a). **Computação em grade aplicada à análise de sistemas de abastecimento de água**. In Seminário Hispano-Brasileiro sobre sistemas de abastecimento urbano de águas, João Pessoa, novembro de 2004.
- GOLDBERG, D. (1989). **Genetic algorithm in search, optimization, and machine learning**. Addison - Wesley Publishing Company, Reading, Massachusetts, 403p.
- GOLDBERG, D. (1985). **Computer-Aided gas pipeline operation using genetic algorithms and rule learning**. University of Alabama, Society of Petroleum Engineers Paper, 1985. *{apud Silva, 1999, p. 21}*
- GOLDBERG, D.; DEB, K. (1991). A comparative analysis of selection schemes used in genetic algorithms. In RAWLINGS, G. (editor) **Foundations of Genetic Algorithms**. Morgan Kaufmann Publishers, San Mateo – Califórnia, p. 69 – 93.
- GOLDBERG, D.; KOZA, J. (1990). **Genetic algorithm in search, optimization and machine learning**. Workshop Notes, Computer Science Department, Stanford University, August 6 – 10. *{ apud Simpson et al., 1994, p. 428}*
- GRENFESTETTE, J. (1986). **Optimization of control parameters for genetic algorithms**. IEEE Transactions on Systems, Man and Cybernetics, volume. 16, number. 1, p. 122–128. *{apud Eiben et al., 1999, p. 125}*
- HAJELA, P.; LIN, C. (1992). **Genetic search strategies in multi-criterion optimal design**. Sstructural Optimization, volume 4, number 2, p. 99 – 107. *{apud Deb, 2001, p. 189}*
- HOLLAND, J. (1975). **Adaptation in natural and artificial systems**. University of Michigan Press, Dept. Computer Science, Ann Arbor, 1975. *{apud Goldberg, 1989, p. 2}*

- HOLLSTIEN, R. (1971). **Artificial genetic adaptation in computer control systems**. Ph.D. Dissertation, University of Michigan, Ann Arbor, 1971. {*apud Goldberg, 1989, p. 99*}
- HORN, J.; NAFPLOITIS, N.; GOLDBERG, D. (1994). **A niched Pareto genetic algorithm for multi-objective optimization**. In Proceedings of the first IEEE Conference on Evolutionary Computation, p. 82 – 87.
- de JONG, K. (1975) **The analysis of the behavior of a class of genetic adaptive systems**. Ph.D. Dissertation, University of Michigan, Dept. Computer Science, Ann Arbor, 1975. {*apud Eiben et al., 1999, p. 125*}
- KNOWLES, J.; CORNE, D. (2000). **Aproximating the non-dominated front using the Pareto archived evolution strategy**. Evolutionary Computation Journal, volume 8, number 2, p. 149 – 172.
- KOIDE, S. (1998). **Equações simplificadas para a utilização da fórmula universal de perda de carga em tubulações**. Engenharia Sanitária e Ambiental, volume 3, número 3, p. 92 – 96.
- KURSAVE, F. (1990). **A variant of evolution strategies for vector optimization**. In Parallel Problem Solving from Nature I (PPSN-I), p. 193 – 197.
- LACERDA, E.; CARVALHO, A. (1999). Introdução aos algoritmos genéticos. In: GALVÃO, C.; VALENÇA, M. (organizadores), **Sistemas inteligentes: Aplicações a recursos hídricos e ciências ambientais**. ABRH, editora UFRGS, Porto Alegre, p. 99 – 150.
- LANSEY, K.; AWUMAH, K. (1994). **Optimal pump operations considering pump switches**. Journal of Water Resources Planning and Management, volume 120, number 1, p. 17 – 35.
- LÓPEZ-IBÁÑEZ, M.; PRASAD, D.; PAECHTER, B. (2005). **Multi-objective pump scheduling optimisation using evolutionary strategies**. In IEEE Congress on Evolutionary Computation, volume 1, p. 435 – 442, Edinburgh, UK, September 2005.

- LÓPEZ-IBÁÑEZ, M.; PRASAD, D.; PAECHTER, B. (2005a). **Optimal pump scheduling: Representation and multiple objectives**. In Proceedings of the Eighth International Conference on Computing and Control for the Water Industry, volume 1, p.117 – 122, University of Exeter, UK, September 2005.
- LÜCKEN, C.; BARÁN, B.; SOTELO, A. (2004). **Pumps scheduling optimization using asynchronous parallel evolutionary algorithms**. CLEI Electronic Journal, volume 7, number 2, paper 2.
- MACHADO, E.; LUCENA, K.; BARBACENA, M.; BRASILEIRO, E.; GALVÃO, C. (2005). **Avaliação da eficácia de um algoritmo genético para escalonamento de bombas em adutoras**. In V SEREA – Seminário Iberoamericano sobre Planificación, Proyecto y Operación de Sistemas de Abastecimiento de Agua. Valencia, 29 de noviembre al 2 de diciembre de 2005.
- MACKLE, G.; SAVIC, D.; WALTERS, G. (1995). **Application of genetic algorithm to pump scheduling for water supply**. GALEZIA'95. Conference Publication 414, p. 400 – 405.
- MACINTYRE, A. (1997). **Bombas e Instalações de Bombeamento**. 2ª edição revista. LTC – Livros Técnicos e Científicos Editora, Rio de Janeiro, 782p.
- MANSANNÉ, F.; SCHOENAUER, M. (2002). **An automatic geophysical inversion procedure using a genetic algorithm**. In: WONG, P.; AMINZADEH, F.; NIKRAVESH, M. (Editors.), **Soft Computing for Reservoir Characterization and Modeling, Studies in Fuzziness and Soft Computing**, volume. 80. Physica-Verlag, p. 331 – 353. *{apud Velez-Langs, 2005, p. 6}*
- MICHALEWICZ, Z.; FOGEL, D. (2002). **How to Solve It: Modern Heuristics**. Springer, Berlim, 460p.
- MICHALEWICZ, Z.; HINTERDING, R.; MICHALEWICZ, M. (1997). Evolutionary Algorithms. In PEDRYCZ, W. (editor), **Fuzzy Evolutionary Computation**. Capítulo 2, Kluwer Academic, 1997
- OLUJIC, Z. (1981). **Compute friction factors fast for flow in pipes**, Chemical Engineering, p. 91 – 93. *{apud Koide, 1988, p. 94}*

- ORMSBEE, L.; LANSEY, K. (1994). **Optimal control of water supply pumping systems.** Journal of Water Resources Planning and Management, volume 120, number 2, p. 237 – 252.
- OSYCZKA, A.; KUNDU, S. (1995). **A new method for solve generalized multicriteria optimization problems using the simple genetic algorithm.** Scstrutural Optimization, volume 10, number 2, p. 94 – 99. *{apud Deb, 2001, p. 253}*
- PACHECO, M. (1999). **Algoritmos genéticos: Princípios e aplicações.** INTERCON99: V Congresso Internacional de Ingeniería Electrónica, Eléctrica y Sistemas, Lima, p. 11 – 16.
- PARETO, V. (1896). **Cours D'Economic Politique.** Volume I and II, F. Rouge. Lausanne, 1896. *{apud Coello, 2000, p. 112}*
- PORTO, R. (2004). **Hidráulica Básica.** 3ª edição revisada, publicação EESC-USP, São Carlos-SP, 519p.
- ROMERO, C.; CARTER, J. (2001). **Using genetic algorithm for reservoir characterisation.** Journal of Petroleum Science and Engineering, volume 31, p. 113 – 123.
- SALGADO, R.; TODINI, E.; O'CONNELL, P. (1988). **Comparison of the Gradient Method with Some Traditional Methods for the Analysis of Water Supply Distribution Networks.** Proceedings of International Conference on Computer Applications for water Supply and Distribution, Leicester Polytechnic, UK, September 1988.
- SCHOTT, J. (1995). **Fault tolerance design using single and multicriteria genetic algorithms.** Master's Thesis, Boston, MA: Department of Aeronautic and Astronautics, Massachusetts Institute of Technology. *{apud Deb, 2001, p. 327}*
- SCHAFFER, J. (1984). **Some experiments in Machine Learning using Vector Evaluated Genetic Algorithms.** Ph.D. Thesis, Nashville, TN: Vanderbilt University. *{apud Deb, 2001, p. 179}*

- SCHAFFER, J.; CARUANA, R.; ESHELMAN, L.; DAS, R. (1989). **A Study of control parameters affecting online performance of genetic algorithms for function optimization.** In Proceedings of the Third International Conference on Genetic Algorithms, p. 51 – 60. *{apud Eiben et al., 1999, p. 132}*
- SCHWAB, M.; SAVIC, D.; WALTERS, G. (1996). **Multi-objective genetic algorithm for pump scheduling in water supply systems.** Technical Report 96/02, Centre for Systems and Control Engineering, School of Engineering, University of Exeter, Exeter, United Kingdom.
- SILVA, A. (1999). **Otimização do transporte em oleodutos utilizando algoritmos genéticos e programação linear.** Dissertação (Mestrado em Engenharia Elétrica) – Faculdade de Engenharia Elétrica e de Computação, Universidade Estadual de Campinas, Campinas, abril de 1999.
- SIMPSON, A.; DANDY, G.; MURPHY, L. (1994). **Genetic algorithm compared to other techniques for pipe optimization.** Journal of Water Resources Planning and Management, volume 120, number 4, p. 423 – 443.
- SOLENG, H. (1999). **Oil reservoir production forecasting with uncertainty estimation using genetic algorithms.** Proceedings of the Congress on Evolutionary Computation, volume 2, p. 1217 – 1223.
- SRINIVAS, N.; DEB, K. (1994). **Multi-objective function optimization using non-dominated sorting genetic algorithms.** Evolutionary Computation Journal, volume 2, number 3, p. 221 – 248.
- SPIEGEL, M. (1977). **Estatística.** Tradução de Pedro Cosentino; ed. rev. por Carlos José Pereira de Lucena. São Paulo, McGraw-Hill do Brasil.
- TODINI, E.; PILATI, S. (1987). **A Gradient Algorithm for the Analysis of Pipe Network.** Computer Applications in Water Supply, Volume 1 - Systems Analysis and Simulation, ed. Bryan Coulbeck and Chun-Hou Orr, Research Studies Press Ltd., Letchworth, Hertfordshire, England.

- TSUTIYA, M. (2001). **Redução do custo de energia elétrica em sistemas de abastecimento de água**. 1ª edição, ABES – Associação Brasileira de Engenharia Sanitária e Ambiental, São Paulo-SP, 185 p.
- TÚPAC, Y.; VELLASCO, M; PACHECO, M. (2002). **Selection of alternatives for oil field development by genetic algorithms**. Rev. Eng. Térm. Spec. Ed. 2, p. 51 – 54. {*apud Velez-Langs, 2005, p. 7*}
- VELDHUIZEN, D. (1999). **Multiobjective evolutionary algorithms: Classifications, Analyses, and new innovations**. Ph.D. Thesis, Faculty of the graduate school of engineering of the air force institute of technology. Technical report no. AFIT/DS/ENG/99-01.
- VELDHUIZEN, D.; ZYDALLIS, J.; LAMONT, G. (2003). **Considerations in engineering parallel multiobjective evolutionary algorithms**. IEEE transactions on evolutionary computation, volume 7, number 2, p. 144 – 173.
- VELEZ-LANGS, O. (2005). **Genetic algorithm in oil industry: An overview**. Journal of Petroleum Science and Engineering, 47 (1-2).
- XIONG, S.; LI, F. (2003). **Parallel strength Pareto multi-objective evolutionary algorithm**. Proceedings of the Fourth International Conference on Parallel and Distributed Computing, Applications and Technologies, p. 681 – 683.
- ZITZLER, E. (2001). **Evolutionary algorithms for multiobjective optimization**. Invited lecture at EUROGEN 2001 conference held in Athens, Greece, September, 2001.
- ZITZLER, E.; THIELE, L. (1998). **An evolutionary algorithm for multiobjective optimization: The Strength Pareto approach**. Technical report 43, Zürich, Switzerland: Computer Engineering and Network Laboratory (TIK), Swiss Federal Institute of Technology (ETH).
- ZITZLER, E.; LAUMANN, M.; THIELE, L. (2001). **SPEA2: Improving the Strength Pareto Evolutionary Algorithm**. Technical report 103, Zürich, Switzerland: Computer Engineering and Network Laboratory (TIK), Swiss Federal Institute of Technology (ETH).

ZITZLER, E.; THIELE, L.; DEB, K. (2000). **Comparison of multiobjective evolutionary algorithms: Empirical results.** Evolutionary Computation. Volume 8, number 2, p. 173 – 195.

ZITZLER, E.; THIELE, L.; LAUMANN, M.; FONSECA, C.; FONSECA, V. (2002). **Performance assessment of multiobjective optimizers: An analysis and review.** Technical report 139, Zürich, Switzerland: Computer Engineering and Network Laboratory (TIK), Swiss Federal Institute of Technology (ETH).