

UNIVERSIDADE FEDERAL DA PARAÍBA  
CENTRO DE CIÊNCIAS E TECNOLOGIA  
COORDENAÇÃO DE PÓS-GRADUAÇÃO EM INFORMÁTICA

Um Algoritmo Genético para Otimização do Controle de  
Redes de Escoamento de Petróleo

*Esther Vilar Brasileiro*

Dissertação de Mestrado submetida à Coordenação do Curso de Pós-Graduação em Ciência da Computação da Universidade Federal de Campina Grande como parte dos requisitos necessários para obtenção do grau de Mestre em Ciência da Computação.

Área de Concentração: Ciência da Computação  
Linha de Pesquisa: Redes de Computadores e Sistemas Distribuídos

*Carlos de Oliveira Galvão, Dr.*  
Orientador

*Francisco V. Brasileiro, Dr.*  
Orientador

**Campina Grande - Paraíba**  
©Esther Vilar Brasileiro, Fevereiro de 2005



# Resumo

O controle em tempo real de redes de tubulações, complexas e de grande escala, para escoamento da produção de petróleo é complicado por vários fatores, entre eles: (a) a confiabilidade dos sistemas de aquisição de dados e comunicação, (b) tempos limites entre a aquisição de dados e a decisão de controle, (c) restrições operacionais de um grande número de dispositivos, (d) controle multi-objetivo, envolvendo objetivos e restrições econômicas, operacionais, ambientais e institucionais. Neste trabalho propomos um Algoritmo Genético (AG) para solucionar o problema do controle em tempo real de redes de escoamento complexas. Centrado no sistema de bombeamento, o algoritmo de otimização exposto utiliza conhecimento especialista do problema para reduzir o tempo de busca e melhorar a qualidade da solução utilizando uma infra-estrutura de grade computacional. Os objetivos do controle são a redução do custo com o consumo de energia e dos riscos ao meio ambiente, mantendo os níveis de produção e segurança. Os operadores genéticos de cruzamento e mutação foram modificados para prevenir convergência prematura e acelerar a busca em regiões mais promissoras do espaço-solução, dando à tradicional ‘cegueira’ dos operadores genéticos a direção para gerar melhores descendentes. A técnica de *seeding* foi utilizada para garantir uma solução viável dentro do prazo. O AG apresenta uma função de adaptabilidade ponderada no tempo. Esta função minimiza as possíveis perdas que se possa ter devido às incertezas presentes na previsão da produção. Os resultados mostram que o AG encontra soluções mais econômicas que os procedimentos *ad hoc* de operação da rede, com uma redução média de 5,45% do custo. Além disso, verificamos que um ganho médio adicional de 16,92% pode ser alcançado com o aumento dos recursos computacionais disponíveis.

# Abstract

Real-time control of complex and large-scale oil pipeline networks is complicated by several reasons, among them (a) reliability of data acquisition and communication systems, (b) strict time limits between data acquisition and decision of control action, (c) operational constraints of a large number of pipeline devices, such as tanks, pumps, valves and pipes, (d) multi-objective control, involving economic, operational, environmental and institutional objectives and constraints. In this work we propose a Genetic Algorithm (GA) to solve the problem of optimizing the control of complex pipeline networks in real time. Centered in the pumping system, the optimization algorithm uses domain based knowledge to reduce the search time and to improve the quality of the solution. The control objectives are reduction of costs with consumption of energy and risks to the environment, at the same time that production and the operational security levels are maintained. Standard GA crossover and mutation operators were modified to prevent early convergence and to speed up search in promising search space areas, giving to the traditional ‘blindness’ of the genetic operators an insight of the best way to apply them in order to generate better descendants. Seeding was used to overcome the problem of delivering a suitable solution on time. The GA introduces an evaluation function weighted over time. This function minimizes the possible loss that one may have due to uncertainty of the production forecast over time. The results showed that the GA provides better solutions than *ad hoc* procedures for pipeline network operation. Our experiments have shown an average reduction on cost of 5,45%. Moreover, we verified that additional gains (16,92% in our experiments) can be achieve increasing the amount of computational resources available.

# Agradecimentos

Aos meus orientadores, Prof. Carlos de Oliveira Galvão e Prof. Francisco Vilar Brasileiro por tudo que aprendi e pela orientação.

Aos meus amigos do laboratório de sistemas distribuídos, em especial a Daniel Paranhos, Lívia, Randolph, Raquel e Zane, pelo apoio, suporte técnico e o bate-papo gostoso durante nossos *breaks* .

À equipe do projeto *SmartPumping*, em especial a Bruno, Cledson, Érica e Mônica, pela modelagem e desenvolvimento do modelo de simulação hidráulico, pelo interesse e disponibilidade em ajudar e pelas preciosas discussões que muito enriqueceram este trabalho.

Aos funcionários do LSD e da COPIN, por todos os serviços prestados.

À minha família e a Andrey, pela paciência nos momentos difíceis.

# Conteúdo

<b>1</b>	<b>INTRODUÇÃO</b>	<b>1</b>
<b>2</b>	<b>FORMALIZAÇÃO DO PROBLEMA</b>	<b>4</b>
2.1	Visão geral do domínio do problema	4
2.2	Objetivo do controle	8
2.3	Simulação do custo da energia	8
2.4	Modelo de simulação hidráulico	13
2.5	Restrições	19
2.6	Estudo de caso	21
<b>3</b>	<b>REVISÃO BIBLIOGRÁFICA</b>	<b>28</b>
<b>4</b>	<b>ALGORITMOS GENÉTICOS</b>	<b>32</b>
4.1	Estrutura do Algoritmo Genético	32
4.2	Codificação da solução	34
4.3	Geração da população inicial	35
4.4	Cálculo da aptidão	36
4.5	Seleção	37
4.6	Operadores de reprodução	40
4.7	Parâmetros de controle do algoritmo	41
4.8	Estratégia de reposição	42
4.9	Critérios de parada	43
4.10	Princípios e funcionamento	44
<b>5</b>	<b>ADAPTANDO O ALGORITMO GENÉTICO</b>	<b>45</b>
5.1	Codificação do problema	45
5.2	Função de aptidão	46
5.3	Tamanho da população	48

<b>5.4</b>	<b>Algoritmo Genético canônico</b>	<b>50</b>
<b>5.5</b>	<b>Tratando as restrições do problema</b>	<b>52</b>
5.5.1	Função de penalidade	52
5.5.2	Eliminação de soluções	54
5.5.3	Operadores genéticos modificados	55
<b>5.6</b>	<b>Garantido resultados dentro do prazo com o seeding</b>	<b>57</b>
<b>5.7</b>	<b>Parâmetros de controle</b>	<b>60</b>
<b>5.8</b>	<b>Testando o AG para diferentes padrões de produção</b>	<b>62</b>
<b>6</b>	<b>CONCLUSÕES E TRABALHOS FUTUROS</b>	<b>70</b>
<b>6.1</b>	<b>Novos objetivos a serem otimizados</b>	<b>71</b>
<b>6.2</b>	<b>Tratamento de inviabilidades</b>	<b>71</b>
<b>6.3</b>	<b>Hibridização</b>	<b>72</b>
	<b>REFERÊNCIAS BIBLIOGRÁFICAS</b>	<b>73</b>

## Lista de Tabelas

TABELA 1 - GRUPOS DE CONSUMO DE ALTA TENSÃO.....	12
TABELA 2 - EXEMPLO DE TARIFA HORO-SAZONAL AZUL .....	13
TABELA 3 - CARACTERÍSTICAS FÍSICAS E DE OPERAÇÃO DOS TANQUES.....	22
TABELA 4 - CARACTERÍSTICAS FÍSICAS DOS DUTOS .....	23
TABELA 5 - LIMITES DE OPERAÇÃO DOS DUTOS.....	23
TABELA 6 - CARACTERÍSTICAS FÍSICAS DAS BOMBAS.....	23
TABELA 7 - QUADRO DE TARIFAS ELÉTRICAS .....	24
TABELA 8 - CONDIÇÕES INICIAIS DO SISTEMA .....	25
TABELA 9 - CARACTERÍSTICA DO FLUIDO NAS ESTAÇÕES.....	25
TABELA 10 - PREVISÃO DE ENTRADA (DA PRODUÇÃO) E SAÍDA DAS ESTAÇÕES.....	26
TABELA 11 - VISCOSIDADE CINEMÁTICA DO FLUIDO .....	26
TABELA 12 - BSW DO FLUIDO.....	26
TABELA 13 - TEMPERATURA DO FLUIDO .....	26
TABELA 14 - MASSA ESPECÍFICA DO FLUIDO .....	27
TABELA 15 - DADOS DE APTIDÃO DE UM PROBLEMA HIPOTÉTICO .....	39
TABELA 16- PARÂMETROS DE CONTROLE .....	51
TABELA 17 - RESTRIÇÕES E GRAU DE SEVERIDADE .....	53
TABELA 18 - ESTRATÉGIA PARA REPARO DE SOLUÇÃO.....	59
TABELA 19 - PARÂMETROS DE CONTROLE.....	61
TABELA 20 - CARACTERÍSTICAS DA PRODUÇÃO .....	62
TABELA 21 - RESULTADOS DA OTIMIZAÇÃO.....	66



# Lista de Figuras

FIGURA 1 – ESQUEMA PARCIAL DA REDE DE ESCOAMENTO DA UN-RNCE	4
FIGURA 2 – ESQUEMA DE REDE DE ESCOAMENTO	5
FIGURA 3 - VAZÃO ESTIMADA INICIAL PARA AS BOMBAS CENTRÍFUGAS E VOLUMÉTRICAS	15
FIGURA 4 - VAZÃO ESTIMADA INICIAL PARA AS BOMBAS ALTERNATIVAS	15
FIGURA 5 - GRÁFICO DO VALOR DA COMPUTAÇÃO VERSUS TEMPO	21
FIGURA 6 - ESQUEMA DA MALHA DE ESCOAMENTO DE TESTES	22
FIGURA 7 - ESTRUTURA DE UM ALGORITMO GENÉTICO	33
FIGURA 8 - CODIFICAÇÃO DOS CROMOSSOMOS	35
FIGURA 9 - REPARO DE UM CROMOSSOMO	36
FIGURA 10 - AMOSTRAGEM ESTOCÁSTICA UNIVERSAL	40
FIGURA 11 - CRUZAMENTO DE CROMOSSOMOS EM UM E DOIS PONTOS	40
FIGURA 12 - OPERADOR DE MUTAÇÃO	41
FIGURA 13 - REPRESENTAÇÃO DE UM CROMOSSOMO	46
FIGURA 14 - DETERMINANDO O TAMANHO DA POPULAÇÃO	49
FIGURA 15 - CRUZAMENTO DIRECIONADO	56
FIGURA 16 - ALGORITMO DO CALCULADOR DE SOLUÇÃO VIÁVEL	58
FIGURA 17 - ALGORITMO DE OPERAÇÃO DA REDE DE ESCOAMENTO	64
FIGURA 18 - DESEMPENHO NO CENÁRIO I DE PRODUÇÃO	67
FIGURA 19 - DESEMPENHO NO CENÁRIO II DE PRODUÇÃO	68
FIGURA 20 - DESEMPENHO NO CENÁRIO III DE PRODUÇÃO	68

# 1 Introdução

A Unidade de Negócios Rio Grande do Norte - Ceará (UN-RNCE) da PETROBRAS, que explora os campos de petróleo da região compreendida entre os estados do Rio Grande do Norte e Ceará, opera atualmente uma rede de dutos de 350km, que se estende por toda a região oeste até o litoral norte do estado do Rio Grande do Norte e compreende 95 campos de produção, onde se encontram mais de 4.500 poços perfurados e 67 estações coletoras. É a maior produção de petróleo *onshore* do Brasil e o bombeamento desta produção consome bastante energia elétrica.

A busca da redução do consumo de energia em sistemas de escoamento de petróleo é importante e uma forma natural de se tornar mais competitiva e racional a produção de petróleo *onshore* para as empresas da área que competem em escala global.

Sem fazer alterações nos equipamentos ou na topologia da rede - alterações de engenharia, uma forma de conseguir reduções do custo do bombeamento da produção é otimizando a operação das bombas.

Atualmente, a operação das bombas responsáveis pelo escoamento da produção é feita de forma descentralizada, baseada em procedimentos *ad hoc*, apoiados em sistemas que monitoram parte dos dispositivos da rede. A complexidade inerente ao sistema, a descentralização do controle, e a visão limitada dos operadores em relação à malha global de escoamento impedem a otimização do processo.

Neste contexto, o trabalho aqui apresentado tem como objetivo prover uma solução otimizada que garanta a máxima eficiência de movimentação da produção, e a redução dos gastos com energia elétrica atendendo aos objetivos financeiros, operacionais, ambientais e institucionais.

O controle de redes de tubulações, complexas e de grande escala, para escoamento da produção de petróleo é complicado por vários fatores, entre eles: (a) a confiabilidade dos sistemas de aquisição de dados e comunicação, (b) tempos limites entre a aquisição de dados e a decisão de controle, (c) restrições operacionais de um grande número de dispositivos, (d) controle multi-objetivo, envolvendo metas e restrições econômicas, operacionais, ambientais e institucionais.

Os aspectos apontados acima se tornam ainda mais críticos à medida que o número de dispositivos aumenta, já que cada um destes dispositivos possui suas próprias espe-

cificações de uso e restrições operacionais. Além disso, o grande número de restrições, tanto do ponto de vista operacional dos equipamentos, como níveis mínimos e máximos de óleo nos tanques, pressão nos dutos e bombas, quanto dos aspectos de segurança operacional e econômico, e, as incertezas presentes no sistema advindas da variação do padrão de produção dos poços, se tornam especialmente críticos à medida que a capacidade máxima de operação do sistema vai se aproximando.

Muitos dos métodos matemáticos que têm sido utilizados para otimização da programação de operação -escalonamento- de bombas sofrem ao lidar com redes com um número elevado de combinações diferentes de bombas e/ou de estações coletoras, com a quantidade de cálculos crescendo tão rapidamente que a demanda por recursos computacionais se torna inaceitável e as restrições temporais difíceis de serem atendidas [28].

A otimização de sistemas de bombeamento tem sido bastante estudada, em especial em sistemas de redes de abastecimento de água [35][41][28][26][37]. As características das redes de escoamento dos fluidos de petróleo, com um número maior de bombas e um fluido que exige que processos de mistura de óleos e decantação sejam modelados, aumentam a complexidade do sistema que se está querendo otimizar. Uma grande variedade de técnicas pode ser utilizada para a resolução deste tipo de problema de elevada complexidade, variando desde métodos de programação matemática, aos sistemas baseados em regras, e aos sistemas baseados em meta-heurísticas, em que se encontram os Algoritmos Genéticos, colônias de formigas entre outros. Esses métodos podem ainda ser utilizados de forma combinada para atacar diferentes aspectos do problema.

Neste trabalho apresentamos uma solução baseada em Algoritmo Genético para otimização do escalonamento das bombas em uma rede de escoamento da produção de petróleo. O Algoritmo Genético tem uma função objetivo ponderada no tempo, operadores de reprodução modificados e pode ser executado em paralelo em uma grade computacional. O algoritmo trata as questões referentes à restrição temporal do problema e às incertezas advindas das mudanças no cenário de produção dos campos de exploração. Questões relativas à confiabilidade dos sistemas de aquisição de dados não são tratadas neste estudo.

O trabalho está estruturado em sete capítulos. No Capítulo 2 expomos detalhadamente o problema, apresentando as características dos sistemas tratados, juntamente com os dados da área piloto utilizada para validação da solução, o modelo matemático da si-

mulação hidráulica e as características do modelo tarifário ao qual o sistema está submetido.

No Capítulo 3 apresentamos as pesquisas na área de otimização da operação de redes de escoamento tanto de óleo quanto de água, e as diversas técnicas utilizadas para resolução de problemas semelhantes. Concluimos este capítulo com uma justificativa para a utilização de Algoritmos Genéticos na solução proposta.

O Capítulo 4 introduz o método de otimização escolhido, os fundamentos do seu funcionamento, suas aplicações e o detalhamento das suas estruturas. No Capítulo 5 apresentamos a solução proposta e a avaliação desta solução em vários cenários, comparando-a com os procedimentos em uso atualmente. Por fim, o Capítulo 6 apresenta as conclusões e as direções futuras de desenvolvimento desta linha de pesquisa.

## 2 Formalização do problema

### 2.1 Visão geral do domínio do problema

Um campo de extração de petróleo é composto por poços e uma rede de dutos, a qual conecta esses poços a estações coletoras, e estas a uma estação de tratamento. O óleo extraído é armazenado em tanques nas estações coletoras e destes tanques é bombeado através da rede de dutos até a estação de tratamento. A operação adequada da rede requer uma programação do bombeamento de maneira a reduzir o gasto com energia elétrica no bombeamento da produção. Uma configuração de rede típica pode ser observada na Figura 1.

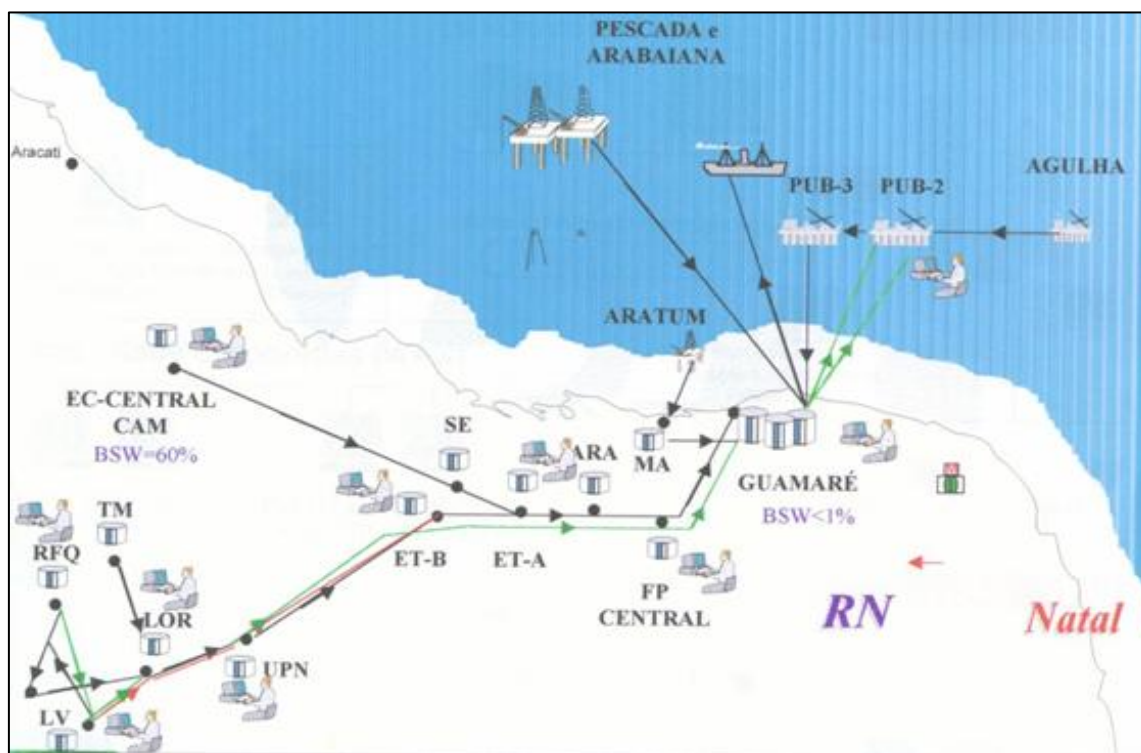
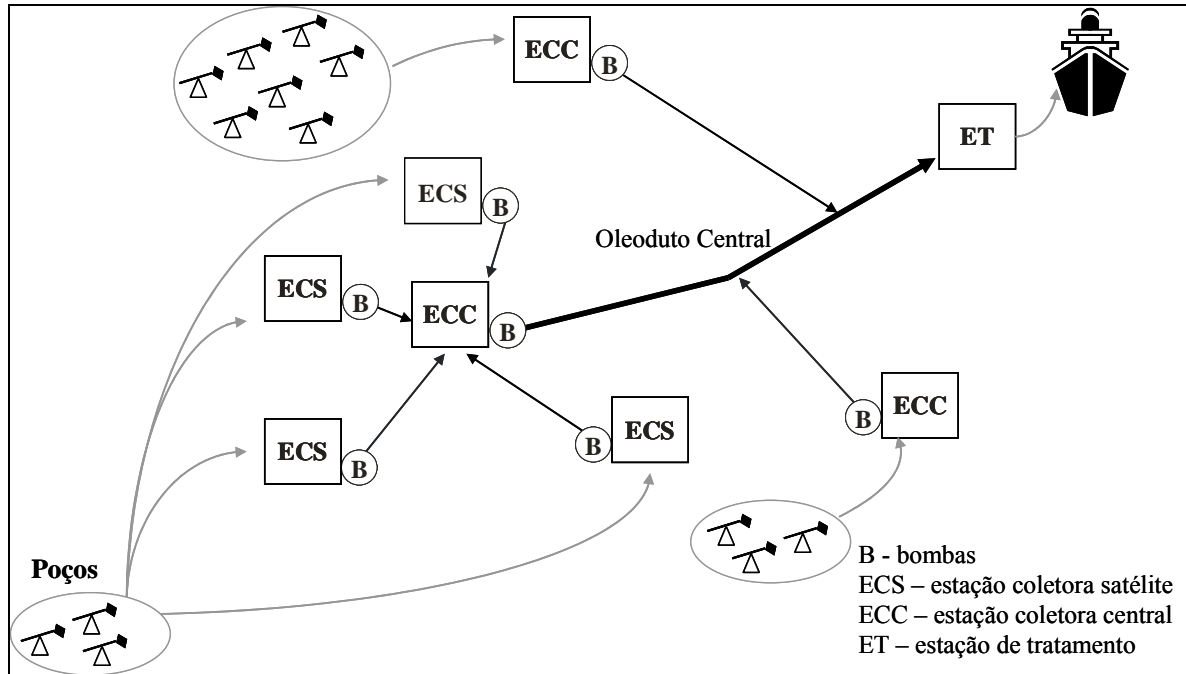


Figura 1 – Esquema parcial da rede de escoamento da UN-RNCE<sup>1</sup>

A produção bruta dos poços escoar para estações coletoras satélites e daí para estações coletoras centrais. O gás produzido cujo aproveitamento não é econômico, face à baixa razão gás/óleo (RGO) é queimado nas estações satélites. Nas estações coletoras centrais, parte da água produzida é separada e tratada. O restante, juntamente com o óleo, é enviado para a estação final de tratamento de óleo e efluentes (ETO). Após o tratamen-

<sup>1</sup> Fonte: Arquivos de imagens da UN-RNCE

to, o óleo segue para as refinarias transportado em navios petroleiros. A água separada na estação de tratamento é tratada para descarte no mar de acordo com os índices e parâmetros permitidos pela legislação ambiental.



**Figura 2 – Esquema de rede de escoamento**

Atualmente, o controle da operação das bombas da malha de escoamento da Unidade de Negócios do Rio Grande do Norte e Ceará (UN-RNCE) da PETROBRAS (Figura 1) é feito de forma descentralizada e independente, baseado em regras simples de operação, auxiliado por equipamentos de segurança, como sensores de níveis e pressostatos. Cada ativo da rede, uma unidade administrativa independente, composta de uma estação coletora central e suas estações coletoras satélites, é controlada por um operador, que, obedecendo a essas regras de operação, determina quando ligar e desligar cada bomba da estação. Dessa forma, o operador possui uma visão limitada, restrita ao ativo sob sua responsabilidade e ao oleoduto central compartilhado, não possuindo informações sobre as demais unidades administrativas da rede, o que normalmente não garante um escoamento ótimo de toda a produção. Do ponto de vista do operador, a operação ótima do seu ativo é aquela em que a maior quantidade de petróleo é escoada, respeitando as restrições operacionais e os requisitos de segurança da rede. As questões relativas ao custo da operação da rede advindo do consumo de energia elétrica são secundárias,

visto que, a avaliação do desempenho de cada unidade administrativa é baseada no volume de fluido bombeado para a estação final de tratamento.

Determinar o escalonamento (quando ligar ou desligar cada bomba) das bombas para certo período no futuro (*horizonte de operação*), sob dados modelo de simulação hidráulica da rede, previsão de produção e esquema tarifário de energia elétrica, objetivando a máxima segurança operacional e o mínimo custo global, respeitando as restrições operacionais dos elementos da rede e sem reduzir as metas de produção de petróleo é um problema de otimização complexo.

O sistema que estamos modelando (Figura 2) está compreendido entre as estações coletoras, que armazenam a produção vinda dos poços nos tanques produtores, e a estação de tratamento, formada por um conjunto de tanques receptores. Todos os elementos fora desse sistema, incluindo os campos de exploração e os poços, e o bombeio até as estações coletoras não estão sendo modelados.

O horizonte de operação define o período de tempo para o qual a otimização será realizada. Por exemplo, um horizonte de operação de 12 horas indica que o otimizador deverá calcular um escalonamento para as bombas da malha fornecida para um período de 12 horas, a partir do horário inicial estipulado. Um horizonte de operação típico é de 24 horas, pois inclui todos os ciclos de tarifação de energia elétrica.

O intervalo de atuação é um divisor do horizonte de operação e discretiza o período de tempo do horizonte de operação, de maneira que a sugestão de escalonamento obedeça a esses intervalos ao sugerir mudanças no estado das bombas. A granularidade do intervalo de atuação não deve ser muito pequena sob pena de acarretar um desgaste nas bombas e diminuir a sua vida útil, nem tampouco pode ser muito grande, por reduzir as possibilidades de otimização [42].

Na entrada de toda estação coletora satélite ou central, o fluido que está sendo produzido e bombeado para ser armazenado nos tanques destas estações deve ser caracterizado por uma previsão da produção de fluidos, que neste trabalho utiliza cenários hipotéticos. A previsão da produção informa a temperatura, a viscosidade e a vazão de entrada do fluido nas diversas estações para o horizonte de operação. Como não se pode garantir que a previsão da produção, baseada em dados históricos da produção, se confirmará tal como foi prevista, e grandes variações no padrão de produção podem inviabilizar parte ou toda a aplicação de uma programação de escalonamento bombas sugerida pelo otimizador, é importante que o otimizador privilegie estratégias de soluções segundo as

quais a maior parte da produção é bombeada não só fora do horário de pico, como também nos primeiros intervalos de operação, onde são maiores as chances da previsão da produção se concretizar como previsto. O escoamento da produção armazenada nas estações nos primeiros intervalos de otimização minimizam as possíveis perdas que uma unidade administrativa possa ter devido a mudanças no cenário futuro de produção, que inviabilizem o escoamento da sua produção, programado para um momento no futuro.

A estratégia de otimização buscará uma solução econômica, mantendo a produção bombeada dos poços. A otimização se dá em sistemas sob qualquer esquema tarifário e os diversos ativos da rede podem constituir diferentes unidades consumidoras, e estar submetidos a diferentes contratos entre os fornecedores de energia elétrica ou mesmo utilizar fontes de energia de geração própria. A redução dos gastos com energia é alcançada evitando-se a operação das bombas nos períodos de tarifas mais cara. O período de ponta é definido pela Concessionária, de acordo com as características do sistema elétrico, e geralmente está situado no intervalo compreendido diariamente, entre 17h e 22h, exceto sábados e domingos e feriados nacionais ou outros feriados definidos por Lei Federal [29]. Outro aspecto que deve ser observado é o acionamento simultâneo de várias bombas, que deve ser evitado para que o pico gerado não ultrapasse os valores de demanda contratados.

A solução para o escalonamento das bombas deve obedecer a todas as restrições de pressões e vazões dos dutos, capacidade de armazenamento dos tanques e operacionais das bombas, válvulas e demais dispositivos do sistema, garantindo a segurança da operação. Uma solução só será considerada válida se, para o horizonte de operação especificado, não ocorrer nenhuma violação das restrições do problema para o conjunto de intervalos de atuação. A violação de uma restrição operacional do problema equivale a um *alarme* no sistema de escoamento real. Dizemos de uma solução que gera um *alarme falha* para o intervalo da ocorrência do alarme.

Além disso, o otimizador deve ser capaz de atender às restrições temporais do problema, que estipula um tempo máximo para o otimizador fornecer uma solução de escalonamento para o problema, dada pelo período entre dois intervalos de atuação.



## 2.2 Objetivo do controle

O problema do escalonamento das bombas é formulado como um problema de otimização de custos. Existem diferentes componentes do custo da produção, mas um dos mais relevantes é o custo da energia. O modelo matemático do problema tratado tem como objetivo a minimização do custo da energia por volume de fluido bombeado para os tanques receptores da rede, na estação de tratamento (Equação 1).

$$fo = \frac{CustoTS}{V_{entregue}} \quad (1)$$

Em que:  $fo$  é a função que se deseja minimizar [R\$/m<sup>3</sup>];

$CustoTS$  é o custo total de demanda e energia consumida durante todo o período da simulação [R\$];

$V_{entregue}$  é o volume total entregue à estação final de tratamento durante todo o período da simulação [m<sup>3</sup>];

O volume total entregue é dado pela seguinte equação:

$$V_{entregue} = t \cdot \sum_{i=1}^n Qd_i \quad (2)$$

Em que:  $t$  é o tempo correspondente a um intervalo da simulação [s];

$i$  é o índice do intervalo da simulação [adimensional];

$\sum_{i=1}^n$  corresponde ao somatório de todos os intervalos da simulação;

$Qd_i$  é a vazão no duto conectado a estação de tratamento para cada intervalo da simulação [m<sup>3</sup>/s];

## 2.3 Simulação do custo da energia

O custo de energia é formado tanto pelo custo da energia consumida pela operação das bombas, o custo do regime permanente, como pelo custo da energia no momento de acionamento da bomba, custo do regime transitório. Por questões de simplificação, neste trabalho, o custo do regime transitório foi desconsiderado no cálculo do custo com

energia elétrica para uma dada solução de escalonamento das bombas. Não encontramos na literatura a quantificação deste custo em comparação ao custo considerado do regime permanente, mas esta perde a relevância quando um dispositivo opera por um período longo, e o número de acionamentos é portanto reduzido. O custo total ( $CustoTS$ ) de um cenário de simulação é portanto obtido pela seguinte equação:

$$CustoTS = CustoET + CustoDT \quad (3)$$

Em que:  $CustoET$  é o custo total da energia consumida referente a todo o período da simulação [R\$];

$CustoDT$  é o custo total da demanda, dado pelo pico de potência durante o período da simulação [R\$];

Conforme a Equação (3), o custo de energia é o somatório do custo da energia consumida pelas bombas e do custo da demanda. O custo da energia consumida ( $CustoET$ ) é dada por:

$$CustoET = \sum_{UC=1}^n \left( \sum_{i=1}^n (Ce_i^{UC} \cdot tarifaE_i^{UC}) \right) \quad (4)$$

Em que:  $\sum_{UC=1}^n$  corresponde ao somatório de todas as unidades consumidoras;

$\sum_{b=1}^n$  corresponde ao somatório de todas as bombas de uma unidade consumidora;

$Ce_i^{UC}$  é o consumo de energia verificado na unidade consumidora  $UC$ , para cada intervalo da simulação [MWh];

$tarifaE_i^{UC}$  é o preço aplicado ao consumo de energia para cada intervalo da simulação, determinado no contrato feito entre a unidade consumidora  $UC$  e a concessionária [R\$/MWh];

$$Ce_i^{UC} = Dp_i^{UC} \cdot t_h \quad (5)$$

Em que:  $Dp_i^{UC}$  é o somatório das potências de todas as bombas da unidade consumidora  $UC$ , para cada intervalo da simulação [MW];

$t_h$  é o intervalo de tempo correspondente a um intervalo da simulação [h];

A potência de uma bomba  $P_i$ , para um intervalo da simulação  $i$  é dada por [36]:

$$P_i = \frac{\rho_{\text{fluido}_i} \cdot g \cdot Hman_i \cdot Qb_i}{\eta_m \cdot \eta_i} \quad (6)$$

Em que:  $\rho_{\text{fluido}_i}$  é a massa específica do fluido bombeado, para cada intervalo da simulação [ $\text{Kg/m}^3$ ];

$g$  é a aceleração da gravidade [ $\text{m/s}^2$ ];

$Hman_i$  é a altura manométrica da bomba, para cada intervalo da simulação [ $\text{mcf}$ ]<sup>2</sup>;

$Qb_i$  é a vazão que passa pela bomba, para cada intervalo da simulação [ $\text{m}^3/\text{s}$ ];

$\eta_m$  é o rendimento do motor [%];

$\eta_i$  é o rendimento da bomba, para cada intervalo da simulação [%];

A demanda é a potência média durante qualquer intervalo de tempo, medido por um aparelho integrador. Para o faturamento de energia pela concessionária são utilizados intervalos de integração de 15 minutos. Em um mês, ocorrem quase 3000 intervalos de quinze minutos. Assim, a demanda será medida quase 3000 vezes no mês, e seu custo é calculado pelo pico verificado num período de 30 dias, ainda que este tenha sido verificado apenas uma única vez. Nos cálculos feitos para determinar o custo de uma solução proposta, com horizonte de operação inferior a 30 dias, consideramos o valor do pico observado durante o horizonte de operação que está sendo otimizado, e o custo da demanda é uma proporção da demanda contratada estabelecida no contrato de fornecimento. Tomando como exemplo um horizonte de operação de 24h, o valor referente ao custo da demanda equivale a 1/30 do valor estipulado para aquela faixa de demanda, conforme contrato que estabelece as tarifas elétricas.

Caso o valor da demanda contratada seja excedido, a parcela da demanda que excede o contratado será cobrada pelo valor especificado nas tarifas de ultrapassagem. A tarifa de ultrapassagem é superior à tarifa normal porque o sistema funciona em condições ótimas quando as demandas são bem definidas e estimadas com antecedência (a partir da demanda contratada). Quando o cliente ultrapassa sua demanda, sobrecarrega o

---

<sup>2</sup> mcf é a unidade métrica metro coluna de fluido.

sistema, o que implica em redução da qualidade do fornecimento (com mais picos e oscilações) e mais perdas de energia elétrica. O custo da demanda ( $custoDT$ ) é dado por:

$$CustoDT = \frac{dS}{dmês} \cdot \sum_{UC=1}^n CustoDM^{UC} \quad (7)$$

Em que:  $dS$  é a duração da simulação [s];

$dmês$  é a duração do período “entre fechamento de faturas” da unidade consumidora  $UC$  [s];

$CustoDM^{UC}$  é o custo total da demanda verificado para o período entre “fechamento de faturas”, para cada unidade consumidora  $UC$  [R\$];

$$CustoDM^{UC} = custodp^{UC} + custodfp^{UC} \quad (8)$$

Em que:  $custodp^{UC}$  é o custo da demanda correspondente aos períodos de ponta verificados entre “fechamento de faturas”, para cada unidade consumidora  $UC$  [R\$];

$custodfp^{UC}$  é o custo da demanda correspondente aos períodos fora de ponta verificados entre “fechamento de faturas”, para cada unidade consumidora  $UC$  [R\$];

$$custodp = f(Dp_i, data, hora, Dpc^{UC}, tarifaD^{UC}) \quad (9)$$

$$custodfp = f(Dp_i, data, hora, Dpf^{UC}, tarifaD^{UC}) \quad (10)$$

Em que:  $f(Dp_i, data, hora, Dpc^{UC}, tarifaD^{UC})$  e  $f(Dp_i, data, hora, Dpf^{UC}, tarifaD^{UC})$  correspondem ao custo da demanda para uma unidade consumidora, que é função das demandas medidas ( $Dp_i$ ), da data e das horas transcorridas durante a simulação, da demanda contratada para a ponta ( $Dpc^{UC}$ ) e fora de ponta ( $Dpf^{UC}$ ), e das características da tarifação ( $tarifaD^{UC}$ ), conforme o contrato feito com a concessionária [R\$];

Nos contratos das concessionárias, os consumidores são classificados pelo nível de tensão em que são atendidos (Tabela 1). Os consumidores atendidos em alta tensão, acima de 2,3 KV, como indústrias, *shopping centers* e alguns edifícios comerciais, são classificados no Grupo A.

**Tabela 1 - Grupos de consumo de alta tensão**

<b>Subgrupos</b>	<b>Tensão de Fornecimento</b>
A1	≥ 203 KV
A2	88 KV a 138 KV
A3	69 KV
A3a	30 KV a 44 KV
A4	2,3 KV a 25 KV
AS	Subterrâneo

Os consumidores do Grupo A têm tarifa binômia, isto é, são cobrados tanto pela demanda quanto pela energia que consomem. Estes consumidores podem ser enquadrados em uma de três categorias tarifárias: tarifação convencional, tarifação horo-sazonal verde ou tarifação horo-sazonal azul. As tarifas horo-sazonais são caracterizadas 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 dos períodos do ano.

Os contratos entre a PETROBRAS e as concessionárias recaem nos subgrupos A3 e A4, e são do tipo horo-sazonal azul. A tarifação horo-sazonal azul apresenta tarifas diferenciadas de acordo com o horário do dia (na ponta e fora de ponta) e com a época do ano (período seco e período úmido) (Tabela 2). Em relação à demanda, apresenta tarifas baseadas apenas no horário do dia (ponta e fora de ponta). O custo da energia elétrica na tarifação horo-sazonal azul será o somatório dos custos devido à demanda na ponta (mais porcentagem da ultrapassagem), à demanda fora de ponta (mais porcentagem da ultrapassagem), ao consumo na ponta (período seco ou úmido) e ao consumo fora de ponta (período seco ou úmido).

**Tabela 2 - Exemplo de tarifa horo-sazonal azul<sup>3</sup>**

<b>Horo-sazonal azul</b>			
Demanda (R\$/KWh)			
Normal		Ultrapassagem	
Ponta	Fora de ponta	Ponta	Fora de ponta
28,39	9,43	85,22	28,39
Consumo (R\$/MWh)			
Ponta		Fora de ponta	
Seco	Úmido	Seco	Úmido
186,33	172,40	88,58	78,28

## 2.4 Modelo de simulação hidráulico

O que se deseja na simulação é a obtenção do equilíbrio hidráulico da rede, ou seja, encontrar o ponto de funcionamento do sistema em termos de suas variáveis de estado: vazão e pressão.

Para equilibrar a rede (Equação (13)) são encontradas: as vazões (Equação (11)), pressões nos dutos e alturas manométricas das bombas (Equação (12)), para uma dada configuração em um determinado instante. Para tanto, arbitra-se, inicialmente, o ponto de trabalho de cada bomba, calcula-se o comportamento da rede (vazões, perdas de carga, pressões, etc.) e verifica-se o atendimento ao equilíbrio hidráulico (critério de parada). Se esse não for atendido, realizam-se novos cálculos iterativamente,  $k$  vezes, partindo-se das novas vazões encontradas, até que o critério de parada (Equação (13)) seja atingido.

$$Qb_{estim_i} = Qb_{estim_k} \quad (11)$$

$$H_{man_i} = H_{man_k} \quad (12)$$

$$\frac{\sum_{b=1}^n (Qb_{calc_k} - Qb_{estim_k})}{n} \leq 10^{-6} \quad (13)$$

<sup>3</sup> subgrupo A4 – fonte: [www.lightempresas.com.br](http://www.lightempresas.com.br)

Em que:  $Qb_{estim_i}$  é a vazão adotada para a bomba a fim de que o equilíbrio seja verificado, para o intervalo  $i$  da verificação [ $m^3/s$ ];

$Qb_{estim_k}$  é a vazão adotada para a bomba a fim de que o equilíbrio seja verificado, para o intervalo  $k$  da verificação [ $m^3/s$ ];

$Qb_{calc_k}$  é a vazão encontrada a partir dos valores de pressões calculados para a vazão estimada ( $Qb_{estim_k}$ ) aplicada ao sistema, para o intervalo  $k$  da verificação [ $m^3/s$ ];

$n$  é o número total de bombas;

$Hman_i$  é a altura manométrica da bomba para o intervalo  $i$  da verificação [mcf];


$Hman_k$  é a altura manométrica da bomba para cada intervalo  $k$  da verificação [mcf];

Para equilibrar a rede, estima-se, para cada bomba, uma vazão inicial (Equação (14)). Convencionou-se que, para as bombas centrífugas, a vazão estimada inicial é igual à metade da vazão resultante da resolução da equação de sua respectiva curva característica obtida para altura manométrica igual a zero. Segundo Driedger [9], a curva característica das bombas volumétricas é basicamente retilínea, logo, para essas bombas, toma-se como vazão estimada inicial a vazão resultante da resolução da equação da sua curva característica para altura manométrica igual a zero ( Figuras 3 e 4).


$$Qb_{estim_k} = Qb_{ini_k}, \text{ para } k = 1 \tag{14}$$

Em que:  $Qb_{ini_k}$  é a vazão inicial estimada para a bomba [ $m^3/s$ ].

Apesar de produzirem fluxo pulsante, as bombas alternativas, com vários êmbolos (duplex, triplex ou multiplex) e/ou com duplo efeito, descarregam uma vazão aproximadamente constante ao longo do tempo, recaindo no gráfico das bombas volumétricas da Figura 4.



**Figura 3 - Vazão estimada inicial para as bombas centrífugas e volumétricas**



**Figura 4 - Vazão estimada inicial para as bombas alternativas**

Uma vez adotadas as vazões iniciais para as bombas, determinam-se as vazões estimadas em cada duto da rede até a estação de tratamento; quando houver dutos em paralelo, a vazão é inicialmente dividida pelo número de dutos e depois é redistribuída (Equações (15) e (16)).

A vazão do duto  $x$ , quando o duto está conectado a uma bomba é dada por:

$$Qx_i = Qb_{estim_i} \quad (15)$$

Em que:  $Qx_i$  é a vazão do duto  $x$ , para cada intervalo  $i$  da simulação [ $m^3/s$ ];

$Qb_{estim_i}$  é a vazão da bomba, para cada intervalo  $i$  da simulação [ $m^3/s$ ];

A vazão do duto  $x$ , quando o duto não está conectado a uma bomba é dado pelo somatório das vazões dos dutos conectados a sua montante:

$$Qx_i = \sum_{d=1}^n Qd_i \quad (16)$$

Em que:  $Qx_i$  é a vazão do duto  $x$ , para cada intervalo  $i$  da simulação [ $m^3/s$ ];

$Qd_i$  é a vazão do duto, o qual está a montante do duto  $x$ , para cada intervalo da simulação [ $m^3/s$ ];

$\sum_{d=1}^n$  corresponde ao somatório dos dutos.



De posse das vazões estimadas para cada duto, calculam-se as perdas de carga nos dutos a partir da seguinte equação:

$$\Delta h_i = f_i \cdot \frac{L}{d} \cdot \frac{v_i^2}{2 \cdot g} \quad (17)$$

Em que:  $\Delta h_i$  é a perda de carga no duto, para cada intervalo da simulação [mcf];

$f_i$  é o fator de atrito no duto, para cada intervalo da simulação [adimensional];

$L$  é o comprimento do duto [m];

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

$v_i$  é a velocidade do fluido no duto, para cada intervalo da simulação [m/s];

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

$$f_i = \begin{cases} \frac{64}{Rey_i}, \text{ se } Rey_i < 2300 \\ \left[ -2 \cdot \log_{10} \left[ \frac{\varepsilon}{3,7 \cdot d} - \frac{5,02}{Rey_i} \cdot \log_{10} \left( \frac{\varepsilon}{3,7 \cdot d} + \frac{14,5}{Rey_i} \right) \right] \right]^{-2}, \text{ se } Rey_i \geq 2300 \end{cases} \quad (18)$$

Em que:  $Rey_i$  é o número de Reynolds, para cada intervalo da simulação [adimensional];

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

A Equação (18) está sendo utilizada em substituição à fórmula de Colebrook-White [34], por evitar cálculos iterativos.

$$Rey_i = \frac{4 \cdot Q_i}{v_i \cdot \pi \cdot d} \quad (19)$$

Em que:  $Q_i$  é a vazão no duto, para cada intervalo  $i$  da simulação [m<sup>3</sup>/s];

$v_i$  é a viscosidade cinemática do fluido no duto, para cada intervalo  $i$  da simulação [m<sup>2</sup>/s].

$$Q_i = A \cdot v_i \quad (20)$$

Em que:  $v_i$  é a velocidade do fluido no duto, para cada intervalo  $i$  da simulação [m/s];

$A$  é a área de seção transversal do duto [ $m^2$ ];

Calcula-se a pressão a montante e a jusante de todos os dutos, seqüencialmente, utilizando as seguintes equações:

$$pmx_i = \begin{cases} N_i, & \text{se duto } x \text{ está conectado a um tanque} \\ Z_j + pjx_i + \Delta h_i - cm, & \text{caso contrário} \end{cases} \quad (21)$$

$$pjx_i = \begin{cases} N_i, & \text{se duto } x \text{ está conectado a um tanque} \\ cm + pmx_i - \Delta h_i - Z_j, & \text{caso contrário} \end{cases} \quad (22)$$

Em que:  $pmx_i$  é a pressão a montante do duto  $x$ , para cada intervalo da simulação [mcf];

$N_i$  é o nível do tanque para cada intervalo da simulação [m];

$pjx_i$  é a pressão a jusante do duto  $x$ , para cada intervalo da simulação [mcf];

$Z_j, Z_m$  são as cotas a jusante e a montante do duto  $x$  [m].

Calcula-se a altura manométrica de cada bomba pela diferença de pressão a jusante e a montante da mesma (Equações (22), (23), e (24)).

$$Hman_i = \begin{cases} |pjb_i - pmb_i|, & \text{se bomba } b \text{ está ligada} \\ 0 \text{ (zero)}, & \text{se bomba } b \text{ está desligada} \end{cases} \quad (22)$$

$$pjb_i = pm_i \quad (23)$$

$$pmb_i = pj_i \quad (24)$$

Em que:  $pjb_i$  é a pressão a jusante da bomba, para cada intervalo da simulação [mcf];

$pmb_i$  é a pressão a montante da bomba, para cada intervalo da simulação [mcf];

$pm_i$  é a pressão a montante do duto conectado a jusante da bomba, para cada intervalo da simulação [mcf];

$pj_i$  é a pressão a jusante do duto conectado a montante da bomba, para cada intervalo da simulação [mcf].

De posse das alturas manométricas, calcula-se uma nova vazão de descarga para todas as bombas, a partir da inserção deste valor na sua curva característica (Equação (25)).

$$Qb_{calc_k} = \max \left[ \frac{-b \pm \sqrt{b^2 - 4.a.(c - Hman_k)}}{2.a} \right]^4 \quad (25)$$

Em que:  $Qb_{calc_k}$  é a vazão encontrada a partir dos valores de pressões calculadas para a vazão estimada ( $Qb_{estim_k}$ ) aplicada ao sistema, para o intervalo de simulação atual [ $m^3/s$ ].

Se a diferença entre as vazões calculadas e as estimadas for maior que um valor mínimo preestabelecido (condição de parada, Equação (27)), repete-se todo procedimento iterativo, assumindo que a nova vazão estimada é igual a média entre a vazão estimada e a vazão calculada anteriores (Equação (26)).

$$Qb_{estim_k} = \frac{Qb_{calc_{k-1}} + Qb_{estim_{k-1}}}{2} \quad (26)$$

$$\frac{\sum_{b=1}^{nb} (Qb_{calc_{k-1}} - Qb_{estim_{k-1}})}{n} > 10^{-6} \quad (27)$$

Em que:  $Qb_{estim_{k-1}}$  é a vazão adotada para a bomba a fim de que o equilíbrio seja verificado, para o intervalo  $k$  da verificação [ $m^3/s$ ];

$Qb_{calc_{k-1}}$  é a vazão encontrada a partir dos valores de pressões calculadas para a vazão estimada ( $Qb_{estim_k}$ ) aplicada ao sistema, para o intervalo  $k$  da verificação [ $m^3/s$ ];

$\sum_{b=1}^n$  corresponde ao somatório de todas as bombas do sistema;

$n$  é o número de bombas do sistema.

---

<sup>4</sup>  $a$ ,  $b$  e  $c$  são os coeficientes da equação da curva da bomba ( $Hman [mcf] = a.Q^2 + b.Q + c$ ;  $Q$  [ $l/s$ ]).

Atendido o critério de parada, obtém-se os valores reais das vazões das bombas (Equação (28)), realiza-se o balanço hídrico nos tanques, onde é calculado o nível atual de cada um (Equação (29)) e calculam-se os consumos de energia envolvidos (Seção 2.3), com isso, finaliza-se um intervalo da simulação.

$$Qb_i = \frac{Qb_{calc_k} + Qb_{estim_k}}{2} \quad (28)$$

$$N_i = \begin{cases} N_{ini}, se i = 1 \\ N_{i-1} + \frac{(Qe_i - Qs_i).t}{Ab}, se i > 1 \end{cases} \quad (29)$$

Em que:  $N_i$  é o nível atual de fluido no tanque [m];

$N_{ini}$  é o nível inicial de fluido no tanque [m];

$N_{i-1}$  é o nível anterior de fluido no tanque [m];

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

$Qe$ ,  $Qs$  são as vazões de entrada e de saída de um tanque, respectivamente [m<sup>3</sup>/s];

$t$  é o intervalo de tempo correspondente a um intervalo da simulação [s].

## 2.5 Restrições

Uma solução será considerada viável caso obedeça a todas as restrições impostas pelo problema. As restrições do problema podem ser de diversas naturezas. As restrições operacionais dizem respeito a restrições de funcionamento dos dispositivos da rede, tais como bombas, dutos e tanques. Os tanques possuem limites de nível mínimo e máximo e os dutos, limites mínimos e máximos de pressão e velocidade do fluido transportado.

Estas restrições não podem ser flexibilizadas sob pena de reduzir os níveis de segurança da operação da rede, devendo ser respeitadas pelo escalonamento gerado. Cada restrição operacional da rede tem um impacto diferente na operação e nos aspectos de segurança e assim podem ser classificados pela sua severidade. Por exemplo, bombear fluido além do limite de nível mínimo de um tanque pode comprometer a vida útil das bombas e até causar a parada do sistema de bombeio. Por outro lado, operar com o fluido

escoando a uma velocidade menor do que a mínima especificada aumenta a deposição de material nas paredes dos dutos, mas é menos crítico do que operar abaixo dos níveis mínimos dos tanques. A pressão sob a qual o sistema opera não só está intimamente ligado à segurança da operação e por isso é uma das restrições mais severas, como também é uma das variáveis mais importantes do ponto de vista econômico. A pressão, juntamente com a vazão, influencia o ponto ótimo de trabalho das bombas. Encontrar uma solução que não viole as restrições operacionais é uma das maiores dificuldades para o algoritmo de otimização.

Além das restrições operacionais, um outro aspecto muito importante é o tempo limite entre a aquisição dos dados e o tempo para informar a programação das bombas para o próximo intervalo de atuação. Por ser aplicado a um sistema em tempo real, as restrições de tempo são fortes, e o algoritmo deve ser capaz de encontrar uma solução viável para o escalonamento das bombas dentro do intervalo de atuação, já que uma solução encontrada após este tempo não terá mais interesse/valor para a aplicação. Dentro de um intervalo de tempo  $t_{\min}$ , inferior a intervalo de atuação, o otimizador deve ser capaz de prover pelo menos uma solução viável para o escalonamento das bombas no próximo intervalo de atuação. O otimizador continuará perseguindo um valor ótimo para todo o horizonte de operação até que o tempo máximo  $t_{\max}$  seja alcançado. Desta forma, à medida que o tempo passa e novas soluções para o problema são exploradas, evoluindo em direção a uma solução ótima para o problema, o valor do processamento aumenta, pois estamos melhorando o resultado que tínhamos inicialmente em  $t_{\min}$ . Depois de transcorrido o prazo ( $t_{\max}$ ), dado pelo horizonte de operação, o valor do processamento cai abruptamente para zero, indicando que o resultado da computação já não tem mais valor para a aplicação (Figura 5). Aplicações com essas características possuem várias soluções intermediárias que podem ter valor para aplicação, mesmo não sendo a solução ótima para o problema.

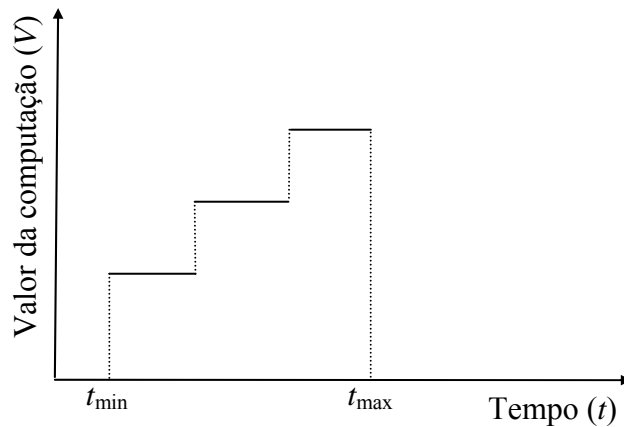


Figura 5 - Gráfico do valor da computação versus tempo

## 2.6 Estudo de caso

O método de resolução proposto será aplicado a uma rede de escoamento de petróleo que consiste em mais de 70 tanques produtores, distribuídos nas diversas estações coletoras, 4 tanques receptores, localizados na estação de tratamento, em torno de 250 bombas de produção e mais de 300 Km de dutos. Os tanques que compõem esta rede possuem diferentes capacidades, as bombas são de diferentes tipos e capacidades e os dutos são de diferentes comprimentos, diâmetros internos e rugosidades. O escalonamento proposto deve adequar-se a todas essas peculiaridades de forma a não desrespeitar nenhuma restrição operacional desses elementos.

Devido ao grande número de dispositivos da rede, o tempo de otimização da malha de escoamento da unidade de negócios RN-CE é bastante elevado, chegando a consumir cerca de cinco minutos para a simulação de cada solução candidata, o que implicaria em vários dias para realizar a otimização de um único cenário. Para fazer o ajuste de parâmetros do algoritmo de otimização é necessário fazer repetidas otimizações da malha de escoamento sob diversas configurações. Por esta razão, para os experimentos que ilustrarão os resultados obtidos durante a realização deste trabalho, apresentados no Capítulo 5, utilizamos uma simplificação desta malha, com um número reduzido de estações e com bombas e tanques equivalentes.

A malha utilizada no estudo é composta por quatro estações coletoras, cada uma com um tanque produtor, e uma estação de tratamento com um tanque receptor. A produ-

ção é bombeada por seis bombas de deslocamento positivo, como pode ser observado no esquema da Figura 6.

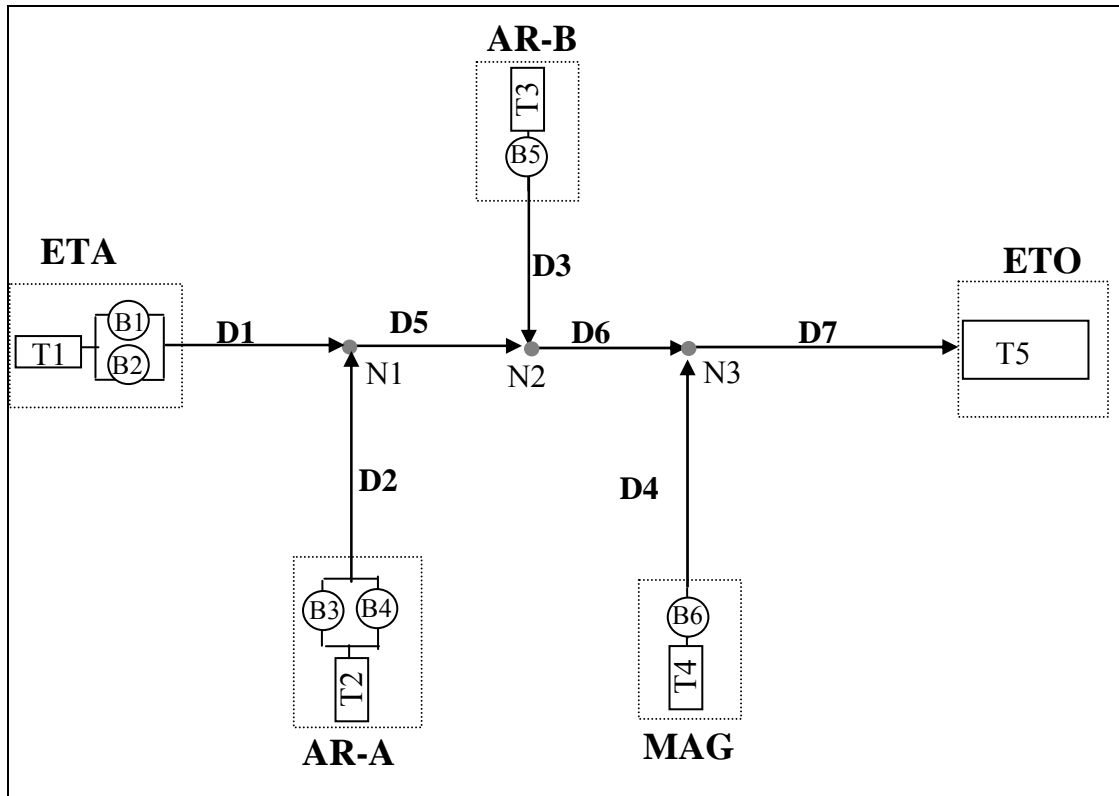


Figura 6 - Esquema da malha de escoamento de testes

As características físicas e os limites operacionais dos tanques, dutos e bombas estão descritas nas Tabelas 3, 4, 5 e Tabela 6.

Tabela 3 - Características físicas e de operação dos tanques

Estação	Tanque	Cota de fundo Z [m]	Nível máximo $N_{m\acute{a}x}$ [m]	Nível máximo de controle $N_{c_{m\acute{a}x}}$ [m]	Nível mínimo de controle $N_{c_{m\acute{i}n}}$ [m]	Diâmetro D [m]	Área da base $A_b$ [m <sup>2</sup> ]
ETA	T1	29,8	11,00	9,10	0,50	10,60	88,25
ARA	T2	10,70	11,00	9,10	0,50	10,60	88,25
ARB	T3	17,10	11,00	9,10	0,50	10,60	88,25
MAG	T4	34,10	11,00	9,10	0,50	10,60	88,25
ETO	T5	71,90	11,00	9,10	0,50	15,95	200,00

**Tabela 4 - Características físicas dos dutos**

Duto	Diâmetro interno d [m]	Comprimento L [m]	Rugosidade $\varepsilon$ [mm]	Cota de montante $Z_{\text{mon}}$ [m]	Cota de jusante $Z_{\text{jus}}$ [m]
D1	0,591	7000	0,025	29,8	10,7
D2	0,337	1200	0,025	10,7	10,7
D3	0,255	1200	0,025	17,1	17,1
D4	0,255	1200	0,025	34,1	34,1
D5	0,591	4200	0,025	10,7	17,1
D6	0,591	6300	0,025	17,1	34,1
D7	0,591	20000	0,025	34,1	71,9

**Tabela 5 - Limites de operação dos dutos**

Duto	Pressão máxima $p_{\text{max}}$ [mcf]	Pressão mínima $p_{\text{min}}$ [mcf]	Velocidade máxima $v_{\text{max}}$ [m/s]	Velocidade mínima $v_{\text{min}}$ [m/s]
D1	250	0	3,0	0
D2	250	0	3,0	0
D3	250	0	3,0	0
D4	250	0	3,0	0
D5	250	0	3,0	0
D6	250	0	3,0	0
D7	250	0	3,0	0

**Tabela 6 - Características físicas das bombas**

Estação	Número de bombas <sup>5</sup>	Cota Z[m]	Rendimento do motor $\eta_M$ [%]	Rendimento da bomba $\eta_B$ [%]			Curva Característica		
				a	b	c	a	b	c
ETA	2	29,8	90	0	0	90	0	-200	12000
ARA	2	10,7	90	0	0	90	0	-200	12000
ARB	1	17,1	90	0	0	90	0	-200	28000
MAG	1	34,1	90	0	0	90	0	-200	28000

Os sistemas sobre os quais desenvolvemos este estudo de caso estão sujeitos a um esquema de tarifas que segue o modelo extraído do contrato entre a Companhia Energética do Rio Grande do Norte (COSERN) e a Central Termoeletrica Alto do Rodrigues com

<sup>5</sup> Todas as bombas de uma estação são iguais ( $H_{\text{man}} [\text{mcf}] = a.Q^2 + b.Q + c$ ;  $Q$  [l/s] )



a PETROBRAS, referentes às unidades consumidoras SE ARG-A3 e SE CAM-A3<sup>6</sup> (Tabela 7). Todas as estações da malha simplificada, baseada na rede de escoamento da UN-RNCE, fazem parte de uma única unidade consumidora, mas como o número de dispositivos nesta malha foi reduzido da original, reduzimos também o valor da demanda contratada presente no contrato original, para tornar os valores adequados para uma rede com um número menor de bombas. Os experimentos ocorrem dentro do período sazonal úmido, no intervalo das 0h às 24h, compreendendo todos os horários tarifários, inclusive o horário de ponta que no contrato com a COSERN corresponde ao período entre 17h30min e 20h30min.

**Tabela 7 - Quadro de tarifas elétricas**

DEMANDA [R\$/KW]	Ponta	21,02
	Fora de Ponta	5,66
	Ponta (ultrapassagem)	63,06
	Fora de Ponta (ultrapassagem)	16,99
CONSUMO [R\$/MWh]	Ponta (período seco)	105,05
	Fora Ponta (período seco)	70,89
	Ponta (período úmido)	93,22
	Fora de Ponta (período úmido)	61,42

O sistema será otimizado em diferentes cenários de produção, para que ele possa ser calibrado para funcionar num cenário cuja produção esteja abaixo do que a rede de

<sup>6</sup> A PETROBRAS e a COSERN possuem outros contratos tarifários para outras unidades consumidoras, como Upanema – A4 e Con/SRC – A4. Todos os contratos utilizam o sistema tarifário horosazonal azul.

duto suporta, um cenário de *baixa saturação* (Cenário I), em um cenário de *média saturação* (Cenário II), onde surgem as primeiras dificuldades de encontrar um escalonamento de bombas que não viole as restrições operacionais do sistema, com a presença de alguns pontos de falhas, e um cenário *saturado* (Cenário III), onde é impossível operar a malha sem que haja um mínimo de coordenação entre as diversas unidades administrativas que estão concorrendo pela capacidade de transferência da tubulação. As condições iniciais do sistema, arbitrados dentro da faixa de operação do sistema, estão nas Tabela 8 e 9, e a previsão da produção para o período a ser otimizado, nos diferentes cenários, é a apresentada na Tabela 10. As características do fluido para todos os cenários hipotéticos de previsão da produção e da previsão de saída da estação de tratamento ETO são apresentadas nas Tabelas 11, 12, 13 e 14.

**Tabela 8 - Condições iniciais do sistema**

Estação	Tanque	Nível inicial N [m]	Quantidade de bombas ligadas inicialmente
ETA	T1	2,0	0
ARA	T2	7,5	1
ARB	T3	8,1	1
MAG	T4	6,0	1
ETO	T5	6,0	-

**Tabela 9 - Característica do fluido nas estações**

Estação	Tanque	BSW <sup>7</sup> [%]	Massa específica $\rho$ [kg/m <sup>3</sup> ]	Viscosidade cinemática $\nu$ [m <sup>2</sup> /s]		Temperatura do fluido T [°C]
				p	q	
ETA	T1	50,000	941,26	0,0579	-2,050	30
ARA	T2	50,000	939,91	0,0435	-1,661	35
ARB	T3	90,000	938,76	0,0290	-1,661	45
MAG	T4	20,000	937,97	0,0145	-1,661	50
ETO	T5	53,491	939,00	0,0268	-1,719	43

<sup>7</sup> **B**asic **S**ediments and **W**ater– sedimentos básicos e água.

**Tabela 10 - Previsão de entrada (da produção) e saída das estações**

Vazão [l/s]					
Estação \ Período	ETA	ARB	ARA	MAG	ETO
Cenário I 00:00 a 24:00	29,5130	73,614	34,1664	15,625	160,00
Cenário II 00:00 a 24:00	35,4160	103,060	42,7080	18,750	207,46
Cenário III 00:00 a 24:00	42,4992	135,600	53,3000	22,500	270,00

**Tabela 11 - Viscosidade cinemática do fluido**

Viscosidade Cinemática do fluido: $\nu = p \cdot T^q$ [m <sup>2</sup> /s]								
Estação \ Período	ETA		ARA		ARB		MAG	
	p	q	p	q	p	q	p	q
00:00 a 07:20	0,0579	-2,050	0,0435	-1,661	0,0290	-1,661	0,0145	-1,661
07:20 a 15:40	0,0290	-1,661	0,0435	-1,661	0,0579	-2,050	0,0145	-1,661
15:40 a 20:40	0,0290	-1,661	0,0579	-2,050	0,0435	-1,661	0,0145	-1,661
20:40 a 00:00	0,0290	-1,661	0,0579	-2,050	0,0435	-1,661	0,0579	-1,661

**Tabela 12 - BSW do fluido**

BSW [%]				
Estação \ Período	ETA	ARA	ARB	MAG
00:00 a 09:50	50	50	90	20
09:50 a 18:10	50	25	65	20
18:10 a 00:00	90	25	65	70

**Tabela 13 - Temperatura do fluido**

Temperatura do fluido: T [°C]				
Estação \ Período	ETA	ARA	ARB	MAG
00:00 a 08:10	30	35	45	50
08:10 a 16:30	37	35	40	50
16:30 a 19:50	37	35	40	60
19:50 a 00:00	35	42	40	60

**Tabela 14 - Massa específica do fluido**

Massa específica do fluido: $\rho$ [kg/m <sup>3</sup> ]				
Estação Período	ETA	ARA	ARB	MAG
00:00 a 04:50	941,26	939,91	938,76	937,97
04:50 a 13:10	937,97	939,91	938,76	941,26
13:10 a 22:20	938,76	939,91	937,97	941,26
22:20 a 00:00	938,76	941,26	937,97	941,26

### 3 Revisão bibliográfica

Devido à natureza do problema, a otimização do escalonamento das bombas em redes de escoamento de fluidos é difícil de ser tratada pela maioria dos métodos de otimização, especialmente quando o sistema a ser otimizado é de grande escala.

Vários métodos dependem da existência de derivadas e restrições de continuidade das funções. A busca no mundo real é cheia de descontinuidades inconvenientes, e espaços de busca multi-modais.

Ormsbee e Lansey [35] publicaram uma revisão das diferentes abordagens para o problema de otimização do escalonamento de bombas. O estudo considera os métodos de programação linear, dinâmica e não-linear, além de adaptações desses métodos. Os diversos trabalhos em otimização do bombeamento são organizados de acordo com os tipos de sistemas aos quais os métodos de otimização se aplicam, explicitando os tipos de rede, de modelo hidráulico e de modelo de demanda que foram utilizados em cada um deles. Os estudos do *Water Research Center* presentes no relatório “*Pump Scheduling in Water Supply*” [46] consideram várias abordagens para o problema de escalonamento de bombas em redes de escoamento de água e traz uma breve descrição dos métodos de programação linear, programação dinâmica, entre outras técnicas, com suas vantagens e desvantagens.

Todavia, nenhum destes métodos é totalmente satisfatório para todos os tipos de problemas de escalonamento de bombas. Todos estes métodos têm um problema comum de serem pouco escaláveis, o que inviabiliza a sua aplicação quando o número de dispositivos cresce, porque a quantidade de cálculos necessários cresce rapidamente e, por conseguinte, o tempo computacional, só sendo adequados para redes de pequeno porte. Muitas vezes os métodos apresentam dificuldades de adequação a redes com mais de um reservatório ou combinações e tipos de bombas diferentes [28].

Muitos problemas de otimização como este, onde a complexidade do problema e a não-linearidade das funções impedem o uso de métodos de otimização tradicionais como a programação linear e a programação dinâmica, utilizam algoritmos de aproximação como os Algoritmos Genéticos. Na falta de algoritmos robustos para localizar o ótimo global, estes têm se destacado por chegar a valores ótimos muito próximos do ótimo global com uma probabilidade alta, sendo muito utilizados em uma grande variedade de

problemas do mundo real, para os quais o espaço de soluções é muito vasto e verificar todas as opções é computacionalmente impraticável.

O uso de Algoritmos Genéticos para a resolução de problemas em redes de escoamento de água, em particular, é muito comum. Os trabalhos mais recentes têm focado seus estudos na otimização de redes de distribuição de água, incluindo, além de projeto de novas redes [7] e modelagem e calibração de modelos de distribuição [39], a reabilitação e a operação [40]. Isso se deve à capacidade dos Algoritmos Genéticos de lidar com problemas grandes e complexos, com funções de otimização multi-objetivo e, muitas vezes, com objetivos conflitantes.

Mackle et al [28], por exemplo, apresentam o uso de Algoritmos Genéticos para a otimização de redes de abastecimento de água. O Algoritmo Genético utiliza uma população inicial gerada randômicamente e um algoritmo de seleção do tipo ordenação. Os resultados com o algoritmo de seleção, que são usados em muitos outros trabalhos de otimização em redes de água, são a maior contribuição daquele trabalho. Posteriormente, há um refinamento, substituindo a população inicial randômica por uma população lida de um arquivo e novos operadores de cruzamento, não apenas com um ponto de troca, mas com dois pontos de troca. O estudo mostra ainda várias comparações entre a abordagem do problema de objetivo único, bem como, como um problema multi-objetivo [41]. A rede estudada tem um único reservatório e quatro bombas, o que totaliza apenas 16 combinações possíveis de escalonamento a cada intervalo de atuação, o que torna possível a exclusão de várias soluções, e mapear a vazão dada pelas diversas combinações e o consumo do conjunto sem a necessidade de simulá-los a cada nova solução candidata a ser avaliada.

Beckwith e Wong [5] apresentam um Algoritmo Genético com o objetivo de reduzir o custo do bombeamento num sistema de água com múltiplos reservatórios, atendendo à demanda diária. O problema é tratado em dois passos: o primeiro determina o volume de água produzido por cada estação para que a demanda seja atendida e o segundo, as bombas que devem ser ligadas para suprir este volume. A solução foi aplicada em uma malha com 5 estações e 16 bombas para um horizonte de operação de uma hora e intervalo de atuação de 15 minutos. Um dos problemas dessa solução é o elevado tempo de processamento. Para a otimização de um cenário, utilizando uma população de 100 indivíduos e 100 gerações, leva-se 3,2 horas.

O EXPLORE (*Hybrid Expert System for water Supply*) [26], por sua vez, é um sistema especialista de apoio à decisão desenvolvido para gerenciar o fornecimento de água na cidade de Sevilha, tendo como meta reduzir o custo da operação de bombeamento da água em reservatórios, mantendo a demanda satisfatória e a água dentro dos padrões de qualidade determinados. O sistema funciona utilizando regras de operação e procedimentos algorítmicos. Para tanto, são necessárias regras que descrevam a operação do sistema de abastecimento de água. A dificuldade de aplicar esta solução ao nosso problema está nas limitações de se capturar as regras de operação, que em geral são procedimentos *ad hoc*, baseadas na experiência prática dos operadores da rede, e que em ambientes cujo comando é descentralizado são difíceis de extrair, dado que o operador não tem uma visão do “todo”. No caso particular do nosso problema, as decisões tomadas nas diversas estações embora sejam consensuais, não visam a otimização do processo de uma forma global. Uma outra abordagem para o problema é a utilização dos Algoritmos Genéticos, juntamente com o aprendizado de máquinas, para a obtenção de regras operacionais ótimas [26]. Esta abordagem, ao invés de fornecer ao operador da rede o escalonamento das bombas para um certo intervalo de tempo, fornece um conjunto de regras extraídas com base nas soluções propostas pelo Algoritmo Genético multi-objetivo, que devem ser seguidas para alcançar um escalonamento ótimo.

A aplicação de Algoritmos Genéticos na indústria de petróleo, por sua vez, tem sido bastante focada na caracterização de reservatórios subterrâneos, inversão sísmica e no desenvolvimento de campos de petróleo [38][6]. O seu uso para operação de sistemas foi pouco explorado, concentrando-se em sistemas de inspeção e reparo de tanques e dutos [42]. As peculiaridades advindas das restrições operacionais neste contexto trazem novos desafios na busca de um algoritmo eficiente para a resolução deste problema (veja [44] para um compêndio sobre aplicação de Algoritmos Genéticos na indústria de petróleo).

Os problemas em redes de escoamento de petróleo foram pouco investigados. Em [42], por exemplo, Algoritmos Genéticos são utilizados juntamente com programação linear para alcançar um fluxo quase constante de óleo na entrada da estação de tratamento de óleo de uma malha de escoamento. Os Algoritmos Genéticos foram utilizados para determinar que bombas seriam ligadas/desligadas. Um indivíduo neste problema é representado por um vetor de apenas 16 variáveis de decisão, com cada variável representando uma bomba do sistema. O número de bombas deste problema é portanto bem menor do

que o do problema da malha de escoamento da UN-RNCE (em torno de 250 bombas), o que reduz bastante o tempo de processamento necessário para alcançar uma solução ótima para este problema. Um outro aspecto é que cabe ao Algoritmo Genético determinar apenas se a bomba estará ligada ou desligada num determinado intervalo de tempo, ficando a cargo do método de programação linear determinar quanto de vazão as bombas de rotação variável, que estiverem ligadas, colocarão no sistema. As restrições do problema foram mapeadas na função de aptidão<sup>8</sup>, em forma de penalidades, de maneira a beneficiar as soluções que além de contribuírem para a menor variação no fluxo de entrada, também reduzam a quantidade armazenada nos tanques e a pressão nos dutos.

A escolha do algoritmo apropriado para a otimização depende bastante das características físicas do sistema que se deseja otimizar. Os Algoritmos Genéticos se apresentam como uma boa solução para otimização de redes de escoamento devido ao tamanho do espaço-solução a ser explorado e a não-linearidade do problema, pois além de não terem nenhum requisito de linearização ou cálculo de derivadas parciais, trabalham com amostras globais, ao invés de seguir um único caminho a partir de um ponto inicial, o que aumenta as chances de convergir num ótimo global.

---

<sup>8</sup> A função de aptidão avalia o quão bem um indivíduo se adapta ao ambiente, em outras palavras ela diz quão boa é a solução.



## 4 Algoritmos Genéticos

Inspirados nos princípios da evolução biológica de Charles Darwin, em que indivíduos mais aptos estão mais capacitados a sobreviver e gerar descendentes pela própria seleção natural, perpetuando suas características através da hereditariedade, os Algoritmos Genéticos são uma versão simplificada do que se passa na natureza. Durante a reprodução, genes dos pais se combinam para formar um novo indivíduo. O descendente criado pode eventualmente sofrer mutação, resultado principalmente de erros na cópia dos genes dos pais, o que possibilita a incorporação de novo material genético a uma população, e o reaparecimento de alguma característica que possa ter desaparecido ao longo da evolução. A aptidão do indivíduo da população é medida pelo sucesso do organismo na sua vida, suas chances de sobrevivência. Os indivíduos mais aptos, que sobrevivem por mais tempo na população têm, portanto, maiores chances de gerar descendentes e, por conseguinte, perpetuar as suas características na população.

Os primeiros estudos e refinamentos das idéias de utilização dos princípios da seleção natural e da evolução em algoritmos de busca culminam com a publicação do livro “*Adaptation in Natural and Artificial Systems*” por John Holland em 1975. Nas últimas décadas os Algoritmos Genéticos vêm sendo amplamente utilizados na solução de problemas nas mais diversas áreas do conhecimento que visam a encontrar um indivíduo ou um conjunto de indivíduos que melhor se adequem a uma série de condições ambientais previamente estabelecidas. Estes problemas se concentram nas áreas de elaboração de escalas de alocação de salas, tarefas e recursos humanos, problemas de *timetable*, seleção de rotas e configuração de sistemas complexos [15].

### 4.1 Estrutura do Algoritmo Genético

A implementação de um Algoritmo Genético começa com a definição de uma função objetivo que se deseja minimizar ou maximizar e uma população aleatória de “cromossomos”, os quais representam possíveis soluções do problema a ser resolvido. Durante o “processo evolutivo” essas estruturas são avaliadas segundo uma função de aptidão e a elas são associadas uma probabilidade de reprodução, de tal forma que as

maiores probabilidades são atribuídas aos cromossomos que representam uma melhor solução para o problema de otimização.

Os indivíduos com maior aptidão são escolhidos através de operadores que imitam o processo de seleção natural da natureza. Os que levam a estados inviáveis do sistema serão fortemente penalizados e muitas vezes descartados da população. Os indivíduos selecionados são modificados através de operadores genéticos de cruzamento e mutação, gerando descendentes para a próxima geração a ser avaliada. Esse processo se repete até que uma solução satisfatória seja encontrada. Estes procedimentos definem a estrutura típica de um Algoritmo Genético, que pode ser observada na Figura 7.

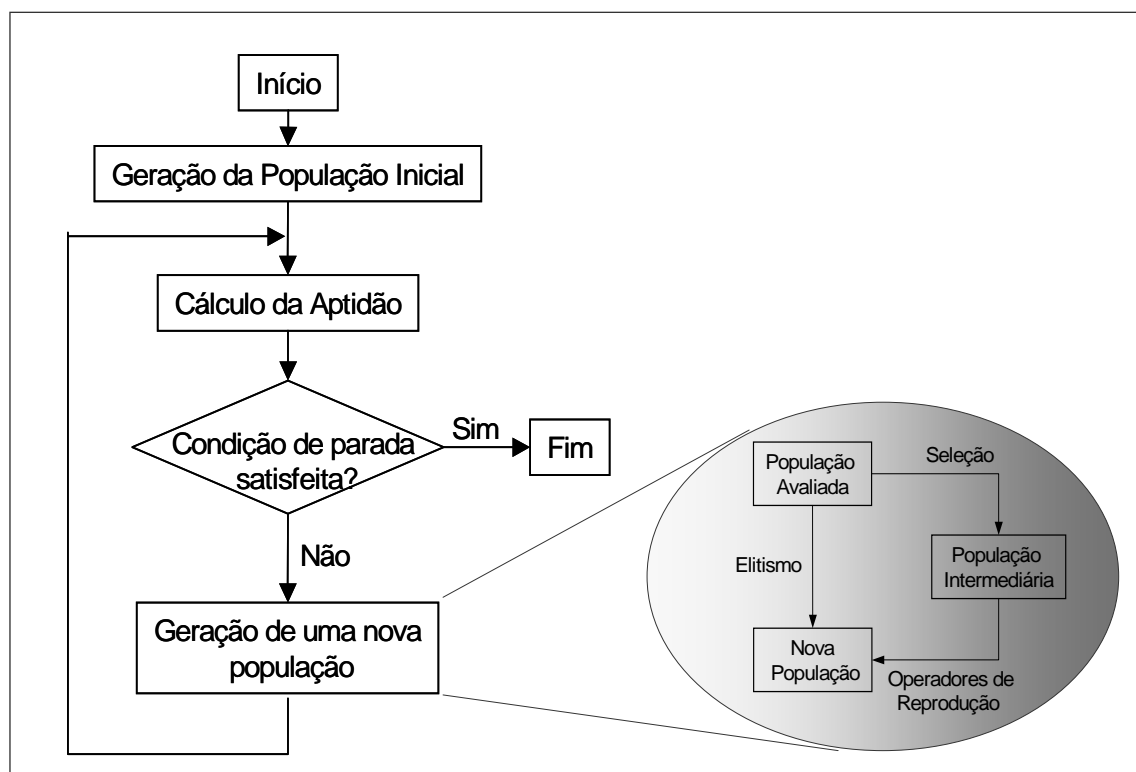


Figura 7 - Estrutura de um Algoritmo Genético

Considerando portanto a estrutura típica de um Algoritmo Genético, podemos afirmar que a escolha da estrutura e definição dos parâmetros de controle do algoritmo incluem as seguintes decisões:

- ❑ A forma mais apropriada de codificar o problema;
- ❑ A função de aptidão a ser usada;
- ❑ O tamanho da população a ser adotado;

- A forma de gerar uma população inicial com possíveis soluções;
- A forma como os cromossomos pais são escolhidos e os descendentes gerados, incluindo decisões a respeito de seleção preferencial, cruzamento e mutação;
- A forma como os indivíduos de uma população são substituídos e,
- Critérios de parada do processamento.

Cada um destes aspectos diferencia um Algoritmo Genético de outro e são determinantes na eficiência do algoritmo. Analisaremos a seguir cada um deles.

## 4.2 Codificação da solução

A escolha da codificação que representa uma possível solução para o problema tem grande impacto no desempenho da busca, já que o tamanho do indivíduo está diretamente ligado ao tempo de processamento necessário para alcançar uma solução ótima. Por esta razão, a codificação deve ser a mais simples e compacta que represente todo o espaço de busca do problema tratado.

Tradicionalmente os Algoritmos Genéticos utilizam uma codificação na forma de seqüência de bits. Esta representação facilita a aplicação dos operadores genéticos padrões e tem uma similaridade maior com a representação genética de um ser vivo. Entretanto, muitas outras formas de codificação são possíveis, entre elas a representação de números inteiros e de números reais. Mesmo nestas representações é possível codificá-las em representações binárias e após a aplicação dos operadores genéticos, decodificá-las para o formato original para avaliação da função de aptidão, o que embora tenha o aspecto negativo das freqüentes conversões, que impactam no tempo de processamento, possibilita utilizar operadores genéticos típicos de representações binárias.

Cada característica codificada é chamada de gene e o conjunto destes genes forma um cromossomo, que representa matematicamente uma possível solução para o problema. Em geral, um cromossomo representa o conjunto de parâmetros da função objetivo. Tomando como exemplo os cromossomos ilustrados na Figura 8, podemos observar vários tipos de codificação e problemas para os quais eles melhor se adequam. O cromossomo A utiliza uma codificação binária, que serve por exemplo, para representar soluções no problema da mochila, que consiste em maximizar o valor dos objetos contidos em uma mochila de capacidade limitada, dado que a cada objeto é atribuído um volume e

um valor. Os cromossomos B e C, por outro lado, utilizam uma codificação valorada, com números reais e caracteres respectivamente. Na codificação valorada cada gene pode assumir o valor de qualquer objeto relacionado ao domínio do problema, um número real, uma seqüência de caracteres ou um objeto, e na maioria das vezes necessitam de operadores de mutação e cruzamento específicos.

Cromossomo A	0 1 0 0 1 0 0 1 1 1 0
Cromossomo B	2.43 3.27 5.88 9.14 11.3
Cromossomo C	Azul verde marrom azul

**Figura 8 - Codificação dos cromossomos**

### 4.3 Geração da população inicial

Uma população inicial pode ser gerada de maneira aleatória, utilizando conhecimentos do domínio do problema, com regras que permitam uma distribuição homogênea no espaço de busca, ou mesmo partindo de soluções previamente calculadas para o problema proposto.

Quando populações pequenas são utilizadas, a distribuição dos indivíduos no espaço de busca pode ser comprometida. Para evitar que regiões do espaço de busca não sejam representadas, uma possibilidade é distribuir os cromossomos de forma equidistante a partir de um ponto aleatório do espaço de busca, ou gerar apenas uma metade da população de maneira aleatória e a outra metade gerar invertendo-se os valores dos indivíduos gerados aleatoriamente.

Alguns problemas permitem que durante a configuração inicial da população, se faça uso de conhecimentos do domínio do problema para gerar apenas soluções possíveis (viáveis). Em algoritmos que visam, por exemplo, maximizar o retorno de uma carteira de investimentos, sabendo-se que a soma dos percentuais investidos em cada uma das diferentes ações que compõem a carteira não pode ultrapassar 100%, pode-se descartar ou corrigir um cromossomo que não esteja em conformidade com esta restrição, evitando que soluções sabidamente inválidas sejam inseridas na população inicial. Isto pode ser observado na Figura 9, onde o cromossomo A não é uma solução válida para o problema, já que a soma dos percentuais investidos em cada uma das ações da carteira supera os

100%. Este cromossomo tanto poderia ser descartado como corrigido, gerando, por exemplo, o cromossomo A' apto a ser incorporado na população (ver Figura 9).

	Ação A	Ação B	Ação C
Cromossomo A	25%	32%	73%
↓			
Cromossomo A'	25%	32%	43%

**Figura 9 - Reparo de um cromossomo**

Outras abordagens inserem já nos cromossomos iniciais características mais desejáveis ou mesmo soluções já conhecidas para o problema. Em problemas de otimização, é comum partir de soluções previamente calculadas por um outro método de maneira que se aumente a possibilidade de encontrar algo melhor do que já se tem, em uma técnica chamada de *seeding* [27].

#### 4.4 Cálculo da aptidão

A função de aptidão calcula a adequação de um indivíduo em relação ao problema proposto, e representa as chances desse indivíduo ser selecionado para fazer parte do processo reprodutivo. A função de aptidão pode considerar um único objetivo, ou pode agregar várias metas e restrições. Em muitos casos ela pode ser a própria função objetivo. Em outros, onde a função objetivo fornece valores negativos, inadequados para alguns métodos de seleção, ou fornece valores muito próximos entre os indivíduos da população ou muito elevados para um pequeno grupo destes indivíduos, se faz necessário mapear a função objetivo em valores de aptidão utilizando uma função de aptidão distinta da função objetivo.

A aptidão é calculada pela aplicação da função de aptidão sobre as variáveis de decisão do problema e fornece um valor único. Este valor é uma medida da proximidade da solução em relação ao conjunto de parâmetros (objetivos) que se tenta otimizar. Os

objetivos que se deseja otimizar podem ser conflitantes, ou seja, quando um aumenta o outro diminui. Por exemplo, ao tentar reduzir o de custo de produção e aumentar a qualidade do que é produzido, temos claramente objetivos divergentes. O objetivo é encontrar o ponto ótimo, ou um conjunto de soluções que sejam as soluções de “melhor compromisso” entre os objetivos considerados, em que não há uma solução melhor que a outra, mas apenas uma relação de compromisso entre os diversos objetivos.

Muitas vezes uma função de penalidade é utilizada embutida ou combinada à função objetivo como forma de calcular a aptidão dos indivíduos inviáveis que possam conter informações importantes para gerar um indivíduo viável. Tipicamente uma função de aptidão com restrições tem a forma

$$f(x) = h(x) + r \sum_{j=1}^n z_j(x) \quad (30)$$

Em que:  $h(x)$  é a função objetivo,

$r$  é a constante de penalidade,

e  $z_j(x)$  é a função de penalidade associada à restrição  $j$  do problema.

Em problemas cuja função de aptidão demande um custo computacional elevado, o algoritmo deve preocupar-se em não reavaliar indivíduos previamente avaliados e que não tenham sofrido alterações (cruzamento e mutação) de uma geração para outra. O algoritmo pode também possuir mecanismos que mantêm resultados parciais previamente calculados que possam ser reutilizados em avaliações futuras ou até mesmo utilizar funções de aptidão mais simples nas primeiras gerações, a fim de identificar as regiões de busca promissoras e só depois avaliar com a função de aptidão desejada [23] [43].

## 4.5 Seleção

Ao final da avaliação da população, os indivíduos são selecionados para reprodução pela sua aptidão. Utilizando algum critério de seleção, promove-se a sobrevivência dos indivíduos mais adaptáveis, com o sacrifício dos menos aptos, que terminam desaparecendo. Os indivíduos selecionados formarão uma população intermediária, também chamada de *matepool*, que é o conjunto de indivíduos que combinados através de operadores genéticos formarão a próxima geração de indivíduos que será avaliada.

Um aspecto importante a ser considerado é o número de cópias de um mesmo indivíduo na população intermediária. Quando se trabalha com populações pequenas, em que exista uma grande discrepância entre os valores resultantes da aplicação da função de

aptidão em uma pequena parte dos indivíduos da população, estes indivíduos com aptidão muito acima da média dominarão a população causando a convergência prematura. Por outro lado, nos casos em que os valores resultantes da aplicação da função de aptidão sob os indivíduos da população assumam valores muito próximos, a busca pode se tornar essencialmente aleatória pela dificuldade de se distinguir entre os membros medianos e os acima da média, necessários para que haja evolução no decorrer das diversas gerações. Nestes casos é necessário mapear os valores da função objetivo em aptidão utilizando uma função de escalonamento da aptidão de forma a possibilitar uma seleção mais equilibrada.

O mapeamento do resultado da avaliação da função objetivo para valores de aptidão permite que se regule os níveis de competição entre os diversos membros da população, através do ajuste da pressão de seleção - probabilidade de o melhor indivíduos ser selecionado comparada à probabilidade média de seleção dos demais indivíduos, e pode ser feito utilizando diversos métodos de escalonamento de aptidão, dentre eles se destacam o método de ordenamento linear [4] e o método de ordenamento exponencial [13]. Estes métodos ordenam a população de acordo com os valores de aptidão de cada indivíduo. A probabilidade de seleção atribuída a cada um dos indivíduos depende somente de sua posição na classificação dos indivíduos da população e não da magnitude da aptidão. Estes métodos introduzem uma função de escalonamento uniforme através da população e fornece uma maneira simples e eficaz de controlar a pressão de seleção, comportando-se de forma mais robusta que métodos que atribuem chances de reprodução a um indivíduo proporcional a sua aptidão [2]. Observe na Tabela 15, que para os mesmos indivíduos temos probabilidades de reprodução diferentes dependendo de como atribuímos a aptidão ao indivíduo, seja pela magnitude da sua aptidão, seja pela sua posição relativa dentro da população. Observe que o indivíduo com maior aptidão teve sua fatia reduzida enquanto que o de menor aptidão teve um crescimento quanto utilizamos a posição relativa na população para definir a aptidão. As chances do primeiro indivíduo ser escolhido em relação ao segundo (os indivíduos de menor e maior aptidão, respectivamente) é de 46,87:6,25, usando o valor real da aptidão ou de 40:10, quando se considera a posição na população.

Dentre os métodos de seleção, um dos mais populares é o método da roleta [16]. O método da roleta consiste em distribuir os indivíduos em fatias de uma roleta de tamanho proporcional à sua aptidão. A roleta possui uma única paleta, que será girada  $n$  ve-

zes, onde  $n$  representa o número de indivíduos da população intermediária. Desta forma, os indivíduos que possuem as mais altas aptidões e por conseguinte uma fatia maior da roleta, têm mais chances de serem selecionados. Vejamos por exemplo o caso de termos indivíduos e uma função de aptidão hipotética, cuja probabilidade de seleção são apresentadas na Figura 10. O indivíduo de número quatro terá a maior fatia da roleta e consequentemente a maior chance de ser escolhido para fazer parte do *matepool*. O método da roleta tem uma alta pressão de seleção, que está diretamente relacionado com a diversidade da população.

**Tabela 15 - Dados de aptidão de um problema hipotético**

<i>No</i>	<i>Indivíduo</i>	<i>Função objetivo</i>	<i>Apt. proporcional ao valor da função objetivo %</i>	<i>Apt. em relação à posição na população %</i>
1	000100	6	6,25	10
2	100011	45	46,87	40
3	111111	28	29,17	30
4	101100	17	17,71	20
<b>Total</b>		96	100	100

A amostragem estocástica universal (SUS, *Stochastic Universal Sampling*) proposta por Baker [4], é um método de seleção semelhante ao da roleta. No SUS a população também é representada por um gráfico em forma de roleta onde o tamanho de cada uma das marcações na roleta é proporcional à aptidão do cromossomo que ela representa. Diferentemente do método da roleta, no SUS o marcador, formado por  $Q$  paletas equidistantes, e os  $Q$  indivíduos na nova população são selecionados em um único giro do marcador, como apresentado na Figura 10. Esse método é uma melhoria do método da roleta, uma vez que mantém a diversidade e previne que as características dos indivíduos com mais alta aptidão dominem a população [18], já que dá chance a indivíduos menos aptos a permanecerem na população e poder fazer parte da formação da nova geração. Vale ressaltar que neste método um indivíduo pode ter mais de uma cópia na população intermediária, como podemos observar no caso dos indivíduos nas fatias 1 e 4 da Figura 10.






Figura 10 - Amostragem estocástica universal

## 4.6 Operadores de reprodução

Os operadores de reprodução geram novos indivíduos a partir dos indivíduos selecionados para compor a população intermediária. O operador de cruzamento (*crossover*) cruza parte de dois indivíduos, trocando parte de suas informações genéticas e gerando dois novos indivíduos, como podemos observar na Figura 11.

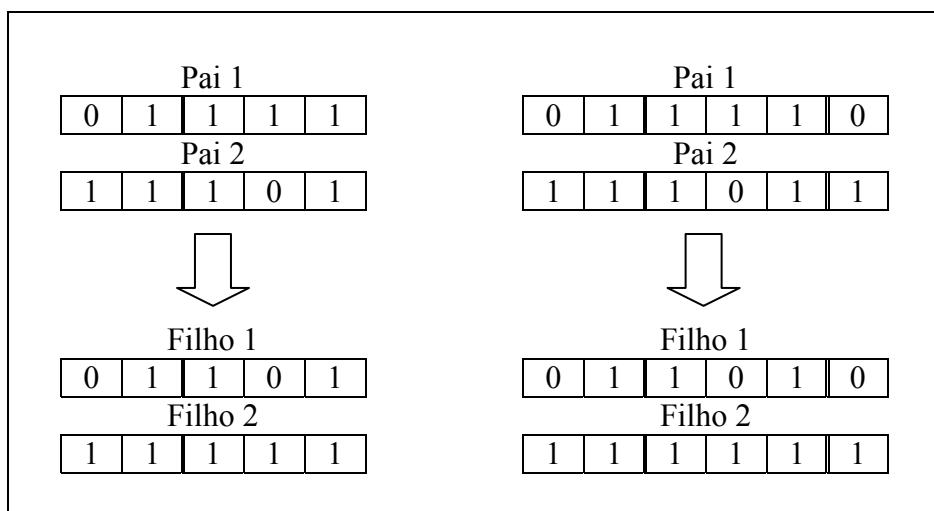


Figura 11 - Cruzamento de cromossomos em um e dois pontos

Se considerarmos que o bom desempenho de um cromossomo é devido aos blocos de construções com alta aptidão, o operador de cruzamento fornece meios de combinar estes blocos de construção de alta aptidão e assim conduzir a soluções com aptidão ainda mais alta.

O operador de mutação por sua vez, altera informações genéticas pontuais em um cromossomo, e desta forma contribui para que informações genéticas novas possam ser introduzidas na população ou mesmo que características perdidas voltem a reaparecer, garantindo a diversidade genética da população. Na Figura 12 o operador de mutação é aplicado a um cromossomo formado por uma cadeia de bits e um gene do cromossomo é invertido de zero para um. A quantidade de genes que sofre mutação e a forma como ela se dá depende tanto da representação adotada quando do comprimento do indivíduo.

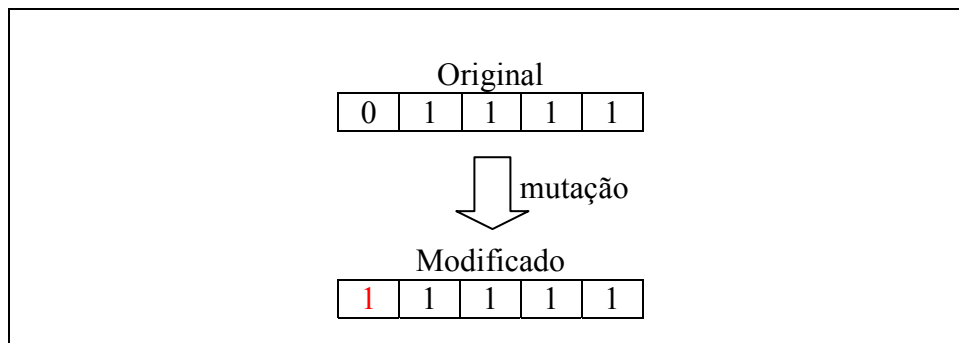


Figura 12 - Operador de mutação

## 4.7 Parâmetros de controle do algoritmo

As taxas para os operadores de reprodução, assim como o tamanho da população, são parâmetros genéticos que influem no comportamento dos algoritmos. A análise da influência de cada um dos operadores é importante para que se possa definir as taxas de reprodução correspondentes conforme as características do problema e dos recursos disponíveis [1][11][17][20].

Populações grandes possibilitam uma melhor exploração do espaço de busca e evitam a convergência prematura num ótimo local, mas implicam num tempo maior de processamento. As populações pequenas, por outro lado, oferecem uma pequena cobertura do espaço de busca. Em geral o tamanho das populações varia entre 50 e 200 indivíduos.

A taxa ou probabilidade de cruzamento determina as chances de que dois indivíduos escolhidos para a reprodução venham a se recombinar. Usualmente a taxa de cruzamento é superior a 60%, chegando muitas vezes a 100% e igual para todos os indiví-

duos da população [30][20]. Caso os indivíduos não sejam recombinados, serão inseridos na população inalterados [16][20].

O número de genes que sofre mutação e a forma como ela se dá depende tanto da representação adotada quanto do comprimento do indivíduo. O operador de mutação é aplicado aos indivíduos com uma probabilidade dada pela taxa de mutação que em geral varia numa faixa pequena entre 0,1% e 3% [20][18][16]. As taxas de cruzamento influenciam a velocidade com que novas estruturas são introduzidas na população e consequentemente a velocidade da evolução. Taxas muito altas podem causar a perda de indivíduos de alta aptidão, enquanto que taxas muito baixas deixam o algoritmo muito lento.

A mutação, responsável pela reintrodução de características que possam ter sido perdidas durante a evolução na população, deve se manter em uma taxa baixa para evitar que a busca se torne essencialmente aleatória.

Ao gerarmos novos indivíduos utilizando os operadores de cruzamento e mutação podemos perder o melhor indivíduo obtido até aquele momento. Para melhorar o desempenho do Algoritmo Genético é importante evitar que isto ocorra. DeJong [8] propôs um operador que preserva o melhor indivíduo de uma população, levando-o sem alteração para a próxima geração. Os estudos de DeJong [8] sugerem que a introdução deste indivíduo melhora a busca local, mas em contrapartida prejudica a busca mais abrangente no espaço solução. Esta técnica é chamada de elitismo e é largamente utilizada.

## 4.8 Estratégia de reposição

A forma como a reposição dos indivíduos de uma geração para outra se dá, define os dois tipos principais de Algoritmos Genéticos: os geracionais, que a cada passo substituem todos os indivíduos de uma geração pelos indivíduos gerados por estes indivíduos através de cruzamento e mutação, e os em regime (*steady-state*) que substituem um pequeno número dos indivíduos de uma população, conforme uma estratégia de reposição estabelecida [13]. Nos algoritmos *steady-state* em geral são criados  $n$  filhos que substituem os  $n$  piores pais e em geral a taxa de crossover aproxima-se de 100% [13]. A primeira abordagem geralmente é acrescida de um operador de elitismo, para garantir que o melhor indivíduo não seja perdido entre uma geração e outra. Variações entre estes dois extremos também são encontradas na literatura.

## 4.9 Critérios de parada

Os Algoritmos Genéticos finalizam sua execução quando um número pré-definido de gerações é atingido, o tempo máximo para execução do algoritmo é atingido, ou pela convergência do algoritmo, que se dá quando não há melhoras significativas nos valores obtidos para a função objetivo por um certo número de gerações, ou mesmo quando toda a população possui uma certa porcentagem de genes com o mesmo valor, o que caracteriza um processo de estagnação do processo evolutivo.

O desaparecimento de algumas características genéticas ao longo do processo de otimização pode levar o algoritmo a restringir sua busca em torno de um máximo ou mínimo local, e acabar por convergir em uma solução não ótima. A este problema dá-se o nome de *convergência prematura*. A convergência prematura se dá quando indivíduos de alta aptidão, quando comparados com o restante da população, são escolhidos com mais frequência para participar do processo reprodutivo, pelos próprios critérios da seleção natural, o que causa o aparecimento de muitos indivíduos com características semelhantes, reduzindo a diversidade genética, e levando a uma convergência do algoritmo nas vizinhanças desses *superindivíduos*. Estes indivíduos embora tenham uma alta aptidão podem não estar na região do ótimo global [13].

Para evitar este comportamento indesejável do algoritmo, pode-se aumentar a taxa de mutação, que reduz a possibilidade de convergência prematura, pois possibilita a busca em diversas regiões do espaço de busca, além de possibilitar o reaparecimento de algum gene que tenha por ventura desaparecido da população devido à superioridade das características contidas num determinado cromossomo que não carrega esta característica. Outra possibilidade é reduzir a participação dos *superindivíduos* no processo reprodutivo, seja por medidas que restrinjam a possibilidade de se ter cromossomos iguais na população ou pela utilização de funções de escalonamento da aptidão.

## 4.10 Princípios e funcionamento

Um bom algoritmo de busca deve tanto explorar uma vasta região de soluções, ou seja, sempre buscar pontos novos no espaço de busca a fim de evitar que se fique preso a um região de um ótimo local, o que é conhecido por *exploration*; quanto utilizar as informações oriundas das melhores regiões visitadas para fazer uma busca no entorno - *exploitation*.

Nos Algoritmos Genéticos, os operadores de reprodução – mutação e cruzamento – fazem *exploration* enquanto que o método de seleção dirige a busca para os melhores pontos do espaço de busca - *exploitation*.

A pressão de seleção é dada pela razão entre a aptidão máxima e a aptidão média da população, e influencia diretamente o comportamento exploratório dos Algoritmos Genéticos. Quando a pressão de seleção é muito baixa, ou seja, não há uma grande variação na aptidão dos indivíduos, o algoritmo adquire um comportamento quase que aleatório, o que não é desejável. Por outro lado, se a pressão de seleção for muito alta o algoritmo tem um comportamento semelhante ao dos algoritmos do tipo subida de encosta. O Algoritmo Genético deve ser configurado de maneira a estabelecer uma pressão de seleção que evite tanto que a busca se torne apenas exploratória, o que levaria a um comportamento de busca aleatório, quanto que a busca se restrinja a uma pequena área do espaço de busca, culminando em soluções pobres (ótimos locais).

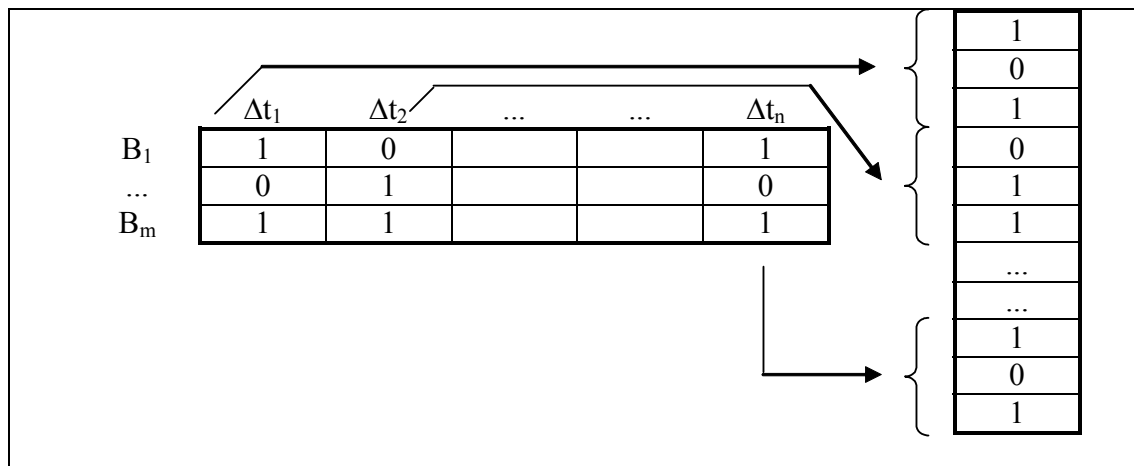
## 5 Adaptando o Algoritmo Genético

Neste capítulo apresentamos o algoritmo proposto para a resolução do problema apresentado no Capítulo 2. A apresentação do algoritmo será feita de forma incremental, apontando as transformações feitas no Algoritmo Genético canônico, para alcançar um escalonamento de bombas otimizado dentro do tempo limite imposto pela aplicação.

No decorrer do capítulo destacamos os resultados alcançados, e os problemas enfrentados na aplicação de um Algoritmo Genético padrão num problema complexo como o abordado neste trabalho.

### 5.1 Codificação do problema

No problema tratado, a função que se deseja minimizar é o custo de energia consumida pelo volume de petróleo bombeado para a estação de tratamento da malha em um dado horizonte de operação. O horizonte de operação é discretizado em intervalos, chamados de intervalos de atuação, onde se dá a programação da operação das bombas. Cada cromossomo da população consiste em uma solução para o escalonamento temporal das bombas, em que cada gene assume os valores 0 (desligado) ou 1 (ligado), que representam se uma determinada bomba **B** está em operação ou não em um dado intervalo de atuação  $\Delta t$ , formando uma matriz bi-dimensional tempo versus bomba, como apresentada na Figura 13. Cada linha da matriz representa uma bomba da rede de escoamento que se deseja otimizar e as colunas, os intervalos de atuação  $\Delta t$ , que são o menor intervalo entre uma alteração de um estado das bombas. Somados, os intervalos de atuação formam o horizonte de operação.



**Figura 13 - Representação de um cromossomo**

Um cromossomo representado como uma matriz bidimensional  $m \times n$  pode ser reorganizado de forma que tenhamos uma estrutura vetorial, sem que haja perda de informação. Cada coluna seria disposta sequencialmente nessa nova estrutura. A opção pelo uso de uma estrutura matricial se deve ao aumento da clareza, pois mantemos a semântica do problema ao preservarmos o sentido temporal da estrutura, e a facilidade de manipulação, já que podemos aplicar os operadores genéticos tradicionalmente utilizados em representações vetoriais.

## 5.2 Função de aptidão

Inicialmente a aptidão foi calculada como a própria função objetivo. As variáveis de estado correspondem ao estado de cada uma das bombas do sistema em um determinado instante, podendo assumir dois valores: ligada ou desligada. O algoritmo visava, portanto, encontrar os valores dessas variáveis que minimizem o resultado da função

$$fo = \frac{CustoTS}{V_{entregue}} \text{ em que,}$$

$CustoTS$  é o custo total de energia consumida durante todo o horizonte de operação, que é resultado da soma do custo total da energia consumida durante o horizonte de operação com o custo total da demanda no mesmo período [R\$];

$V_{entregue}$  é o total de volume entregue na estação de tratamento final durante todo o período de otimização [ $m^3$ ];

Tendo em vista que o controle é obtido levando-se em consideração uma previsão de produção de petróleo arbitrada, que pode vir ou não a se concretizar, a função objetivo foi alterada para levar em consideração mais este fator, e minimizar a possível perda que alguma das partes, no caso as diversas unidades administrativas responsáveis pela operação de cada um dos ativos da malha, possa ter devido a incertezas na previsão da produção.

A nova função de aptidão, ponderada no tempo, atribui pesos maiores para a produção bombeada nos intervalos iniciais do horizonte de operação. Como uma estratégia de controle que envolve vários participantes e interesses conflitantes, a função de aptidão deve privilegiar soluções cujo ganho alcançado nos primeiros intervalos do escalonamento sejam maiores que aqueles obtidos ao final, considerando-se que os participantes preferem não arriscar seus ganhos, deixando-os para um período mais distante no futuro, sob pena de que incertezas na previsão da produção, no modelo de simulação e nos sistemas de aquisição de dados, tornarem o escalonamento previsto para aquele dado momento não factível, e o participante ter seu momento de ganhos novamente adiado.

O algoritmo utiliza portanto uma função objetivo ponderada no tempo, dada pela seguinte equação:

$$fo = \frac{CustoTS}{\sum_{i=1}^n V_i P_i} \text{ em que,} \quad (31)$$

*Custo* é a soma do valor gasto com energia elétrica para aquela programação de liga/desliga, em reais [R\$],

*n* corresponde ao número de intervalos no horizonte de operação que está sendo otimizado,

$V_i$  é o volume entregue na estação de tratamento final no intervalo *i*, em m<sup>3</sup>, e

$P_i$  é um fator de ponderação, que obedece à seguinte relação:  $P_i \geq P_{i+1}$ .

O fator de ponderação foi estimado em 1,2, o que corresponde a um aumento de 20% no volume bombeado, aplicado no primeiro ¼ do horizonte de operação. A cada novo ¼ do horizonte, o fator de ponderação é subtraído em 0,05.



### 5.3 Tamanho da população

Os estudos iniciais de Goldberg [17] a respeito do tamanho ideal para uma população de cromossomos determinavam que em indivíduos codificados na forma de seqüências binárias, a população deveria crescer exponencialmente com o comprimento da seqüência. Isto tornaria as populações em problemas como o que estamos tratando enormes, e os Algoritmos Genéticos pouco eficientes para a solução destes problemas. Resultados empíricos de estudos posteriores mostraram bons resultados para problemas complexos com populações entre  $n$  e  $2n$ , onde  $n$  é o comprimento da seqüência binária [1]. Apesar destas recomendações, questões relativas ao tempo de processamento necessário para avaliar uma geração do algoritmo, nos fez reduzir a faixa de testes de tamanho da população para valores até  $n$ .

O comprimento da representação de uma solução para o problema varia com o tamanho do horizonte de operação, o intervalo de atuação e o número de bombas. A determinação do tamanho ideal para a população foi feita através de experimentos com diferentes tamanhos de população, em uma otimização com comprimento do indivíduo,  $n$ , de 192 (24h x 30 min x 4 bombas)<sup>9</sup>.

**Tabela 16- Parâmetros de controle do experimento**

<b>Parâmetro</b>	<b>Valor</b>
Tamanho da população	20-200
Taxa de seleção para população intermediária	50%
Taxa de cruzamento	90%
Taxa de mutação	10%
Critério de parada	24h

Optamos por variar numa faixa de 20 a 200 indivíduos, e estabelecer um critério temporal para parada do algoritmo, a população intermediária era formada por 50% dos indivíduos da população, e a melhor solução a cada geração era preservada (Tabela 16). Não consideramos o tamanho de população que convergiria para a solução de mais alta qualidade caso fosse dada a chance de evoluir pelo mesmo número de gerações, e sim,

---

<sup>9</sup> Utilizamos neste experimento uma malha reduzida, com apenas quatro estações coletoras e quatro bombas. Estes experimentos foram conduzidos antes que tivesse sido identificado o trecho da malha que utilizaríamos como piloto.

aquela que alcançaria, dentro do prazo estabelecido de 24h, a melhor solução. Populações maiores não foram consideradas devido ao custo computacional da função objetivo que está sendo avaliada e, por conseguinte, o tempo necessário para avaliar uma única geração ser muito elevado.

O gráfico da Figura 14 mostra o resultado obtido com populações de 20, 50 e 200 indivíduos para o mesmo tempo de processamento. A população de 200 indivíduos alcançou a pior solução dentro do prazo que foi estabelecido. Embora uma população maior contribua para uma maior diversidade, devido ao tempo estrito que temos para otimizar não foram consideradas as possíveis melhorias que uma população com 200 indivíduos alcançaria caso evoluísse pelo mesmo número de gerações que as demais populações. As populações com 20, 50 e 200 indivíduos alcançaram resultados muito próximos ( $0,002089508 \text{ R\$/m}^3$ ,  $0,001897773 \text{ R\$/m}^3$  e  $0,002178901 \text{ R\$/m}^3$ , respectivamente), todavia, os resultados da população com 50 indivíduos são melhores que a de 20 indivíduos e, considerando que a população é bem maior, possibilitará uma melhor exploração do espaço de soluções, por outro lado, e por esta razão foi o tamanho de população que adotamos no algoritmo.




Figura 14 - Determinando o tamanho da população

## 5.4 Algoritmo Genético canônico

O Algoritmo Genético canônico ou SGA (Simple Genetic Algorithm) apresentado por David Goldberg no livro “*Genetic Algorithms in search, optimization, and machine learning*” [16] é utilizado na resolução de problemas em diferentes domínios de aplicação. Algoritmos canônicos são todos os algoritmos que obedecem aos princípios do algoritmo proposto por Holland, incluindo aí o algoritmo de DeJong [8], que servem como comparativo e ponto de partida de diferentes implementações de um Algoritmo Genético [48].

No Algoritmo Genético canônico cada membro da população é representado por uma cadeia de caracteres binários de comprimento pré-definido. A população inicial é gerada de maneira aleatória. Neste algoritmo a aptidão é definida por  $f_i / \bar{f}$ , onde  $f_i$  é o valor da função objetivo aplicado ao indivíduo  $i$ , e  $\bar{f}$  é a média do valor obtido com a avaliação de todos os indivíduos da população (pode-se também utilizar uma aptidão referente a posição do indivíduo na população). Após calcular a aptidão de todos os indivíduos é feita a seleção dos indivíduos que formarão a população intermediária. A escolha é feita de forma que a ocorrência de um indivíduo na população intermediária seja proporcional a sua aptidão. Utilizamos o método de amostragem estocástica universal (SUS) para a seleção dos indivíduos para reprodução.

Escolhidos os indivíduos que comporão a população intermediária, inicia-se o processo de reprodução utilizando um operador de cruzamento. O operador de cruzamento escolhe dois cromossomos pais aleatoriamente na população, e combina-os em um único ponto de troca. Após o cruzamento, um operador de mutação é aplicado. Para realizar a mutação em uma solução, é escolhido um intervalo de tempo aleatório e são modificados os estados de 10% das bombas da malha para esse intervalo. Nos casos em que 10% das bombas correspondam a um valor menor que um, o estado de uma bomba é alterado. As bombas cujo estado é alterado são escolhidas aleatoriamente. Relacionar o número de pontos a serem mutados ao número de bombas da malha é importante, pois permite que em malhas com um conjunto de bombas grande por estação, onde o efeito de ligar ou desligar apenas uma bomba não seria muito significativo, o estado de um número maior de bombas seja alterado. Isto acelera a busca na vizinhança proporcionada pela mutação.

Quando o Algoritmo Genético canônico foi aplicado ao problema proposto, consideramos na função objetivo apenas a relação do custo com energia elétrica pelo volume de fluido bombeado para a estação de tratamento da malha de escoamento e atribuímos uma penalidade proporcional à posição do primeiro ponto da falha dada pela seguinte equação:

$$f(x) = \begin{cases} f(x), & \text{se não houver falhas} \\ f(x) \times n / (pf - 1), & \text{se } pf > 1 \\ 0, & \text{se } pf = 1 \end{cases} \quad (32)$$

Em que  $f(x)$  é a função de aptidão do indivíduo  $x$  que se deseja minimizar,  $n$  é o número total de intervalos de atuação da matriz de representação do indivíduo (número de colunas), e  $pf$ , o intervalo de atuação no qual ocorre alguma violação a restrições do problema.

**Tabela 17- Parâmetros de controle**

<b>Parâmetro</b>	<b>Valor</b>
Tamanho da população	50
Tamanho da população intermediária	25
Taxa de cruzamento	90%
Taxa de mutação	10%
Critério de parada	20 min

Os primeiros experimentos foram feitos em malhas com um número muito reduzido de bombas (4 bombas) e para horizontes de operação de poucas horas, com resultados satisfatórios. O Algoritmo Genético foi capaz de encontrar soluções viáveis, partindo de soluções inviáveis, para horizontes de operação de 3h com intervalos de atuação de 30 min. Todavia, ao utilizar horizontes de operação mais realistas, em torno de 24h, os desafios presentes no problema afloraram. O grande número de restrições violadas pelas soluções e a incapacidade de sair das regiões de inviabilidade faziam com que o algoritmo convergisse em soluções de baixo custo, mas operacionalmente inviáveis. Para nossa malha exemplo (detalhes na seção 2.5), utilizando a função de aptidão da equação (32), descrita acima, os parâmetros de controle da Tabela 17, e um horizonte de operação de 24h, a solução viável encontrada pela regra de operação padrão (ver detalhes na Seção

5.8) tinha um custo de 0,1583 R\$/m<sup>3</sup>, o algoritmo canônico obteve seu melhor resultado num experimento em que o custo da solução encontrada foi de 0,1317 R\$/m<sup>3</sup>, o que representa uma redução de 16,8% no custo operacional padrão, contudo a solução encontrada era inviável e tinha sua primeira falha no décimo quarto intervalo de atuação, violando a pressão máxima admissível nos dutos. O algoritmo precisava ser guiado para sair das regiões de inviabilidade e técnicas de tratamento de restrições foram incorporadas.

## 5.5 Tratando as restrições do problema

As técnicas de inicialização, cruzamento e mutação dos Algoritmos Genéticos garantem genes dentro do domínio de cada variável. Para o problema tratado, garantimos que a matriz gerada será formada por elementos 0 e 1. Todavia, essas operações não garantem que os cromossomos satisfaçam determinadas restrições e não é trivial descobrir *a priori* se as soluções serão viáveis ou não. Para aumentar as chances de termos indivíduos viáveis na população, utilizamos algumas técnicas conhecidas para lidar com problemas com restrições e propomos algumas variantes dos operadores de reprodução para aumentar as chances de gerar um indivíduo viável.

### 5.5.1 Função de penalidade

A forma mais comum de tratar a inviabilidade das soluções é penalizando-as. A maneira de trabalhar com a penalidade é adicioná-la ao grau de aptidão de uma solução em problemas de mínimo e subtraí-la em problemas de máximo. Esta função impõe penalidades criando uma classificação onde as avaliações das soluções viáveis sejam sempre mapeadas para valores melhores que as soluções não viáveis. Ou seja, a pior solução viável é melhor que a melhor solução inviável [31].

No caso do problema em estudo, para que uma função de penalidade fosse utilizada seria necessário mapear as violações das restrições em uma equação matemática, cujo resultado seria adicionado ao valor calculado para a função de aptidão de cada indivíduo. A dificuldade de implementação está na determinação de uma boa equação para representar todas as restrições do sistema e a calibração desta função.

Optamos por, ao invés de utilizar uma função de penalidade, classificar as restrições do problema por ordem de severidade (Tabela 18). Relacionamos tanto a restrição quanto a posição na matriz em que ocorre a falha, com uma maior ou menor aptidão de um indivíduo. Desta forma ao compararmos duas soluções inviáveis, aquela cuja falha está mais próxima ao final do horizonte de operação, é considerada superior em relação a outra. Caso o ponto de falha recaia na mesma posição nas duas soluções, aquela que violou a restrição de menor severidade será considerada mais apta. Por fim, caso as soluções tenham o mesmo ponto de falha e violem a mesma restrição, aquela que tem o menor custo será considerada melhor.

**Tabela 18 - Restrições e grau de severidade**

<b>Restrição Violada</b>	<b>Severidade</b>
Tanque produtor atinge o nível máximo	Alta
Tanque produtor atinge o nível mínimo	Baixa
Tanque receptor atinge o nível máximo	Alta
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

Após classificarmos os indivíduos, em ordem crescente de aptidão, segundo os critérios apontados, atribuímos uma aptidão relativa à sua posição na classificação. Métodos que relacionam a probabilidade de seleção à posição de classificação do indivíduo comportam-se de forma mais robusta que métodos que atribuem à probabilidade de seleção valores proporcionais ao resultado direto da avaliação da função de aptidão [47].

Utilizando o método da classificação linear (ver Seção 4.5), com uma pressão de seleção arbitrada em 2,0, a aptidão é dada por:

$$Aptidão(pos) = 2(pos - 1)/(n - 1) \quad (33)$$

Em que:  $pos$  é a posição de um indivíduo na população; e  
 $n$  é o tamanho da população.

Para selecionar a população intermediária, utilizamos a amostragem estocástica universal (SUS). Caso o melhor indivíduo seja selecionado pelos critérios do algoritmo de seleção para fazer parte da população intermediária, o operador de elitismo não mais inserirá uma cópia do mesmo, evitando que tenhamos uma superpopulação de um indivi-

duo de alta aptidão, o que comprometeria a exploração do espaço de busca pelo Algoritmo Genético.

### **5.5.2 Eliminação de soluções**

O descarte de indivíduos inviáveis, conhecido como penalidade de morte, é uma opção bastante utilizada em muitos Algoritmos Genéticos. Em um problema como o que está sendo estudado, cuja possibilidade de gerar soluções inválidas é muito grande, como foi verificado nos nossos experimentos preliminares, o descarte de todas as soluções inviáveis comprometeria o desempenho do Algoritmo Genético, já que uma população gerada aleatoriamente poderia ser completamente inviável e, caso as soluções estejam dispersas no espaço de busca e descartássemos todas para gerar novos indivíduos, o algoritmo estaria seriamente comprometido, tanto do ponto de vista de tempo computacional, como do aspecto evolutivo, já que não seria dada a possibilidade de se evoluir a partir de soluções inviáveis para regiões de soluções viáveis [31].

Optamos por utilizar regras de descarte simples que, antes mesmo que a simulação da operação ocorra, permitam verificar se uma solução desrespeita alguma restrição operacional do problema. Caso ocorra a violação, descartar-se-ia o indivíduo da população sem nem mesmo avaliá-lo. Dada a complexidade do problema, e a limitação de se extrair regras genéricas de descarte, sem que seja necessário simular as soluções, apenas uma regra de descarte está sendo utilizada.

A regra de descarte implementada é capaz de evitar soluções que resultem no transbordo dos tanques produtores. A avaliação é simples: para cada tanque produtor, a previsão da produção determina a vazão de entrada a ser considerada. A partir dessa vazão de entrada podemos calcular facilmente em quanto tempo o tanque enche, caso todas as bombas associadas a ele estejam desligadas. As soluções que apresentem as bombas associadas a esse tanque desligadas por um número de intervalos de atuação superior ao tempo de enchimento calculado serão descartadas. Aplicando essa regra simples para todos os tanques produtores, muitas soluções inviáveis geradas podem ser descartadas antes da simulação para o cálculo da função objetivo, melhorando assim o desempenho do otimizador, especialmente para sistemas de bombeio escoando uma produção elevada para a capacidade da rede de dutos. Nos experimentos conduzidos num cenário de produ-

ção de baixa saturação, nas primeiras gerações o número de descartes representa em média 6% dos indivíduos gerados, caindo rapidamente para 0% dos indivíduos e se mantendo desta forma até o fim da otimização. Em um cenário saturado, a média de descartes foi ligeiramente mais elevada, 8,23%, mas esta se manteve por toda a otimização, com uma pequena queda nas gerações finais

A técnica de descarte de soluções deve ser utilizada em problemas onde há baixa probabilidade de gerar soluções inviáveis pelos operadores genéticos. No problema tratado há uma alta probabilidade de se gerar indivíduos inviáveis, mas o alto custo computacional da avaliação da função objetivo, juntamente com o fato de apenas uma pequena porcentagem de soluções inviáveis serem detectadas pela regra do transbordo dos tanques, justifica-se sua utilização, visto que o desempenho do Algoritmo Genético não é comprometido pela necessidade de se gerar novas soluções para complementar a população, nem tampouco, pelo comportamento aleatório que substituições em grande quantidade gerariam.

### **5.5.3 Operadores genéticos modificados**

Alguns problemas possuem um nível de restrições tão elevado que apenas classificar as soluções pelo seu grau de inadequação ou mesmo descartar as soluções inviáveis não é suficiente para o algoritmo convergir em uma solução ótima em um tempo satisfatório. O problema da otimização do escoamento da produção de petróleo aqui tratado é um destes.

Ao contrário do que se poderia supor, as muitas restrições de um problema, que reduzem em tamanho o espaço-solução e, por conseguinte, o número de soluções possíveis, o que faria a busca por uma solução uma tarefa mais simples, exige que tenhamos operadores que não só sejam capazes de mover-se de uma solução viável para outra solução viável melhor, como sair de uma região de inviabilidade para uma região de soluções viáveis.

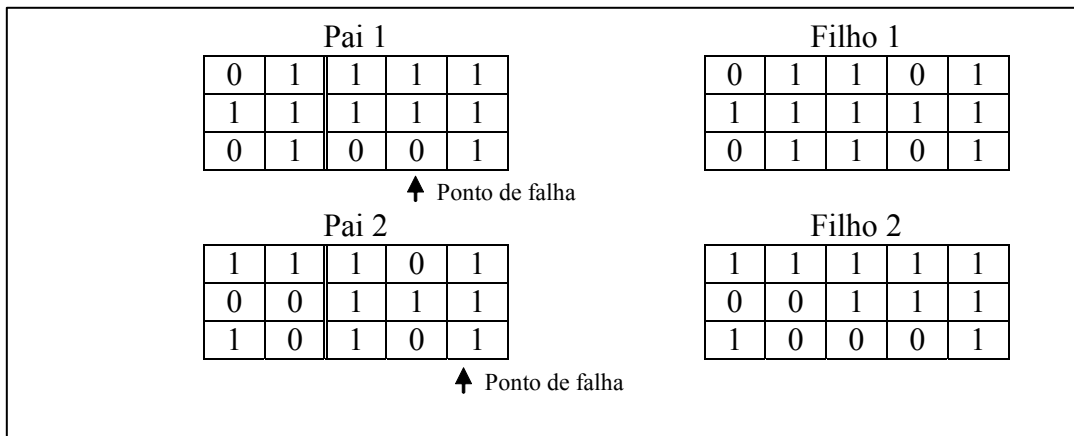
Uma técnica bastante utilizada para lidar com restrições é a de reparo de soluções [31]. Esta técnica corrige soluções que violam restrições com um algoritmo de reparo específico. Dada a complexidade do problema tratado, um algoritmo para correção de soluções seria computacionalmente intensivo, e por esta razão inviável. Optamos por



introduzir modificações nos operadores genéticos tradicionais. Essas modificações utilizam informações de pontos de violação das restrições na solução melhorando as chances de se gerar indivíduos mais aptos.

Ao gerar novos descendentes os operadores de mutação e cruzamento direcionados levam em consideração o conhecimento da posição, na seqüência de *bits*, onde a solução não satisfaz as restrições do problema. A mutação direcionada efetua a mutação dois intervalos antes do ponto de falha. As bombas que serão mutadas naquele intervalo, num total de 10%, são escolhidas aleatoriamente.

O cruzamento direcionado, o nosso operador modificado, funciona da seguinte forma. Comparamos o ponto de falha dos dois cromossomos envolvidos na operação de cruzamento, tomamos a posição daquele que falha mais prematuramente, retrocedemos duas posições e neste ponto fazemos a troca, como mostra a Figura 15. O Pai 2 falha na quinta posição enquanto que o Pai 1 falha na quarta, assim procedemos a troca após o segundo intervalo, dois intervalos antes que a falha no do Pai 1. A decisão de retroceder duas posições é arbitrária, não havendo qualquer dado experimental que indique que este seja um valor ideal, e foi adotada pela necessidade de retroceder um número de intervalos de atuação suficientes para que uma falha possa ser corrigida. Este retrocesso amplia as chances da viabilidade do cromossomo filho, todavia não garante que o resultado da operação será um indivíduo viável.



**Figura 15 - Cruzamento direcionado**

No caso do ponto de falha ser logo no primeiro intervalo, ao invés de fazermos um cruzamento direcionado, que não resolveria o problema da falha, submetemos o cro-

mosso a uma mutação direcionada no primeiro intervalo do cromossomo, e depois a um cruzamento convencional.

As soluções resultantes das operações de cruzamento direcionado e mutação direcionada são avaliadas pela regra de descarte descrita na seção 5.5.2. No cruzamento direcionado, como os pontos de falha dos cromossomos são fixos, a troca de genes é realizada apenas uma vez. Se um dos filhos for descartado, novos pais são selecionados na população intermediária. Na mutação direcionada, caso alguma inviabilidade seja detectada em uma determinada solução, esta é descartada e a operação é realizada novamente. O número de tentativas é limitado de acordo com o tamanho da matriz que representa a solução. Se esse limite for atingido, um outro cromossomo é escolhido na população intermediária para que a mutação possa ser efetuada.

Quando comparamos o desempenho do Algoritmo Genético com os operadores genéticos modificados com aqueles utilizando apenas operadores convencionais, observamos uma evolução mais rápida da posição dos pontos de falhas nos operadores modificados. O número de gerações necessárias para que o ponto de falha da população se encontre em média na metade final do escalonamento, utilizando operadores modificados, variou entre 6 e 10 gerações, enquanto que utilizando os operadores convencionais, variou entre 20 e 26 gerações. Esta variação seja com os operadores convencionais, ou com os operadores modificados é válida para cenários de baixa saturação. Nos cenários saturados pode-se levar até 40 gerações para atingir esta mesma posição de falha, dada a dificuldade de encontrar soluções que obedeçam as restrições neste cenário.

## **5.6 Garantido resultados dentro do prazo com o *seeding***

A técnica denominada “*seeding*” consiste em colocar, na população inicial, soluções encontradas anteriormente para o problema pelo próprio Algoritmo Genético utilizado ou por outros métodos de otimização. Esta técnica pode ser útil em muitos problemas práticos, já que inicia a otimização por regiões mais promissoras, ou mesmo garante que a solução gerada pelo Algoritmo Genético não será inferior às soluções geradas pelos demais métodos de otimização.

A opção pelo uso da técnica de *seeding* foi motivada pelas características da aplicação a que este Algoritmo Genético se destina, uma aplicação com prazos estritos para entrega de uma solução, sob pena de transcorrido o prazo as soluções calculadas até o

momento não terem mais valor para a aplicação. Este prazo é o tempo entre dois intervalos de atuação. A introdução de uma solução do problema, previamente calculada, assegura que, mesmo o Algoritmo Genético não encontrando uma solução viável para o problema dentro do tempo para o próximo intervalo de atuação, ele terá pelo menos uma sugestão de escalonamento viável para este intervalo, caso ela exista.

Ao iniciar a otimização, paralelamente à execução do Algoritmo Genético, procuramos por uma solução viável para o problema utilizando um calculador baseado em regras de operação simples, que calcula para cada intervalo de atuação um escalonamento de bombas que não gere alarmes. O algoritmo desse calculador é apresentado na Figura 16.

---

---

Algoritmo do Calculador de Solução Viável

---

```
intervaloAtual ← tempoInicialOtimizacao
tempoFinalOtimizacao ← intervaloAtual + horizonteOperacao
Enquanto IntervaloAtual < tempoFinalOtimizacao faça
    Calcular configuração inicial das bombas
    Simular
    Enquanto ocorreAlarme e existeMudancaConfiguracaoPossível faça
        Alterar configuração das bombas baseada nas regras de operação
        Simular
    fimEnquanto
    Armazenar escalonamento para o intervaloAtual
    intervaloAtual ← intervaloAtual + intervaloAtuação
fimEnquanto
Retorna escalonamento encontrado
```

---

---

**Figura 16 - Algoritmo do calculador de solução viável**

Para cada intervalo de atuação, o algoritmo define uma programação inicial das bombas. A escolha da configuração inicial das bombas baseia-se no nível atual dos tanques. Cada tanque produtor é dividido em três partes iguais, conforme a sua capacidade. Se o nível do tanque estiver no primeiro terço da divisão, e o tanque portanto está com um nível baixo de fluido, as bombas associadas a esse tanque são desligadas. Se o nível estiver no último terço, e o tanque portanto estiver próximo a sua capacidade máxima, as bombas são ligadas. E, finalmente, se o nível do tanque estiver no segundo terço do mesmo, a decisão é baseada no nível do tanque receptor da malha, caso o tanque recep-

tor, da estação de tratamento, esteja com o nível abaixo ou acima da metade da sua capacidade, as bombas são ligadas ou desligadas, respectivamente.

Após estabelecida a configuração das bombas, o intervalo é simulado e, caso ocorra algum alarme, indicando que alguma restrição do sistema foi violada e, portanto, a solução é inviável, são efetuadas modificações na configuração das bombas de acordo com as regras de operação, estabelecidas na Tabela 19. Para evitar que o algoritmo fique preso num laço infinito, com a aplicação sucessiva das regras de reparo, as ações tomadas para solucionar problemas num dado intervalo 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 de bombas definida nas ações já foram tomadas, o calculador considera o intervalo atual como concluído e avança para o intervalo seguinte. Após finalizada a busca, a solução encontrada, mesmo que não seja viável, é introduzida na população.

**Tabela 19 - Estratégia para reparo de solução**

<b>Restrição Violada</b>	<b>Ações</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
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

O calculador busca um escalonamento viável para cada intervalo de tempo independentemente. Como ele não retrocede para um intervalo já resolvido, é possível que o algoritmo não encontre uma solução viável, mesmo para malhas que apresentam tal solução. Se elaborássemos um calculador mais sofisticado, que retrocedesse para intervalos anteriores na tentativa de gerar uma solução viável, teríamos um algoritmo de busca exaustiva, e recairíamos no problema de solucionar um problema *NP-hard*<sup>10</sup>.

<sup>10</sup> NP-hard é a classe de complexidade dos problemas de decisão que são intrinsecamente mais difíceis que aqueles que podem ser resolvidos por uma máquina de *Turing* não-determinística em tempo

A análise dos indivíduos da população indica que a introdução deste indivíduo aumenta significativamente as chances de se obter outros indivíduos viáveis, visto que a introdução de um indivíduo de mais alta aptidão acelera a introdução de características desejáveis na população, resultado dos blocos de construções com alto valor de aptidão que se espalham rapidamente na população [18].

Mesmo nos casos onde o calculador de solução viável não é capaz de encontrar uma solução viável para o problema, e o indivíduo inserido na população é inviável, as características desse indivíduo tendem a se propagar pela população, pois seu ponto de falha, em geral, está localizado em uma posição superior à dos indivíduos gerados aleatoriamente.

Em cenários de produção onde o sistema opera dentro da sua capacidade, mesmo quando o calculador de solução viável não é bem sucedido, os operadores genéticos modificados são capazes de mover a posição de falha para posições maiores na matriz de escalonamento. Todavia, como não há a inserção de uma solução viável, não há uma propagação rápida de blocos de construção com alta aptidão, que aceleram o progresso da busca. Para o mesmo caso avaliado na Seção 5.5.3, com uma malha operando dentro da sua capacidade, utilizando operadores genéticos modificados, sem que contudo tenhamos uma solução viável inserida na população, leva-se em torno de 30 gerações para que se alcance uma matriz com falhas, apenas na segunda metade do horizonte de operação na maior parte dos indivíduos da população, valor bem acima da faixa observada quando na presença de uma solução viável, de 6 a 10 gerações.

## 5.7 Parâmetros de controle

Incorporadas as modificações para o tratamento das restrições do problema e do calculador de solução viável, passamos à fase de eleição dos parâmetros de controle do algoritmo.

Cada um dos componentes de um Algoritmo Genético tem parâmetros associados a si, como a probabilidade de mutação, a porcentagem de indivíduos escolhidos pelo algoritmo de seleção, o tamanho da população, entre outros. Os valores destes parâmetros

---

polinomial. Quando a versão de decisão de um problema de otimização é provada pertencer à classe dos problemas NP-completo, então sua versão de otimização é NP-hard [14].

têm grande influência no tempo para se alcançar uma solução viável e na qualidade da solução encontrada [18][11].

Pesquisas mostram que certas classes de problemas requerem parametrização específica para alcançar um bom desempenho [3]. Parâmetros como a taxa de cruzamento e de mutação utilizados neste trabalho foram resgatados da literatura [20][16][30][21][1]. Outros como o tamanho da população e a porcentagem de indivíduos gerados por cruzamento e cruzamento direcionado foram determinados através de experimentos num processo conhecido como “ajuste de parâmetros”. Esse ajuste de parâmetros manual, além de demorado, tem alguns inconvenientes, visto que os experimentos são conduzidos para cada parâmetro por vez, e há uma forte dependência entre eles que não é considerada, pois proceder experimentos para todas as combinações é praticamente impossível [11].

Os parâmetros de controle do algoritmo podem ser observados no quadro da Tabela 20.

**Tabela 20 - Parâmetros de controle**

<b>Parâmetro</b>	<b>Valor</b>
Tamanho da população	50
Tamanho da população intermediária	25
Taxa de cruzamento	90%
Taxa de mutação	30%
Indivíduos inseridos por elitismo	1
Indivíduos inseridos por cruzamento/cruzamento direcionado	15/34
Critério de parada	20min

O tamanho da amostra selecionada para fazer parte da população intermediária é de 50% do tamanho da população original. O operador de elitismo seleciona apenas o melhor indivíduo de cada geração para fazer parte da próxima população. Os valores encontrados na literatura levaram-nos a adotar uma probabilidade de cruzamento entre dois indivíduos de 90%. A proporção de indivíduos gerados por cruzamento e cruzamento direcionado é de 30% e 70%, respectivamente. A taxa de mutação foi fixada dentro dos valores de referência da literatura, e têm uma probabilidade de ocorrência de 30%, aplicada por indivíduo (e não bit a bit), em um único intervalo de tempo, o que resulta numa probabilidade de aproximadamente 0,2% de que um bit venha a ser invertido. Estes

valores foram estabelecidos após experimentos variando as taxas de mutação no intervalo de 0,1 a 5% e as taxas de cruzamento de 60 a 90% [3][1].

Resultados apresentados na seção 5.8 sugerem que um dos refinamentos que este algoritmo deve sofrer é a substituição destes parâmetros estabelecidos experimentalmente na forma de ajuste gradual pelo controle de parâmetros [11]. O controle de parâmetros é uma outra abordagem para a parametrização de Algoritmos Genéticos, onde os parâmetros vão sendo configurados dinamicamente durante o processo de otimização, à medida que o algoritmo evolui. A estagnação prematura observada em algumas amostras, em torno de ótimos locais, sugere a necessidade de uma taxa de cruzamento e mutação adaptativa, até porque utilizamos duas técnicas diferentes para os operadores de cruzamento e mutação, a convencional e a direcionada, que precisam ser equilibradas, conforme o progresso do algoritmo.

## 5.8 Testando o AG para diferentes padrões de produção

Um Algoritmo Genético para o problema tratado deve ser capaz de suportar tanto variações na topologia e dimensão da malha, quanto alterações na previsão da produção. As alterações de topologia e dimensão da malha relacionadas à parada de equipamentos para manutenção e a expansões com obras de engenharia na rede e o padrão de produção influenciam diretamente em uma maior ou menor dificuldade de se encontrar uma solução viável para o problema e na possibilidade de otimização do bombeio.

Nesta seção analisamos três cenários de operação distintos, que correspondem respectivamente a um sistema com baixa saturação para a produção, um sistema de média saturação e um sistema saturado. Para cada um destes cenários observamos como o Algoritmo Genético se comporta quando comparado a um sistema de regras que simula o comportamento de um operador.

Para conseguir representar estes cenários são feitas alterações no perfil de produção dos campos de maneira a saturar o sistema. O perfil de produção dos três cenários pode ser observado na Tabela 21 (apresentada anteriormente no Capítulo 2).

**Tabela 21 - Características da produção**

Estação	ETA	ARB	ARA	MAG	ETO
---------	-----	-----	-----	-----	-----

Propriedades	Q (l/s)	Q(l/s)	Q(l/s)	Q(l/s)	Q(l/s)
Cenário I (baixa saturação)	29,5130	73,614	34,1664	15,625	160,00
Cenário II (média saturação)	35,4160	103,060	42,7080	18,750	207,46
Cenário III (saturado)	42,4992	135,600	53,3000	22,500	270,00

O perfil de produção nos diferentes campos varia, nos três cenários, apenas no que se refere à vazão de entrada em cada uma das estações. As demais propriedades de fluido, como temperatura e viscosidade, foram mantidas as mesmas nos três cenários (ver Seção 2.6). A vazão de entrada em ETA cresce numa razão de 20% a cada cenário, em ARA 25%, em MAG 20%, em ARB ela cresce 40% do cenário I para o cenário II, e 20% do cenário II para o cenário III. A vazão de saída na estação de tratamento ETO aumenta 30% tanto do cenário I para o II, quanto do cenário II para o III. A vazão média de saída das bombas associadas às estações é respectivamente, 188 l/s em ETA, 118 l/s em ARB, 139 l/s em ARA e 138 l/s em MAG.

Em todos os experimentos foi utilizada a mesma malha detalhada na Seção 2.6, com 6 bombas. O horizonte de operação é de 24h com intervalo de atuação de 20 min. Comparamos os resultados alcançados pelo Algoritmo Genético para os três cenários de previsão da produção, com os resultados obtidos por uma regra de operação que simula o comportamento de um operador da malha real. O operador deste sistema gerencia o bombeio da sua estação coletora sem levar em consideração as outras unidades de bombeio. O objetivo do operador é bombear toda a sua produção durante os horários de tarifas mais baixas, de forma que no início do período de ponta os tanques estejam no menor nível possível. A regra de operação, baseada na operação *ad-hoc* do sistema real, mantém todas as bombas ligadas até que o limite de nível mínimo do tanque seja atingido, quando as bombas são desligadas e só voltam a ser religadas quando o limite de nível máximo do tanque for atingido. Esta é a operação em todo o período, exceto ao se aproximar do horário de pico, quando os operadores ligam as bombas, para que os tanques estejam no seu menor nível no início do horário de ponta. O algoritmo está descrito na Figura 17.



---

### Algoritmo da Regra de Operação

---

intervaloAtual  $\leftarrow$  tempoInicialOtimizacao

tempoFinalOtimizacao  $\leftarrow$  intervaloAtual + horizonteOperacao

**Para cada** estação **faça**

    estaEsvaziando  $\leftarrow$  verdadeiro;

    cheioDentroHorarioPico  $\leftarrow$  falso;

**Enquanto** intervaloAtual < tempoFinalOtimizacao **faça**

**Se** tanque está seco

            Desligar bombas

            estaEsvaziando  $\leftarrow$  falso

**Se** intervaloAtual dentro do horário de pico

                cheioDentroHorarioPico  $\leftarrow$  verdadeiro;

**fimSe**

**Se** tanque está cheio

            Ligar bombas

            estaEsvaziando  $\leftarrow$  verdadeiro

**fimSe**

**Se** (não está cheioDentroHorarioPico e

            intervaloAtual dentro do horário de pico)

            estaEsvaziando  $\leftarrow$  falso

            Deligar bombas

**Senão**

**Se** (intervaloAtual **menor que** tempoParaInicioHorarioPonta) e

            (tempoParaEsvaziarTanqueAntesHorarioPico **maior que** InicioHorarioPico)

                estaEsvaziando  $\leftarrow$  verdadeiro

**fimSe**

**fimSe**

**fimEnquanto**

    Armazenar escalonamento para o intervaloAtual

    AtualizarNiveisTanques

    intervaloAtual  $\leftarrow$  intervaloAtual + intervaloAtuacao

**fimPara**

**Retorna** escalonamento encontrado

---

Figura 17 - Algoritmo de operação da rede de escoamento

Os Algoritmos Genéticos fazem parte da classe de heurísticas não-determinísticas, e por essa razão, para caracterizar seu desempenho é necessário a repetição de um mesmo experimento diversas vezes. O baixo desvio padrão observado nos nossos experimentos (Tabela 22) nos dá uma indicação de que podemos considerar os resultados dos nossos experimentos, com um número reduzido de repetições, válidos. Executamos os experimentos numa grade computacional, um ambiente pouco estável e heterogêneo, que utiliza computadores independentes conectados em rede, incluindo aqueles utilizados para atividades de propósito geral, como plataforma para execução de aplicações paralelas [12].

Adotamos um modelo de paralelização mestre-escravo pela facilidade de implementação, baixo acoplamento entre as tarefas e a grande eficiência do método quando a função a ser avaliada consome muitos recursos computacionais [9]. Nesta arquitetura de paralelização um dos processadores, o mestre, irá armazenar toda a população, enviar indivíduos para serem avaliados pelos processadores escravos, coletar os resultados, e aplicar os operadores genéticos para gerar a nova população. O algoritmo mestre-escravo não tem seu comportamento de busca alterado devido à paralelização, visto que há uma sincronização entre o nó mestre e os escravos, portando-se como um algoritmo seqüencial, o que do ponto de vista do desempenho geral do algoritmo pode não ser o ideal, mas permite que toda a teoria desenvolvida para os algoritmos seqüenciais possa ser aplicada diretamente, sem adaptações ou considerações [19][44].

Devido ao elevado custo computacional da avaliação da função objetivo, que é proporcional à complexidade da malha para a qual se deseja obter um escalonamento de bombas ótimo, apenas um número pequeno de gerações consegue ser avaliada dentro do prazo. As características da infra-estrutura de processamento dificultavam a comparação dos experimentos, já que para um mesmo intervalo de tempo (20 min), poderíamos avaliar uma quantidade diferente de indivíduos, devido a variação na carga e no número de recursos disponíveis na grade computacional.

Para determinar quantas gerações poderiam ser avaliadas em 20 min, caso os recursos fossem de uso dedicado, deixamos as máquinas de uma grade computacional de cinquenta computadores *pentium* IV com 512Mb de RAM indisponíveis por este período para uso pelos demais usuários. Neste período conseguimos avaliar apenas 20 gerações. Fixamos então em 20, o número de gerações que seriam avaliadas em cada um dos experimentos.

Para cada cenário de operação, repetimos a otimização com o Algoritmo Genético por cinco vezes, avaliando em cada uma delas 20 gerações. Os resultados obtidos estão apresentados na Tabela 22. O Algoritmo Genético é na média, melhor que a regra em todos os cenários, contudo no pior caso o Algoritmo Genético conforme implementado é pior que a regra tanto no cenário I quanto no II, só superando a regra no cenário III devido ao ponto de falha mais distante no horizonte de operação. No terceiro cenário, onde a malha está saturada, e o custo obtido pela regra de operação é inferior em quase 5%, o ponto de falha da regra acontece dezoito intervalos antes, enquanto a regra falha no oitavo intervalo, a solução encontrada pelo Algoritmo Genético só falha no vigésimo sexto intervalo.

O número de gerações avaliadas, e por conseguinte o número de indivíduos avaliados, é muito pequeno quando comparado ao tamanho do espaço-solução. Este fato sugere que caso tivéssemos mais recursos disponíveis, e por conseguinte avaliássemos um número maior de gerações, alcançaríamos além de maiores ganhos nos cenários I e II, uma solução viável para o cenário III.

**Tabela 22 - Resultados da otimização**

		Cenário I (baixa saturação)	Cenário II (média saturação)	Cenário III (saturado)
<b>Regra de operação</b>	Custo (R\$/m <sup>3</sup> )	0,00246	0,00275	0,00252
	Ponto de falha	Transbordo na ETO	12	8
<b>Algoritmo Genético</b>	Valor mínimo (R\$/m <sup>3</sup> )	0,00216	0,00207	0,00220
	Valor máximo (R\$/m <sup>3</sup> )	0,00256	0,00284	0,00312
	Média (R\$/m <sup>3</sup> )	0,00225	0,00240	0,00264
	Desvio padrão	0,00011	0,00040	0,00035
	Ganho na média (%)	8,53	12,70	-4,87
	Ponto de falha	-	-	26

Para investigar essa hipótese, executamos o Algoritmo Genético por 24h em uma grade computacional de oito máquinas não dedicadas, o que permitiu a avaliação de aproximadamente 250 gerações. Observando os resultados da otimização, percebeu-se que após as primeiras 150 gerações, a redução do custo da função objetivo era mais lenta.

Fixamos então 150 gerações como o tempo ideal para que o algoritmo genético executasse. A opção por um número fixo de gerações, ao invés de uma condição de parada por tempo, se deve a dificuldade que teríamos para analisar os resultados, visto que os recursos da grade não estão dedicados, poderíamos ter experimentos sendo executados pela mesma quantidade de tempo, mas com número de gerações avaliadas diferentes, e desta forma com um número menor de soluções avaliadas.

Para os mesmos cenários avaliados inicialmente com 20 gerações, refizemos os experimentos utilizando como critério de parada a avaliação de 150 gerações.

Na Figura 18, observamos o comportamento do cenário I, de baixa saturação, com uma produção abaixo da capacidade de escoamento da rede. A solução encontrada pelo Algoritmo Genético é mais barata que da regra de operação usual, e tem um custo de 0,00185 R\$/m<sup>3</sup>. A regra de operação alcançou um custo de 0,00246 R\$/m<sup>3</sup>, com uma falha operacional de baixa severidade, com a violação do limite de nível superior do tanque da estação de tratamento final. O Algoritmo Genético conseguiu portanto uma redução de 24,79% em relação à operação convencional.





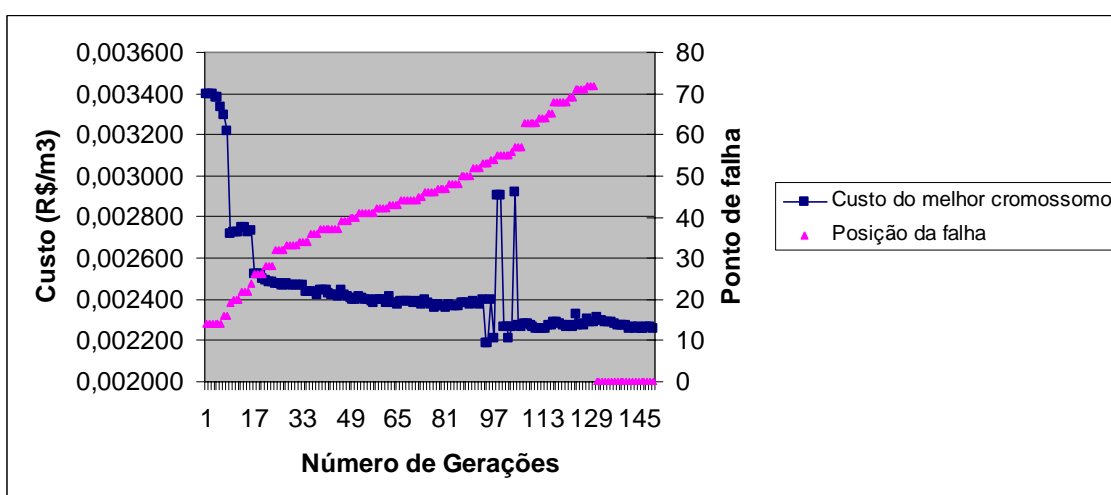
Figura 18 - Desempenho no cenário I de produção

No segundo cenário, um cenário de saturação mediana, observado (Figura 19), a regra de operação também não consegue encontrar uma solução viável para o problema e causa, além do transbordo do tanque receptor, sobrepessão em alguns dutos. A redução de custo alcançada pelo Algoritmo Genético neste cenário em relação à regra de operação é de 32%. O Algoritmo Genético alcança um valor de 0,00187 R\$/m<sup>3</sup>, enquanto que a regra de operação só consegue otimizar a solução a um custo de 0,00275 R\$/m<sup>3</sup>.



**Figura 19 - Desempenho no cenário II de produção**

O terceiro cenário de simulação se dá em uma rede de escoamento saturada e, neste cenário, a regra de operação também não é capaz de encontrar uma solução viável. O calculador de solução viável também não consegue encontrar uma solução viável, e a otimização se inicia com uma solução com falha no décimo quarto intervalo de atuação. O primeiro indivíduo viável surge na geração 130 e tem um custo de 0,00231 R\$/m<sup>3</sup>. Ao final de 150 gerações o custo do melhor cromossomo é de 0,00226 R\$/m<sup>3</sup>. A regra de operação falha no oitavo intervalo e tem um custo de 0,00252 R\$/m<sup>3</sup>. O ganho do Algoritmo Genético em relação a regra é de 10,31 %.



**Figura 20 - Desempenho no cenário III de produção**

O gráfico da Figura 20, diferentemente dos demais, apresenta quedas e subidas no valor da função de custo avaliada, isto é resultado do critério adotado para classificar as soluções. Quando duas soluções inviáveis são comparadas, aquela que possui o ponto de falha no maior intervalo de atuação será considerada a melhor solução entre elas, embora o custo possa ser superior. Neste experimento, a melhor solução da nonagésima sétima geração possui um custo de  $0,002209 \text{ R\$/m}^3$  e a melhor da nonagésima oitava geração tem um custo de  $0,002904 \text{ R\$/m}^3$ , mas o ponto de falha da primeira é na posição 54, enquanto o da segunda é no intervalo 55 de atuação.

Observando os gráficos das Figuras 18,19 e 20, podemos notar quedas bruscas no valor do custo da melhor solução encontrada. Essas quedas ocorrem quando as operações genéticas tiram da inviabilidade uma solução de mais baixo custo, por esta razão temos mudanças pontuais significativas no custo do melhor cromossomo.

## 6 Conclusões e trabalhos futuros

O Algoritmo Genético demonstrou ser uma técnica satisfatória e simples para a resolução de problemas em redes de escoamento complexas, com espaço de solução de dimensão elevada e restrições operacionais rígidas. A complexidade da malha, os níveis de saturação da rede e as restrições operacionais sob a qual opera são fatores importantes para determinar se uma solução viável será alcançada e o tempo que levará para que isso ocorra.

Um dos maiores problemas enfrentados pelo algoritmo apresentado são as restrições temporais que precisam ser respeitadas. No cenário de otimização saturado, onde a operação simultânea de todas as estações, com a conseqüente concorrência pela capacidade de transferência da rede de dutos, leva a violação de restrições de pressão e velocidade do fluido nos dutos, o algoritmo não foi capaz de identificar uma solução viável para o problema dentro do prazo da aplicação. O elevado tempo computacional da avaliação da função de custo inviabiliza uma busca mais ampla no espaço-solução, o que pode ser crítico quando o cenário que está sendo otimizado está saturado e o número de soluções viáveis é pequeno.

A ampliação do estudo de caso para um cenário com um número maior de estações coletoras e de bombas por estação, como a malha da UN-RNCE, permitirá a avaliação da eficiência e eficácia da solução quando aplicada a uma rede mais complexa, com um número maior de dispositivos. Para isto, o modelo de simulação hidráulica precisa ser refinado para melhorar a sua eficiência computacional, permitindo uma avaliação mais rápida da função-objetivo, pois a adoção de uma outra arquitetura de paralelização de Algoritmos Genéticos mais eficiente, ou mesmo uma grade computacional de maior dimensão, não seriam suficientes para viabilizar a otimização de uma malha com um grande número de dispositivos em um tempo aceitável.

Um aspecto importante da solução apresentada é a sua generalidade. O modelo apresentado se aplica a uma malha de escoamento de petróleo de topologia genérica, com a possibilidade de paradas programadas em parte dos ativos da malha dentro do horizonte de uma otimização, sem que para isso tenha que haver qualquer modificação na solução.

O desempenho do Algoritmo Genético depende fortemente dos parâmetros de controle utilizados e do ajuste adequado desses parâmetros, especialmente em relação à

incorporação futura de taxas variáveis ao longo do tempo, onde o próprio algoritmo, de acordo com o processo evolutivo, selecione os parâmetros e até mesmo os operadores que devem ser aplicados.

Os operadores genéticos modificados e a solução inicial introduzida pelo calculador de solução viável se mostraram eficazes na aceleração da busca por uma solução viável para ao problema. O operador de elitismo assegurou a preservação da melhor solução, sem que com isso tivéssemos uma convergência prematura.

## **6.1 Novos objetivos a serem otimizados**

O custo com consumo de energia transitório, dado pela energia consumida no momento que a bomba é acionada, e o custo da manutenção das bombas, que são de difícil estimativa e cálculo, além da manutenção de um padrão de BSW e vazão que chegam à estação de tratamento, são alguns dos objetivos que podem ser incorporados.

O consumo de energia transitório e o custo da manutenção de equipamentos estão diretamente ligados à sua operação. No caso das bombas, a operação de liga/desliga constitui um fator importante para o desgaste do equipamento e redução da sua vida útil, assim como sinaliza a solução que teria o maior custo caso o consumo de energia transitório fosse medido. Embora difícil de quantificar este custo, é possível adicionar este novo objetivo como um dos objetivos a ser perseguido pelo algoritmo de otimização, de forma que soluções equivalentes em termos de custo de energia elétrica (custo em regime) possam ser diferenciadas uma das outras pelo número de chaveamentos. O chaveamento é a transição do estado desligado para estado ligado, e a sua otimização em muitos casos é tão ou mais importante que os aspectos de consumo de energia em problemas de otimização do escalonamento das bombas [25]. Soluções que tivessem um menor número de alterações de estado de desligado para ligado seriam incentivadas em relação às demais soluções.

## **6.2 Tratamento de inviabilidades**

Devido às restrições do problema, uma preocupação relevante do algoritmo proposto é o tratamento das soluções inviáveis. Parte dos nossos estudos foram focados nos operadores de reprodução direcionados e na avaliação da sua contribuição para o direcio-



namento da busca. Alguns refinamentos desse operador podem ser conseguidos ao se levar em consideração não só o ponto da falha, como também a natureza desta, possibilitando que o algoritmo faça o reparo da solução, tendo como base ações simples como as apresentadas na Tabela 19 da Seção 5.6 .

Uma possibilidade que deve ser investigada é a incorporação da regra de reparo na regra de descarte. Assim, ao invés de descartarmos as soluções que não satisfaçam os critérios da regra de descarte, poderíamos aplicar regras de reparo nestas soluções, e mantê-las na população.

Experimentos precisam ser conduzidos para melhor caracterizar o comportamento do algoritmo em relação a esse mecanismo de descarte, considerando não só o tempo computacional ganho por não avaliar uma solução inviável, mas principalmente, analisando a implicação do uso dessa técnica na qualidade das soluções encontradas na população.

Outra possibilidade para o tratamento das restrições do problema é a incorporação das restrições do problema como novos objetivos a serem perseguidos, com os Algoritmos Genéticos multi-objetivos.

### **6.3 Hibridização**

Uma alternativa para melhorar o desempenho do algoritmo que deve ser considerada, é a hibridização com métodos de busca locais, visto que os Algoritmos Genéticos são bastante eficientes para identificar as regiões promissoras do espaço de busca, mas têm dificuldades de refinar as soluções, fazendo operações de busca numa vizinhança próxima de uma solução. Pelas características do próprio problema que tratamos, um simples deslocamento da programação da operação no tempo, por exemplo, podem possibilitar uma melhoria considerável no custo da solução. A integração desta heurística com outros métodos de busca locais, como por exemplo, a Pesquisa em Vizinhança Variável (VNS, *Variable Neighborhood Search*) [33], partindo de soluções identificadas pelo Algoritmo Genético, pode ser bastante promissora.

## Referências bibliográficas

- [1] Alander, J.T., 'On optimal population size of genetic algorithms', Proc. of CompEuro 92, Computer Systems and Software Engineering, 6th Annual European Computer Conference, pp. 65-70, 1992.
- [2] Bäck, T. and Hoffmeister, F. 'Extended Selection Mechanisms in Genetic Algorithms'. ICGA4, pp. 92-99, 1991
- [3] Back, T., Fogel, D., Michalewicz, Z. Handbook of evolutionary computation. Ed. Thomas Baeck, 1997.
- [4] Baker, J. E., 'Reducing bias and inefficiency in the selection Algorithms'. *Proc. of the 2nd Intl. Conference on Genetic Algorithms*, pp.14-21, 1987.
- [5] Beckwith, S.F. and Wong, K.P. 'A Genetic Algorithm Approach for Electric Pump Scheduling in Water Supply Systems', *IEEE International Conference on Evolutionary Computing*, Perth, IEEE Neural Networks Council, 1: pp 21-26, 1995.
- [6] Bush, M.D., Carter, J.N., 'Application of a Modified Genetic Algorithm to Parameter Estimation in the Petroleum Industry'. *Intelligent Engineering Systems through Artificial Neural Networks 6*, Dagli et. Al (Editores), ASME Press, NY, 397, 1996.
- [7] Cembrowicz, R. G., 'Water supply systems optimization for developing countries.', *Pipeline Systems*, B. Coulbeck and E. Evans, eds., Kluwer Academic Publishers, pp. 59-76, 1992.
- [8] De Jong, K. *Analysis of the behavior of a class of genetic adaptive systems*, Ph.D. Thesis, Department of Computer and Communications Sciences, University of Michigan, Ann Arbor, Mi, 1975.
- [9] Cantú-Paz, E., *Designing Efficient and Accurate Parallel Genetic Algorithms*, PhD thesis, Graduate College of the University of Illinois at Urbana Champaign, 1999.
- [10] Driedger, W., Controlling Positive Displacement Pumps. <http://www.driedger.ca> , 2000.
- [11] Eiben, A.E., Hinterding, R., Michalewicz, Z. 'Parameter control in evolutionary algorithms'. *IEEE Trans. on Evolutionary Computation*, pp. 124-141, 1999.
- [12] Foster, I., Kesseman, C. *Globus: A toolkit-based architecture. The Grid: Blueprint for a New Computing Infrastructure*. Editor Morgan Kaufmann. 1999.

- [13] Galvão, C., Valença, M. (org.) *Sistemas Inteligentes: Aplicações a Recursos Hídricos e Ciências Ambientais*. Ed. Universidade/UFRGS/ABRH, 1999.
- [14] Garey, M.R., Johnson, D.S. *Computers and intractability: a guide to the theory of NP-completeness*. Ed. W.H. Freeman and Company, 1979.
- [15] Goldberg, D. E., "Genetic and Evolutionary Algorithms Come of Age", *Communications of the ACM* , N. 3 Vol. 37, pp. 113-119, 1994.
- [16] Goldberg, D. E., 'Genetic Algorithms in search, optimization, and machine learning', Addison-Wesley Pub Co, 1989.
- [17] Goldberg, D.E. 'Sizing populations for serial and parallel genetic algorithms.' *Proceedings of third International Conference of Genetic Algorithms*, pp. 70-79, 1989.
- [18] Goldberg, D.E., *The Design of Innovation: Lessons from and for Competent Genetic Algorithms*, Série Kluwer em Genetic Algorithms and Evolutionary Computation, Vol. 7, 2002.
- [19] Gordon, V.S., Whitley, D. 'Serial and Parallel Genetic Algorithms as Function Optimizers'. *Proc. of the Fifth Intl. Conf. on Genetic Algorithms*, Morgan Kaufmann Publishers, pp. 177-183, 1993.
- [20] Grefenstette, J.J. 'Optimization of control parameters for genetic algorithms'. *IEEE Transactions on System, Man, and Cybernetics*, 16(1), pp 122-128, 1986.
- [21] Grefentette, J. J., *Foundations of Genetic Algorithms -2*, D. Whitley, ed., Morgan Kaufmann, pp. 75-91, 1993.
- [22] Hansen, P., Mladenovic, N. *Variable Neighborhood Search. Handbook of Metaheuristics*. Editores F. Glover e G. Kochenagen, Kuwer Academic Publishers, Dordrecht, 2003.
- [23] Haupt, R. L., Haupt, S. E. *Practical Genetic Algorithms*. Wiley-Interscience Publication, John Wiley & Sons, Inc., USA, 1998.
- [24] Holland, J. H.. *Adaptation in Natural and Artificial Systems*. University of Michigan Press, Ann Arbor, 1975.
- [25] Lansey et al. 'Optimal Pump Operations Considering Pump Swithes'. *Jornal of Water Resources Planning and Management*, vol. 120, N. 1, 1994.
- [26] León C., Martín, S., Elena, J. M., Luque, J.: 'Explore: Hybrid Expert System for Water Networks Management', *ASCE, Journal of Water Resources Planning and Management*. March/April 2000, pp. 65-74.

- [27] Louis, S., Johnson, J., ‘Solving Similar Problems using Genetic Algorithms and Case- Based Memory’, *Proc. of the 7th IEEE Int. Conf. on Genetic Algorithms - VII ICGA'97*, Morgan Kaufman, pp. 283-290, 1997.
- [28] Mackle, G. Savic, D., Walters, G. ‘Application of Genetic Algorithms to Pump Scheduling for Water Supply’, *GALESIA'95*, pp. 400-405, 1995.
- [29] Manual de tarifação da energia elétrica, PROCEL –Programa nacional de conservação de energia elétrica, 1ª Edição, maio/2001.
- [30] Mercer, R. E. ‘Adaptive Search using a reproductive meta-plan’. *Kybernets*, 7, 215-228, 1977.
- [31] Michalewicz, Z., Fogel, D. B. How to solve it: modern heuristics. Editora Springer-Verlag, 3ª edição, 2002.
- [32] Michalewicz, Z., “Genetic Algorithms, Numerical Optimization and Constraints”, *Proc. of the 6th Intl. Conference on Genetic Algorithms*, Pittsburgh, 1995, p. 151-158.
- [33] Mladenovic, N.;Hansen, P. *Variable Neighborhood Search, a Chapter of "Handbook of Metaheuristics"*. *Comps. in Opns. Res.* 24, 1097--1100 ,1997.
- [34] Olujic, Z. Compute friction factors fast for flow in pipes. *Chemical Engineering*, pp. 91-93, dezembro, 1981.
- [35] Ormsbee, I. E., Lansley, K.E. ‘Optimal Control of Water Supply Pumping Systems’. *Journal of Water Resources Planning and Management*, Vol. 120, N. 2, pp 237-252 1994.
- [36] Porto, R. M. *Hidráulica Básica*. Ed. EESC-USP, São Paulo, 1998.
- [37] Reis, L. F. R., Carrijo, I. B. ‘Extração de regras operacionais ótimas de sistemas de distribuição de água através de Algoritmos Genéticos multiobjetivo e aprendizado de máquina’. *Quarto Seminário Hispano-Brasileiro sobre Sistemas de Abastecimento Urbano de Água- SEREA*, João Pessoa, novembro, 2004
- [38] Romero, CE., Carter, J. ‘Using genetic algorithms for reservoir characterization’. *J. Petroleum Sci. and Eng.* 31, pp. 113-123, 2001.
- [39] Savic, D. A., and Walters, G. A. ‘Evolving Sustainable Water Networks’. *Hydrological Sciences*, 42(4), 549, 1997.
- [40] Savic, D. A., Walters, G. A., Randall-Smith, M., and Atkinson, R. M. ‘Large Water Distribution Systems Design Through Genetic Algorithm Optimisation’. *Proceedings of the ASCE Joint Conference on Water Resources Engineering and Water Resources Planning and Management*, American Society of Civil

- Engineers, Hotchkiss, R. H., and Glade, M., eds., proceedings published on CD, Minneapolis, Minnesota, 2000.
- [41] Schwab, M., D.A. Savic and G.A. Walters. Multi-Objective Genetic Algorithm for Pump Scheduling in Water Supply Systems, Centre For Systems And Control Engineering, Report No. 96/02, School of Engineering, University of Exeter, Exeter, United Kingdom, p.60, 1996.
- [42] Silva, A., T. Ohishi, A. Mendes, F. França e E. Delgado, 'Using Genetic Algorithm and Simplex Method to Stabilize an Oil Treatment Plant Inlet Flow'. *Proceedings do IPC2000 - International Pipeline Conference*, pp. 1459-1466, 2000.
- [43] Souza, B., Braz, H., Alves, H. 'Um Algoritmo Genético para configuração óptima de alimentadores de energia elétrica'. 6º. Simpósio Brasileiro de Automação Inteligente – SBAI, setembro de 2003.
- [44] Starkweather, T., Whitley, D., e Mathias, K. 'Optimization using Distributed Genetic Algorithms'. *Proceedings of Parallel Problem Solving from Nature I*, pp. 176-185, 1991.
- [45] Velez-Langs, O., Ossowski, S., 'Evolutionary Computation in Oil Industry: An Overview'. *International Joint Conference on Artificial Intelligence*, Second Workshop Intelligent Computing in the Petroleum Industry, pp. 51-55, 2003.
- [46] Water Research Center, United Kingdom. *Pump Scheduling in Water Supply*, Report TR232, Swindon, Wiltshire SN5 8YR, 1985.
- [47] Whitley, D. 'The GENITOR Algorithm and Selection Pressure: Why Rank-Based Allocation of Reproductive Trials is Best'. *Proceedings of the Third International Conference on Genetic Algorithms*, San Mateo, California, USA: Morgan Kaufmann Publishers, pp. 116-121, 1989.
- [48] Whitley, D. *A Genetic Algorithm Tutorial*. Technical Report CS-93-103, Department of Computer Science, Colorado State University, 1993.