

Universidade Estadual de Campinas  
Faculdade de Engenharia Elétrica e de Computação

**Otimização baseada em confiabilidade  
de planos de manutenção de sistemas de distribuição  
de energia elétrica**

**Autor: Paulo Alexandre Reis**  
**Orientador: Prof. Dr. Christiano Lyra Filho**  
**Co-orientador: Prof. Dr. Celso Cavellucci**

**Dissertação de Mestrado** apresentada à Faculdade de Engenharia Elétrica e de Computação como parte dos requisitos para obtenção do título de Mestre em Engenharia Elétrica. Área de concentração: **Au-  
tomação.**

**Banca Examinadora**

Luciana Salete Buriol, Dra. . . . Departamento de Informática Teórica/UFRGS  
Fernando José Von Zuben, Dr. . . . . . DCA/FEEC/Unicamp  
Anésio dos Santos Júnior, Dr. . . . . . DENSIS/FEEC/Unicamp

Campinas, SP  
13/04/2007

FICHA CATALOGRÁFICA ELABORADA PELA  
BIBLIOTECA DA ÁREA DE ENGENHARIA E ARQUITETURA - BAE - UNICAMP

Reis, Paulo Alexandre  
R277o Otimização baseada em confiabilidade de planos de  
manutenção de sistemas de distribuição de energia elétrica  
Paulo Alexandre Reis. – Campinas, SP: [s.n.], 2007.

Orientadores: Christiano Lyra Filho, Celso Cavellucci.  
Dissertação (Mestrado) - Universidade Estadual de Campinas,  
Faculdade de Engenharia Elétrica e de Computação.

1. Energia elétrica - Distribuição. 2. Controle preditivo.  
3. Otimização combinatória. 4. GRASP (Sistema operacional  
de computador). 5. Algoritmos genéticos. I. Lyra Filho,  
Christiano. II. Cavellucci, Celso. III. Universidade Estadual  
de Campinas. Faculdade de Engenharia Elétrica e de  
Computação. IV. Título.

Título em Inglês: Reliability based optimization of maintenance schedules for  
electric power distribution systems

Palavras-chave em Inglês: Electric power distribution, Preventive maintenance,  
Combinatorial optimization, GRASP, Genetic algorithms,  
Evolutionary algorithms

Área de concentração: Automação

Titulação: Mestre em Engenharia Elétrica

Banca examinadora: Luciana Salete Buriol, Fernando José Von Zuben, Anésio dos Santos  
Júnior

Data da defesa: 13/04/2007

Programa de Pós-Graduação: Engenharia Elétrica

## COMISSÃO JULGADORA - DISSERTAÇÃO DE MESTRADO

**Candidato:** Paulo Alexandre Reis

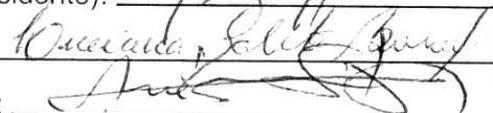
**Data da Defesa:** 13 de Abril de 2007

**Título da Dissertação:** “Otimização baseada em confiabilidade de planos de manutenção de sistemas de distribuição de energia elétrica”

Prof. Dr. Christiano Lyra Filho (Presidente):



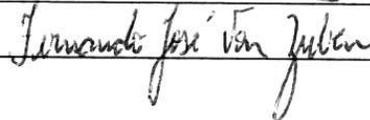
Profa. Dra. Luciana Salete Buriol:



Prof. Dr. Anésio dos Santos Júnior:



Prof. Dr. Fernando José Von Zuben:



# Resumo

Abordagens tradicionais de manutenção de sistemas de distribuição de energia elétrica se baseiam em ações realizadas periodicamente, ou programadas, de acordo com uma análise de necessidades e prioridades após inspeções. Embora essas abordagens tenham o objetivo de melhorar a confiabilidade dos sistemas, geralmente não há uma avaliação precisa do impacto das ações de manutenção na confiabilidade dos mesmos. O planejamento de manutenções pode ser realizado sob a perspectiva da confiabilidade com abordagens recentes chamadas *RCM* (*reliability centered maintenance* - manutenção baseada em confiabilidade). Essas abordagens procuram estabelecer uma ligação rigorosa entre manutenção e confiabilidade. Este trabalho propõe uma abordagem de manutenção baseada em confiabilidade com a perspectiva de encontrar as melhores estratégias para manutenções de redes de distribuição de energia elétrica; apresenta um modelo matemático e metodologia de otimização para encontrar as melhores estratégias de manutenções em um determinado horizonte de estudo. O problema formulado caracteriza-se como um problema de otimização combinatória com o objetivo de encontrar as ações de manutenção que minimizem os recursos utilizados em manutenções preventivas e corretivas, garantindo um nível de confiabilidade desejado para o sistema. O trabalho desenvolve duas alternativas para solução do problema: a primeira abordagem foi construída a partir do método *GRASP* (*greedy randomized adaptive search procedure*); a segunda abordagem é um método de computação evolutiva com busca local. Estudos de casos em redes de porte real avaliam as duas alternativas de solução. Os resultados realçam aspectos significativos da abordagem desenvolvida.

**Palavras-chave:** distribuição de energia elétrica, manutenção preventiva, otimização combinatória, GRASP, algoritmos genéticos, algoritmos evolutivos.

# Abstract

Traditional approaches to electric power distribution systems maintenance are based on activities performed at regular intervals, or scheduled after analysis of needs and priorities identified after inspections. Although these maintenance activities are carried out to improve reliability, usually such approaches do not explicitly consider the impact of maintenance activities on reliability. Maintenance planning can be guided by reliability with recent approaches known as RCM (reliability centered maintenance). A RCM approach tries to establish a rigorous link between maintenance and reliability. This work proposes a reliability centered maintenance approach to unveil the best maintenance schedule for electric power distribution networks; it presents a mathematical model and optimization methods to find the best maintenance schedule along a given planning horizon. The problem is formulated as a combinatorial optimization problem with the objective of finding the maintenance activities that minimize the resources allocated to preventive and corrective maintenance, making sure the system meets a reliability target. The work proposes two heuristic methods to solve the problem: the first one is a GRASP method (Greedy Randomized Adaptive Search Procedure); the other one is an evolutionary computation method with local search. Realistic case studies are used to evaluate both methods. The results highlight meaningful aspects of the proposed approaches.

**Keywords:** Electric power distribution; preventive maintenance, combinatorial optimization, GRASP, genetic algorithms, evolutionary algorithms.

*A minha avó, Maria*

# Agradecimentos

A Greice pela compreensão nesses dois anos e meio de ausência.

A minha família pela confiança e apoio em cada passo desde que os deixei em Jussara.

Aos meus orientadores, Christiano Lyra Filho e Celso Cavellucci... Apenas 30 meses foram pouco diante do que teria para aprender com vocês.

A Domingas e ao José Antonio que me acolheram em sua casa e me deram uma família em Campinas.

Aos amigos do DENSIS, dentre eles: Alana, Anibal, Edilson, José, Josi, Leonardo, Olinto e Vinícius que fizeram deste um ambiente descontraído e ao mesmo tempo de cooperação e muito trabalho.

Aos amigos Fabrício, Tiago e José Carlos pela companhia e amizade que ajudaram imensamente a me fazer me sentir em casa em Campinas.

À CAPES, pelo apoio financeiro.

# Sumário

<b>Lista de Abreviaturas</b>	<b>x</b>
<b>Lista de Símbolos</b>	<b>xi</b>
<b>1 Introdução</b>	<b>1</b>
<b>2 Planejamento de manutenção em sistemas de distribuição de energia elétrica</b>	<b>3</b>
2.1 Introdução . . . . .	3
2.2 Sistemas de distribuição de energia elétrica . . . . .	3
2.3 Principais alternativas para estratégias de manutenções . . . . .	6
2.3.1 Abordagens por otimização para o planejamento de manutenções . . . . .	8
2.4 Abordagens por otimização para manutenção em SDEE . . . . .	8
2.5 Comentários . . . . .	10
<b>3 Representação do problema</b>	<b>12</b>
3.1 Introdução . . . . .	12
3.2 Características do modelo . . . . .	12
3.2.1 O modelo de taxa de falha . . . . .	14
3.2.2 Ações preventivas . . . . .	15
3.2.3 A confiabilidade do sistema de distribuição . . . . .	16
3.2.4 Alternativas para a modelagem do problema . . . . .	17
3.3 Formulação matemática do problema . . . . .	18
3.4 Comentários . . . . .	21
<b>4 Método GRASP para abordagem do problema de manutenção de SDEE</b>	<b>22</b>
4.1 Introdução . . . . .	22
4.2 Problemas de otimização combinatória . . . . .	22
4.3 Métodos Heurísticos . . . . .	23

4.4	GRASP . . . . .	24
4.4.1	Heurística construtiva para o problema de planejamento de manutenção . . .	26
4.4.2	Busca Local para o problema de planejamento de manutenção . . . . .	32
4.5	Comentários . . . . .	35
<b>5</b>	<b>Algoritmo Genético para abordagem do problema de manutenção de SDEE</b>	<b>36</b>
5.1	Introdução . . . . .	36
5.2	Algoritmos Evolutivos . . . . .	36
5.3	Algoritmos Genéticos para o problema . . . . .	37
5.3.1	A representação dos indivíduos . . . . .	37
5.3.2	Avaliação dos indivíduos da população . . . . .	43
5.3.3	Inicialização da população . . . . .	44
5.3.4	Operadores de recombinação e mutação . . . . .	44
5.3.5	Atualização da população . . . . .	45
5.3.6	Hibridização . . . . .	45
5.3.7	Operador de seleção . . . . .	47
5.3.8	Critério de parada . . . . .	47
5.3.9	Parâmetros . . . . .	47
5.4	Comentários . . . . .	48
<b>6</b>	<b>Estudos de casos</b>	<b>49</b>
6.1	Introdução . . . . .	49
6.2	Casos de teste . . . . .	49
6.2.1	Dados da rede . . . . .	50
6.2.2	Dados de manutenção . . . . .	51
6.3	Experimentos realizados . . . . .	57
6.3.1	Experimento 1: Penalização da manutenção corretiva . . . . .	58
6.3.2	Experimento 2: Horizonte de planejamento . . . . .	59
6.3.3	Comparação entre os métodos . . . . .	63
6.4	Comentários . . . . .	67
<b>7</b>	<b>Conclusões e Propostas de Trabalhos Futuros</b>	<b>68</b>

# Lista de Abreviaturas

<i>AE</i>	- algoritmo evolutivo
<i>AG</i>	- algoritmo genético
<i>BL</i>	- busca local
<i>CBC</i>	- custo devido à baixa confiabilidade
<i>CMC</i>	- custo de manutenção corretiva
<i>CMP</i>	- custo de manutenção preventiva
<i>DEC</i>	- duração equivalente de interrupção por consumidor
<i>FEC</i>	- frequência equivalente de interrupção por consumidor
<i>GRASP</i>	- <i>greedy randomized adaptive search procedure</i>
<i>HP</i>	- número de anos do horizonte de planejamento
<i>MTTF</i>	- <i>mean time to failure</i>
<i>MTTR</i>	- <i>mean time to repair</i>
<i>RCL</i>	- <i>restricted candidate list</i> - lista restrita de candidatos
<i>RCM</i>	- <i>reliability centered maintenance</i> - manutenção baseada em confiabilidade
<i>SDEE</i>	- Sistemas de distribuição de energia elétrica

# Lista de Símbolos

$\lambda_e^t$	- taxa de falha do elemento $e$ no período $t$
$\lambda_e^{(t-1)}$	- taxa de falha do elemento $e$ no período anterior (ou a taxa de falha inicial para $t = 1$ )
$k_e$	- tipo do elemento $e$ (transformador, religador, etc)
$N_{k_e}$	- conjunto de ações (níveis de ações) preventivas que podem ser programadas para o componente de tipo $k_e$
$\delta_{k_e n}$	- multiplicador de taxa de falha do componente de tipo $k_e$ para a ação de nível $n$
$x_{en}^t$	- variável de decisão. Indica se foi programada uma ação de manutenção nível $n$ para o elemento $e$ no período $t$ ( $x_{en}^t = 1$ ), ou não ( $x_{en}^t = 0$ )
$FEC^t$	- valor estimado para o FEC no período $t$
$S$	- conjunto de seções da rede
$\lambda_s^t$	- taxa de falha da seção $s$ no período $t$
$N_s$	- número de consumidores da seção $s$
$NT$	- número total de consumidores da rede
$E_s$	- representa o conjunto formado por todos os elementos sujeitos à manutenção na seção $s$
$\lambda_s$	- taxa de falha base da seção $s$ (constante que representa a parcela da taxa de falha associada aos fatores não incorporados no modelo)
$E$	- conjunto de elementos sujeitos a manutenções (transformadores, religadores, chaves fusíveis e seções de condutores)
$FEC_{perm}$	- valor máximo permitido para o FEC
$p_{(k_e)n}$	- custo da ação preventiva de nível $n$ no elemento de tipo $k_e$
$c_{(k_e)}$	- custo de manutenção corretiva do elemento de tipo $k_e$
$HP$	- horizonte de planejamento adotado para o problema
$FG_e$	- função gulosa utilizada na heurística construtiva (avalia o custo/benefício de aumentar o nível de manutenção do elemento $e$ )
$FG_e^{min}$	- menor valor de $FG_e$ dentre todos os elementos
$FG_e^{max}$	- maior valor de $FG_e$ dentre todos os elementos
$\Delta FEC_{e,atual}$	- contribuição atual do elemento $e$ para com o $FEC$ total do sistema
$\Delta FEC_{e,minimo}$	- contribuição do elemento $e$ para com o $FEC$ no maior nível de manutenção
$custo_{e,maximo}$	- custo do maior nível de manutenção do elemento $e$
$custo_{e,atual}$	- custo do nível atual de manutenção do elemento $e$

$\Delta FEC_e^t$	- contribuição do elemento $e$ para com o $FEC$ do sistema no período $t$
$CMC_e^t$	- custo de manutenção corretiva do elemento $e$ no período $t$
$P_e$	- probabilidade de escolha do elemento $e$ durante o processo de decodificação no $AG$
$inv_e$	- investimento destinado ao elemento $e$ no genótipo de uma solução no $AG$
$invJaAlocado_e$	- investimento já alocado ao elemento $e$ durante o processo de decodificação de uma solução no $AG$
$I_e^i$	- investimento em manutenção associado ao elemento $e$ do indivíduo $i$ no $AG$
$\alpha$	- parâmetro que define o tamanho da lista $RCL$ na heurística construtiva do $GRASP$ e do $AG$
$\rho$	- parâmetro que define a taxa de mutação no $AG$
$\epsilon$	- parâmetro que define o progresso mínimo do critério de parada no $AG$

# Capítulo 1

## Introdução

Os sistemas de potência compõem-se da geração, transmissão e distribuição, responsáveis, respectivamente, pela conversão de uma fonte primária de energia em eletricidade, pelo transporte da energia gerada até os centros consumidores e pela distribuição da mesma aos pontos de consumo. A energia deve ser gerada, transmitida e entregue para atender as demandas com níveis de qualidade e confiabilidade especificados. A confiabilidade dos sistemas de potência pode ser comprometida devido à ocorrência de falhas em seus componentes. Na ocorrência de falhas, os estados dos componentes da rede podem ser restabelecidos às condições normais de funcionamento através da realização de reparos ou substituições de elementos danificados. Estas ações são chamadas de *manutenções corretivas* (Endrenyi et al., 2001). Alternativamente, as falhas resultantes do processo de deterioração dos componentes podem ser tratadas de forma preventiva, através de ações chamadas *manutenções preventivas*. Essas ações têm o objetivo de interferir no processo de deterioração, reduzindo ou pelo menos retardando as falhas dos elementos do sistema (Endrenyi et al., 2001).

A mudança na percepção dos consumidores quanto a serviços de qualidade, a crescente demanda por serviços de eletricidade ininterruptos e a fiscalização de metas de qualidade impostas pelos órgãos reguladores sugerem investimentos em ações de manutenção para assegurar a confiabilidade do sistema de distribuição de energia elétrica. Essas ações devem ser selecionadas entre aquelas que, com o menor investimento possível, proporcionam o maior impacto na confiabilidade do sistema.

As abordagens tradicionais de manutenção se baseiam em ações realizadas periodicamente, ou programadas de acordo com uma análise de necessidades e prioridades após inspeções. Em tais abordagens, geralmente não há uma avaliação do impacto das ações de manutenção na confiabilidade do sistema. O planejamento de manutenção pode ser realizado sob a perspectiva da confiabilidade em abordagens chamadas *RCM* (*reliability centered maintenance* – manutenção baseada em confiabilidade). Essas abordagens procuram estabelecer uma ligação entre manutenção e confiabilidade. Em outras palavras, permitem avaliar a confiabilidade do sistema com a adoção de um plano de manuten-

ção. A possibilidade de avaliar os planos de manutenção permite a comparação entre as soluções e, assim, a adoção de métodos de otimização para resolução do problema.

O presente trabalho aborda o problema de planejamento de ações de manutenção preventiva em equipamentos e condutores de sistemas de distribuição de energia elétrica. Seus objetivos são formular um modelo de otimização para o problema baseado nas alternativas da literatura e propor métodos para resolver este modelo em casos de teste construídos sobre dados de redes de porte real. O trabalho está organizado em sete capítulos, descritos resumidamente a seguir.

O Capítulo 2 apresenta o sistema de distribuição e as principais abordagens para tratar o problema de manutenção. Em seguida, são discutidos alguns trabalhos sobre abordagens para o problema de manutenção de sistemas de distribuição de energia elétrica.

O Capítulo 3 apresenta o modelo adotado para estimar a confiabilidade dos elementos do sistema e o parâmetro adotado para representar a confiabilidade do sistema de distribuição como um todo. Ao final do capítulo, o problema de manutenção de sistemas de distribuição é formulado matematicamente como um problema de otimização combinatória, tendo como objetivo minimizar custos com manutenção, sujeito a uma restrição que garante um nível mínimo de confiabilidade para os sistemas.

O capítulo seguinte à formulação do problema comenta a complexidade combinatória do modelo formulado e cita métodos heurísticos como uma alternativa para o seu tratamento. Este capítulo descreve a abordagem pelo método *GRASP* (*greedy randomized adaptive search procedure*) e apresenta a heurística construtiva e a busca local desenvolvidas para procurar soluções ótimas (ou próximas à ótima) para o modelo apresentado no capítulo anterior.

O Capítulo 5 apresenta o desenvolvimento da abordagem por Algoritmos Genéticos, alternativa ao método *GRASP* na busca de soluções ótimas para o problema de manutenção. Como aspectos importantes do Algoritmo Genético desenvolvido estão a representação dos indivíduos através de vetores reais, a utilização de um procedimento de decodificação para mapear um indivíduo para uma solução do problema, a inicialização da população por uma heurística construtiva e a incorporação de uma heurística de melhoramento para auxiliar o método na exploração local do espaço de busca.

No Capítulo 6 são apresentados três estudos de casos construídos a partir de dados de redes reais de grande porte. Os estudos de casos permitem avaliar a formulação para o problema de manutenção e os métodos desenvolvidos no trabalho. Em particular, os experimentos realizados permitem avaliar dois aspectos do modelo e comparar os dois métodos desenvolvidos para sua resolução.

Por fim, no Capítulo 7 são discutidas as contribuições do trabalho para o problema de planejamento de manutenção em sistemas de distribuição de energia elétrica e são levantados alguns pontos que poderiam ser abordados em trabalhos futuros, dando prosseguimento ao estudo.

## **Capítulo 2**

# **Planejamento de manutenção em sistemas de distribuição de energia elétrica**

### **2.1 Introdução**

Neste capítulo será discutida a necessidade da realização de manutenções para impedir o comprometimento excessivo na qualidade dos serviços, particularmente em sistemas de distribuição de energia elétrica. Parte da literatura relata a programação de manutenções em intervalos regulares baseado em conhecimento empírico. Estas e outras abordagens para o tratamento do problema serão descritas a seguir, em especial aquelas baseadas em modelos matemáticos. Esses modelos matemáticos permitem quantificar a ligação entre manutenções e confiabilidade, possibilitando otimização dos benefícios com planos de manutenção.

### **2.2 Sistemas de distribuição de energia elétrica**

Os sistemas de potência (ou sistemas de energia elétrica) compreendem desde a conversão de outras fontes de energia em energia elétrica até a alimentação do consumidor final. Os sistemas de potência podem ser divididos em três subsistemas: geração, transmissão e distribuição.

O sistema de geração tem o objetivo de converter uma fonte primária de energia em eletricidade. A eletricidade gerada é então transportada aos centros de consumo pelo sistema de transmissão. O sistema de transmissão tem início nas subestações elevadoras que aumentam os valores de tensões para reduzir perdas e viabilizar o transporte de grandes quantidades de energia a grandes distâncias. Por questões de segurança e características das aplicações, próximo aos pontos de consumo, nas subestações abaixadoras, os valores de tensão da energia são reduzidos. As subestações normalmente marcam o início do sistema de distribuição, que faz a ligação final com os pontos de consumo.

Os sistemas de distribuição de energia elétrica (*SDEE*) são compostos de alimentadores e equipamentos com diversas finalidades. Os alimentadores são formados por condutores e equipamentos associados, que partem das subestações de distribuição<sup>1</sup> e transportam a energia até os consumidores. Os equipamentos podem ser classificados de acordo com suas funções em: equipamentos de manobra, proteção, correção e transformação (Bueno, 2005).

Os equipamentos de manobra (chaves a óleo, chaves facas) permitem a transferência de cargas através da abertura e fechamento de circuitos. Os equipamentos de proteção são utilizados para proteger os sistemas de distribuição na ocorrência de falhas; exemplos destes equipamentos são disjuntores, chaves-fusíveis, religadores e pára-raios. A finalidade dos equipamentos de correção é corrigir grandezas com níveis inadequados — por exemplo, tensões e fatores de potência, no caso dos reguladores de tensão e dos bancos de capacitores, respectivamente. Como equipamentos de transformação, temos os transformadores, que abaixam a tensão fornecida pelas subestações para níveis dos consumidores comuns (Bueno, 2005).

Neste ponto, é importante ressaltar a função dos equipamentos de proteção, pois estes definem a representação do *SDEE* adotada em alguns trabalhos recentes sobre o problema de manutenção (Kuntz et al., 2002; Sittithumwat et al., 2004) e, em particular, a representação adotada neste trabalho.

Os sistemas de distribuição, normalmente, são radiais e, por essa razão, suscetíveis a interrupções devido a um único evento (Billinton e Billinton, 1989). Na ocorrência de uma falha, essa pode se propagar, causando a interrupção no fornecimento de energia em grande parte da rede. Alguns equipamentos de proteção<sup>2</sup> têm a função de isolar as falhas - atuam na presença de falhas, seccionando a rede para isolar a seção com defeito e impedir o comprometimento do fornecimento de energia ao restante da rede.

As seções agrupam os elementos que podem causar o acionamento de um mesmo equipamento de proteção. Pela característica radial das redes, o acionamento de um equipamento de proteção qualquer causa a perda do fornecimento de toda a subrede a partir deste. Assim, os componentes da rede mais próximos das subestações são mais importantes do que aqueles mais distantes das subestações, pois suas falhas têm impacto em um número maior de consumidores.

A Fig. 2.1 apresenta uma representação simplificada de uma rede de distribuição com dois alimentadores. A rede possui quatro equipamentos de proteção<sup>3</sup> que dividem a mesma nas seções B, C, D e E. Uma outra seção, a seção A, é considerada para representar o trecho da rede que liga a subestação às demais seções. Na Fig. 2.1 as linhas pontilhadas delimitam as seções, apresentadas explicitamente na Fig. 2.2.

---

<sup>1</sup>Neste trabalho chamaremos apenas de subestações quando no contexto utilizado não for necessário especificá-la.

<sup>2</sup>No trabalho chamaremos tais equipamentos simplesmente de equipamentos de proteção, mas ao usarmos o termo estaremos nos referindo exclusivamente àqueles com função de isolar falhas: religadores, chaves-fusíveis e disjuntores.

<sup>3</sup>Na rede representada na Fig. 2.1 os equipamentos de proteção correspondem a religadores ou chaves fusíveis

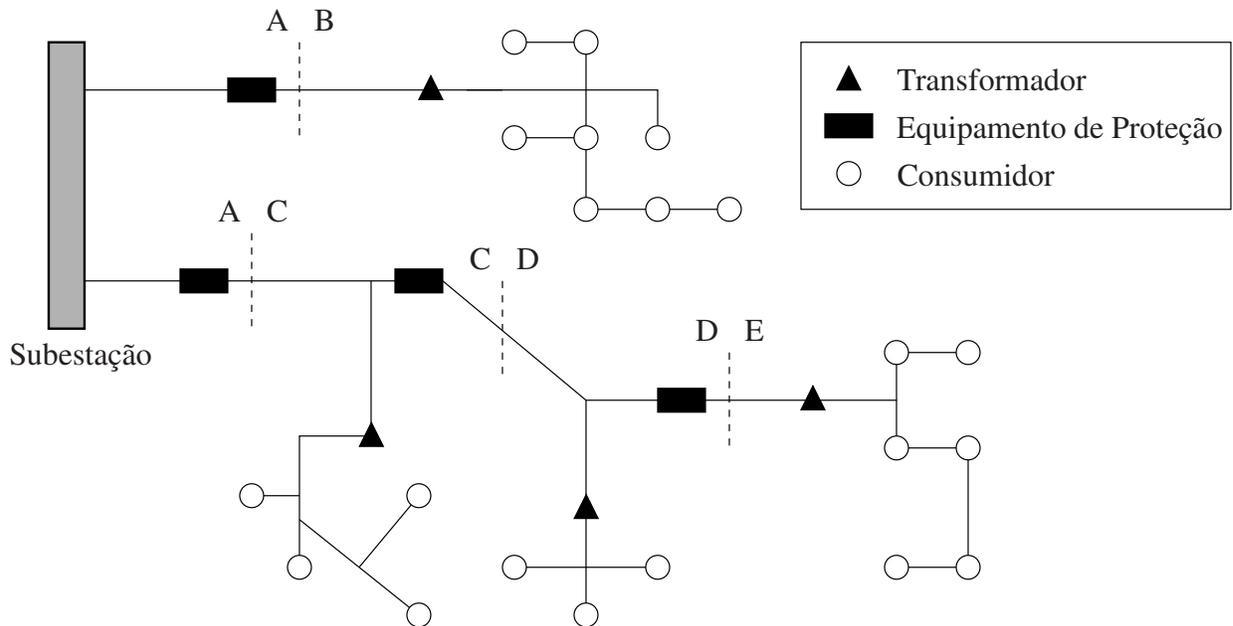


Fig. 2.1: Representação de rede de distribuição

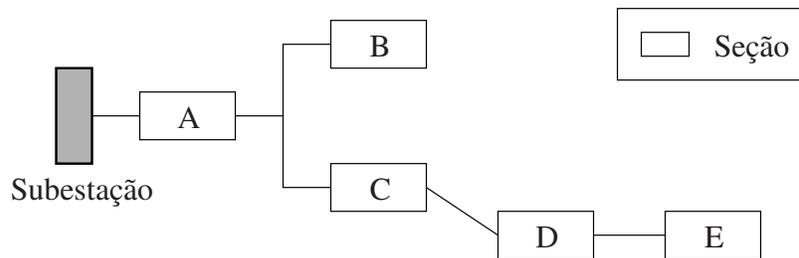


Fig. 2.2: Divisão da rede de distribuição da Fig. 2.1 em seções

A representação do sistema de distribuição em seções é utilizada em alguns trabalhos sobre manutenção para avaliar o impacto relativo na confiabilidade da rede, levando em consideração o número de consumidores que poderiam ser afetados por falhas em cada um dos elementos (Sittithumwat et al., 2004; Kuntz et al., 2002). Esta representação é uma alternativa em abordagens para o problema que buscam alocar recursos de manutenção com foco na confiabilidade da rede.

Na próxima seção, serão apresentadas as principais abordagens para modelar o problema. Serão discutidas tanto aquelas abordagens que tratam os elementos individualmente como as que consideram a dependência existente entre eles para avaliar o impacto das ações preventivas no sistema como um todo.

## 2.3 Principais alternativas para estratégias de manutenções

Por definição, falha é a perda da habilidade de um elemento realizar uma função requerida (Endrenyi et al., 2001). Alguns tipos de falhas são resultado do processo de deterioração ao qual os elementos estão sujeitos, outras são resultado de eventos que independem do sistema e não podem ser previstos, por exemplo, perda de fornecimento pela rede de transmissão, quedas de raios na rede ou acidentes de automóveis em postes do sistema. Ambos os tipos de falhas podem ser tratados de forma corretiva, através de ações chamadas de manutenções corretivas. Alternativamente, as falhas resultantes da deterioração dos elementos podem ser tratadas de forma preventiva através de ações chamadas de manutenções preventivas ou simplesmente manutenções. Essas manutenções são ações realizadas em elementos em operação para interferir no processo de deterioração, reduzindo ou ao menos retardando as falhas.

No sistema de distribuição, no geral, os esforços de manutenção são destinados aos equipamentos (transformadores, religadores, etc) para interferir em sua deterioração e em podas de árvores ao longo dos condutores para reduzir contatos de árvores com a rede. Os principais fatores que influenciam as falhas em sistemas de distribuição são a idade dos equipamentos e histórico de uso e de manutenções e as características e densidade das árvores próximas à rede, além das condições climáticas da região que interferem no crescimento destas árvores.

Encontram-se na literatura algumas alternativas de abordagens para o problema de manutenção. Apesar da variedade de modelos para o problema, estes podem ser classificados de acordo com algumas políticas de manutenção na qual são baseados. Valdez-Flores e Feldman (1989) e Wang (2002) apresentam uma revisão de modelos para o problema de manutenção, organizando-os em termos das políticas de manutenção.

No que se refere ao sistema de distribuição, as políticas mais comuns encontradas na literatura são: manutenções programadas, manutenções preditivas e manutenções centradas na confiabilidade

(Endrenyi et al., 2001).

Manutenção programada é uma política simples para a programação de manutenções, consistindo na definição de intervalos regulares para a execução das atividades. Esses intervalos são definidos de acordo com a experiência, sendo ajustados normalmente por tentativa e erro. Tal política pode ser ineficiente pelo tratamento precário da informação para alocação de recursos (Endrenyi et al., 2001).

As manutenções podem estar baseadas também em uma análise de necessidades e prioridades, sobre dados obtidos por inspeções periódicas ou contínuas. Esta alternativa é chamada de manutenção preditiva (Endrenyi et al., 2001). Neste caso, não se definem programas rígidos de manutenção; as informações obtidas pelas inspeções permitem a utilização dos recursos em ações consideradas necessárias.

Uma outra política para o problema de manutenção é aquela com o foco na confiabilidade do sistema. As ações são programadas não apenas pela avaliação das necessidades, mas também pelo efeito na confiabilidade do sistema.

Nesse ponto, vale ressaltar a estratégia *RCM*. A *RCM* (*reliability centered maintenance* — manutenção centrada na confiabilidade) é uma estratégia sistemática para reduzir os custos de manutenção e aumentar a confiabilidade dos sistemas (Rausand, 1998). Esses objetivos são atingidos por evitar-se ou remover-se ações não identificadas como estritamente necessárias e pelo direcionamento dos recursos em ações mais efetivas, de acordo com a política centrada na confiabilidade.

A *RCM* pode ser caracterizada simplificada pelos seguintes passos:

1. Estudo do sistema e identificação dos elementos críticos;
2. Definição das ações a serem tomadas;
3. Determinação dos intervalos entre manutenções.

O primeiro passo corresponde a um levantamento dos componentes do sistema e suas funções, seguido de coleta e análise de dados para identificar os elementos críticos (por exemplo, com alto impacto na confiabilidade do sistema, com alto custo de reparo ou com alta taxa de falha). Os dados utilizados nessa fase podem ser obtidos através de inspeções, modelos de falhas e também pela realimentação da própria *RCM*.

No passo seguinte, são investigados os efeitos das possíveis ações a serem programadas para determinar quais serão adotadas. Como resultado dessa fase, são definidas as ações a serem utilizadas para cada classe de elementos, existindo a possibilidade de manter determinado conjunto de elementos sem manutenção, devido ao baixo impacto na confiabilidade do sistema.

O último passo da *RCM* consiste em programar as manutenções, ou seja, fazer o planejamento de quando executar as ações determinadas no passo anterior. Segundo Rausand (1998), na prática

muitas vezes acaba-se definindo os intervalos para manutenção com base nas recomendações dos fabricantes dos equipamentos e nas experiências passadas, resultando muitas vezes em manutenções mais freqüentes do que o necessário para atingir determinados níveis de confiabilidade. Na busca por programas de manutenção eficientes, pode-se utilizar abordagens por otimização para a escolha dos intervalos entre manutenções.

### 2.3.1 Abordagens por otimização para o planejamento de manutenções

Para uma completa avaliação de um programa de manutenção é necessário medir seu impacto no processo de deterioração dos elementos. A modelagem do impacto das ações de manutenção programadas sobre a confiabilidade dos elementos, em conjunto com a modelagem do processo de deterioração dos mesmos, fazem a ligação entre manutenção e confiabilidade, inexistente nas abordagens anteriores (Endrenyi et al., 2001). Essa ligação permite o tratamento do planejamento de manutenção como um problema de otimização.

A avaliação dos planos de manutenção consiste em calcular o custo total das ações programadas e verificar a confiabilidade do sistema com a execução dessas ações. A adoção de um modelo matemático viabiliza a avaliação dos planos de manutenção, ao tornar possível estimar seu impacto na confiabilidade. Sendo possível a avaliação dos planos de manutenção, pode-se comparar soluções o que permite a adoção de métodos de busca para resolução do problema.

Na próxima seção, é apresentada uma revisão bibliográfica das principais referências para a construção da abordagem de manutenção em *SDEE* adotada neste trabalho, com foco na otimização de planos de manutenção.

## 2.4 Abordagens por otimização para manutenção em SDEE

Grande parte dos trabalhos sobre manutenção de sistemas de potência se concentra na geração e transmissão (Mohanta et al., 2004; Yang, 2004; Sergaki e Kalaitzakis, 2002; Dahal et al., 1999; El-Amin et al., 2000; Langdon e Treleaven, 1997; Kralj e Petrovic, 1995; Marwali e Shahidehpour, 1998; Yellen et al., 1992). Falhas na geração e transmissão geralmente são mais críticas do que falhas no sistema de distribuição, pois podem provocar a perda de fornecimento em regiões maiores. Entretanto, recentemente o problema de manutenção em *SDEE* ganhou atenção, devido à crescente necessidade por serviços de eletricidade ininterruptos e pela fiscalização e metas de qualidade impostas por órgãos reguladores.

Em seguida, são analisados alguns modelos para o problema de planejamento de manutenção em *SDEE*. Um aspecto que pode ser usado para classificar os modelos a seguir é a relação entre os

componentes do sistema. Em sistemas constituídos de vários componentes, onde não há dependência econômica de falha ou estrutural, as decisões de manutenção podem ser independentes. Contudo, se existe dependência, o programa de manutenção ótimo deve considerar o conjunto de componentes e, portanto, as decisões de manutenção não devem ser independentes (Wang, 2002).

Endrenyi et al. (1998) apresentam um modelo probabilístico para o processo de deterioração de elementos de *SDEE* através de estados discretos. O modelo utiliza inspeções periódicas para verificar o estado de deterioração em que o elemento se encontra. A escolha de planos de manutenção é realizada por um método probabilístico que avalia o impacto das variáveis de decisão, podendo haver uma análise de sensibilidade em relação a essas variáveis para buscar melhores soluções. O modelo programa ações de manutenções independentemente, ou seja, sem considerar a dependência estrutural e econômica existente entre os elementos. A dependência estrutural se dá porque uma falha em um componente pode comprometer o fornecimento em toda a seção da rede<sup>4</sup>. A dependência econômica existe na disputa entre os componentes sobre recursos limitados destinados a manutenções.

Uma política mais elaborada para o planejamento de manutenções deve levar em consideração as dependências existentes entre os elementos. Uma alternativa para isso é adotar para o tratamento do problema a política de manutenção com foco na confiabilidade (*RCM*) como os modelos de otimização apresentados por Sittithumwat et al. (2004) e Kuntz et al. (2002).

Sittithumwat et al. (2004) representa em um modelo determinístico as condições dos elementos do sistema de distribuição pela sua taxa de falha (probabilidade de falha). A confiabilidade do sistema é avaliada por estimativa do valor de um índice de continuidade no fornecimento. O objetivo do modelo de otimização é maximizar a confiabilidade do SDEE, impondo restrições quanto ao investimento e a mão-de-obra disponíveis para manutenções. O processo de deterioração dos elementos e o impacto das ações preventivas são representadas por multiplicadores de taxas de falha, interpretados como a mudança esperada na taxa de falha de um elemento após o período de um ano. Cada ação de manutenção (intensiva, mínima ou nenhuma manutenção) tem um valor de multiplicador de taxa de falha que afeta diferentemente a variação anual da taxa de falha dos elementos. As variáveis do modelo (taxas de falha e multiplicadores de taxas de falha) foram descritos por números nebulosos, para incorporar a incerteza ou inexatidão em seus valores. Foram consideradas no modelo ações referentes a manutenções preventivas em equipamentos e podas de árvores em seções da rede. Um método de programação inteira foi utilizado para resolver um problema com 13 elementos sujeitos à manutenção.

Como alternativa ao modelo apresentado por Sittithumwat et al. (2004), Radmer et al. (2002), Kuntz et al. (2002) e Mohanta et al. (2004) utilizam modelos de predição para estimar a taxa de falha dos elementos. De forma geral, nesses modelos, fatores que influenciam a deterioração dos elementos

---

<sup>4</sup>A seção da rede é definida pelos equipamentos de proteção como discutido na Seção 2.2

são usados para estimar suas condições. Os modelos de predição são como funções (Fig. 2.3), que apresentam uma estimativa da variação na taxa de falha (dados de saída) de acordo com valores para os fatores considerados (dados de entrada).

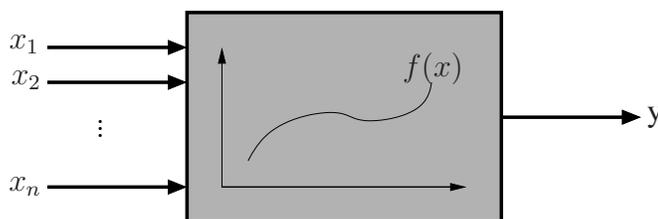


Fig. 2.3: Modelos de predição

Radmer et al. (2002) utilizam redes neurais como modelo de predição da taxa de falha em seções da rede, devido a contatos de árvores com a rede. Foram considerados sete fatores para a predição, incluindo o tempo desde a última poda e as densidades de árvores na seção, os demais fatores representam chuvas, velocidade do vento e temperatura. Este modelo de predição serviu como base para o modelo de otimização proposto em Kuntz et al. (2002). Em Kuntz et al. (2002), o modelo de otimização adotado usa a ponderação de dois índices de continuidade no fornecimento como critério de confiabilidade. O problema foi modelado para minimizar os custos de manutenção com restrição de confiabilidade e para maximizar a confiabilidade com restrição de custo. Em ambos os modelos foi considerada uma restrição adicional referente à mão de obra disponível para executar as ações de manutenção. Para resolver o problema de planejamento de manutenção foram testadas três alternativas heurísticas, os melhores resultados foram obtidos com um algoritmo genético seguido de um método *hill-climbing*.

Vale ressaltar que o presente trabalho também apresenta um algoritmo genético em conjunto com um método de exploração local para o problema de planejamento de manutenção em *SDEE*. Entretanto, no trabalho explora-se não apenas podas de árvores, como em Kuntz et al. (2002), mas também manutenções em equipamentos sujeitos à deterioração.

Em um outro trabalho, onde também foi utilizado um modelo de predição para o problema de manutenção, Mohanta et al. (2004) estimam o *MTTF* (*mean time to failure*) e o *MTTR* (*mean time to repair*) de equipamentos no sistema de geração através de um método com variáveis nebulosas (*fuzzy*). Utilizou-se três fatores para a predição do *MTTF* e o *MTTR*: idade do equipamento, qualidade da última manutenção e tempo desde a última manutenção. A predição foi feita por um sistema com regras nebulosas definidas através do conhecimento de especialistas em manutenção.

## 2.5 Comentários

Este capítulo descreveu os sistemas de distribuição, localizando-os no sistema de potência. Foram apresentados os componentes principais dos sistemas de distribuição, em especial, aqueles equipamentos de proteção que atuam na ocorrência de falhas para seu isolamento e para evitar a propagação das falhas ao restante da rede. Estes equipamentos são importantes na divisão da rede adotada na formulação do problema, apresentada no capítulo seguinte.

Discutiu-se também neste capítulo, as principais alternativas para o problema de manutenção em *SDEE*. Dentre elas, destacamos a *RCM*. As demais alternativas discutidas têm como objetivo a definição de quando programar as ações de manutenção. Já a *RCM* compreende um estudo detalhado e contínuo do sistema para identificação de ações efetivas quanto ao aumento de sua confiabilidade, para só então, programar quando realizar manutenções. A programação das ações preventivas corresponde apenas a uma fase da *RCM*, onde se pode inclusive adotar alternativas como as demais discutidas no capítulo.

A *RCM* pode ser uma importante ferramenta na busca por garantir o máximo de confiabilidade para o sistema. Entretanto, frisamos que neste trabalho o foco é dirigido para a programação das ações de manutenção, considerando que essas ações são previamente conhecidas. A *RCM* é importante na contextualização do trabalho por apresentar a política baseada em confiabilidade, adotada como orientação para o planejamento de manutenções.

A política baseada em confiabilidade é explorada neste trabalho através de um modelo de otimização. O tratamento do planejamento de manutenções como um problema de otimização é viabilizado pela incorporação de um modelo para avaliar a confiabilidade do sistema com a adoção de um plano de manutenção. No geral, esses modelos utilizam a divisão da rede em seções caracterizadas pelos equipamentos de proteção para estimar índices da continuidade no fornecimento de energia, utilizados nos modelos para indicar a confiabilidade da rede.

Os princípios presentes nos modelos de otimização foram utilizados neste trabalho como será discutido no próximo capítulo. Partimos da hipótese de que as ações de manutenções preventivas são conhecidas, e tratamos da programação dessas ações dentro do horizonte de planejamento.

# Capítulo 3

## Representação do problema

### 3.1 Introdução

Neste capítulo, serão descritas as características do modelo adotado para o planejamento de manutenções em *SDEE*. Dentre os pontos principais do modelo estão: o conhecimento sobre as ações preventivas adotadas, sobre os parâmetros utilizados para representar a confiabilidade do sistema e de seus elementos individuais, sobre a estratégia utilizada para estimar o processo de deterioração dos elementos e o impacto das ações preventivas neste processo. Outro aspecto importante é a escolha da alternativa para abordar os dois objetivos conflitantes do problema: reduzir custos e aumentar a confiabilidade. Ao final do capítulo, é apresentado o modelo matemático do problema, que leva a um problema de otimização combinatória, formulado a partir dos pontos discutidos no capítulo.

### 3.2 Características do modelo

Em abordagens tradicionais, geralmente a programação de manutenções é feita por atividades pré-definidas, executadas em intervalos regulares (Endrenyi et al., 1998). Desse modo, não se avalia os efeitos das manutenções na confiabilidade do sistema. Sem levar em consideração a ligação entre manutenção e confiabilidade, as possibilidades de realizar predições sobre os efeitos das manutenções e de realizar otimizações são muito limitadas (Endrenyi et al., 2001).

Na abordagem proposta para o problema utilizamos dois modelos: o modelo de planejamento de manutenção e o modelo de taxa de falha, conforme apresentado na Fig. 3.1. O modelo de planejamento de manutenção corresponde ao modelo de otimização do problema em questão, discutido na Seção 3.3 — Formulação matemática do problema. O modelo de taxa de falha é um componente utilizado no modelo de otimização para avaliar os planos de manutenção, possibilitando o processo de busca discutido na Seção 3.2.1.

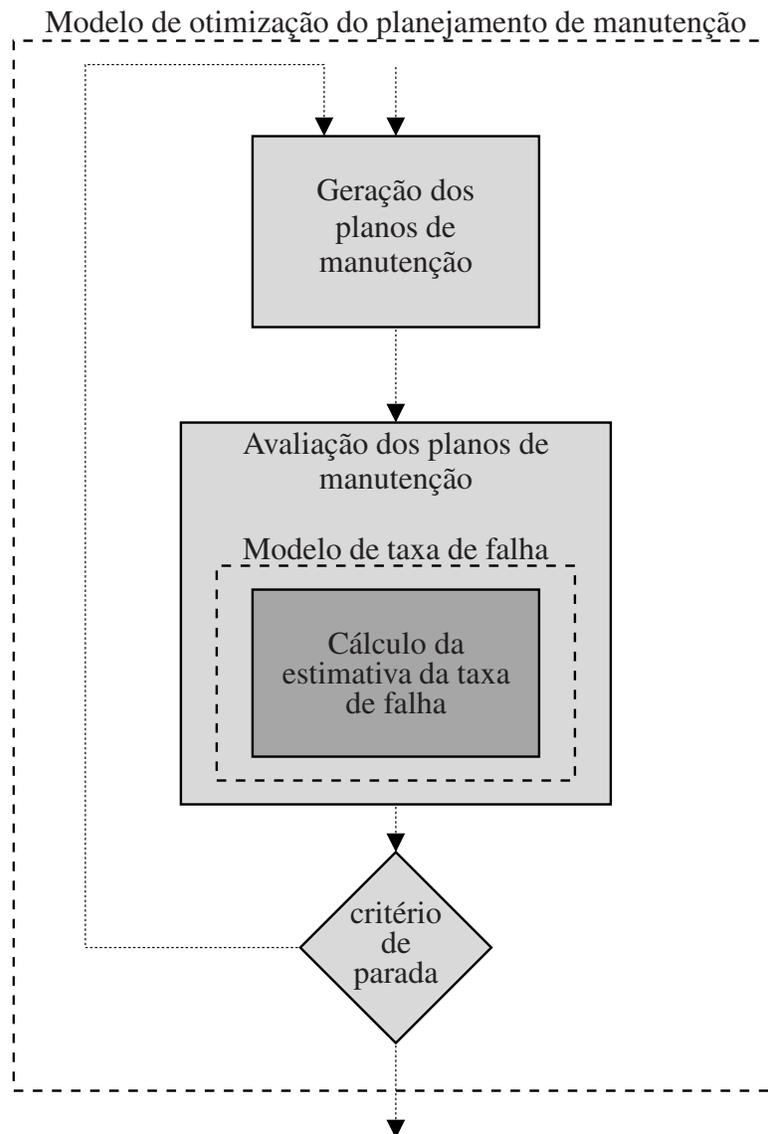


Fig. 3.1: Representação da relação entre o modelo de otimização e o modelo de taxa de falha para o problema de planejamento de manutenção

Como apresentado na Fig. 3.1, o modelo de otimização é um processo de busca iterativo. Em cada iteração, novas soluções são geradas e avaliadas. O processo se repete até atingir um determinado critério de parada estabelecido, de acordo com o método adotado para resolver o modelo. É importante ressaltar a função do modelo de taxa de falha, utilizado na fase de avaliação das soluções, sem o qual não seria possível realizar otimização.

### 3.2.1 O modelo de taxa de falha

O modelo de taxa de falha<sup>1</sup> representa o processo de deterioração dos elementos e os efeitos das ações de manutenção sobre os mesmos. Seu objetivo é fazer a ligação entre as ações de manutenção e a confiabilidade do sistema, para possibilitar otimização na elaboração de planos de manutenção.

A Fig. 3.2 ilustra o papel de um modelo de taxa de falha. A parte superior da figura mostra a modelagem da deterioração do elemento, aproximada no exemplo em três estágios discretos,  $D_1$ ,  $D_2$  e  $D_3$ , resultando na falha do elemento no estágio  $F$ . A parte inferior da figura representa a modelagem do efeito das ações de manutenção ( $M_1$  e  $M_2$ ) sobre o elemento, provocando o aumento de sua confiabilidade representado como o retorno a um estágio anterior de deterioração.

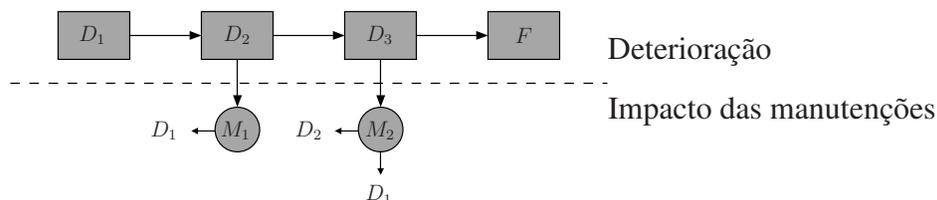


Fig. 3.2: Representação da função do modelo de taxa de falha

O modelo de taxa de falha calcula uma estimativa da probabilidade de ocorrências de falhas de cada elemento, como resultado das ações programadas e da deterioração do elemento no período. A disponibilidade de uma medida de confiabilidade individual dos elementos (sua taxa de falha) permite estimar a confiabilidade do sistema como um todo. Logo, é possível a avaliação de alternativas e comparação entre as soluções do problema de manutenção, possibilitando otimização.

A implementação do modelo de taxa de falha foi feita por multiplicadores de taxa de falha. Esses parâmetros representam a variação típica da taxa de falha em função da ação realizada no período. A Fig. 3.3 ilustra a utilização destes parâmetros para estimar a taxa de falha de um elemento qualquer no período  $t$ . Esta figura apresenta um gráfico de tempo x taxa de falha, mostrando que a taxa de falha no período  $t$  depende de seu valor no período anterior ( $t - 1$ ) e da ação realizada no período (nenhuma manutenção, manutenção mínima ou manutenção intensiva).

<sup>1</sup>Chamado assim porque a taxa de falha foi adotada para representar a confiabilidade de um elemento individual da rede.

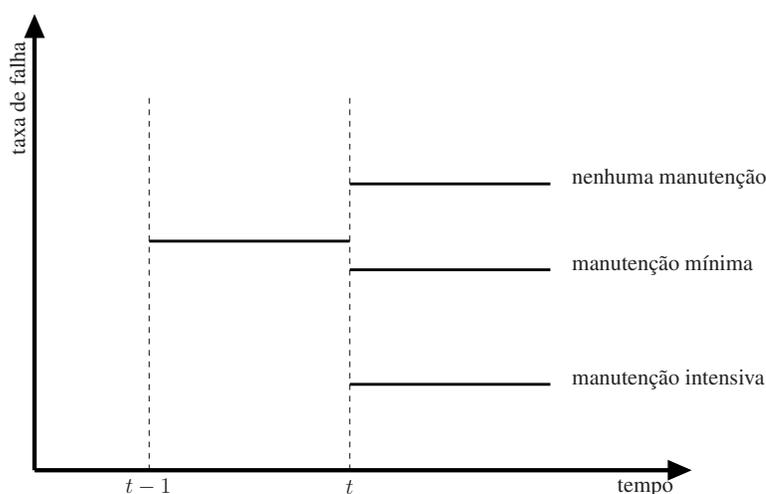


Fig. 3.3: Representação da estimativa da confiabilidade de um elemento através de multiplicadores de taxa de falha

Cada classe de componentes da rede (por exemplo, transformadores e religadores) possui um multiplicador de taxa de falha associado a cada ação de manutenção possível para esse elemento — incluindo não fazer nenhuma ação de manutenção - representando a deterioração do elemento. A representação matemática do modelo de taxas de falha será apresentada na Seção 3.3, juntamente com a definição do problema de otimização.

### 3.2.2 Ações preventivas

De acordo com Endrenyi et al. (1998), o propósito das manutenções é aumentar a vida útil dos elementos ou o tempo médio até a próxima falha. Estudos sobre causas de falhas e interrupções apontam a deterioração dos equipamentos e os contatos de cabos com árvores com significativas contribuições para tais eventos. A Tabela 3.1 apresenta resultados referentes a falhas ou interrupções provocadas por equipamentos e contatos de cabos com árvores. No artigo de Horton et al. (1991) são apresentados dados da probabilidade de falhas. Billinton e Billinton (1989) mostram valores de índices de continuidade no fornecimento de energia, que representam a duração e a frequência das interrupções. Os dados extraídos de Chow e Taylor (1995) correspondem ao número de falhas. A Tabela 3.1 mostra que falhas provocadas pela deterioração dos equipamentos e pelo contato de árvores com a rede têm um impacto significativo na confiabilidade do sistema de distribuição.

Tantos as falhas provocadas pela deterioração de equipamentos quanto às falhas causadas por contatos de cabos com árvores podem ser beneficiadas por manutenções preventivas. Assim, adotou-se neste trabalho dois tipos de ações preventivas a serem planejadas: manutenções em equipamentos e podas de árvores ao longo de alimentadores.

Tab. 3.1: Contribuição para as falhas e interrupções em redes de distribuição

<i>Medida</i>	<i>Equipamentos</i>	<i>Árvores</i>	<i>Fonte</i>
Taxa de falha	15%	75% <sup>a</sup>	Horton et al. (1991)
Duração Interrupções	15,3%	11,8%	Billinton e Billinton (1989)
Frequência Interrupções	15,9%	6,6%	Billinton e Billinton (1989)
Número de falhas	14%	19%	Chow e Taylor (1995)

<sup>a</sup>Valor correspondente à da taxa de falha causada por fatores externos, e não somente por contatos com árvores.

As ações preventivas podem não corresponder a uma única ação, mas a várias ações, com níveis diferentes de complexidade; por exemplo, manutenção mínima e manutenção intensiva. O nível de complexidade de uma ação reflete-se na qualidade do resultado de sua aplicação e no custo dessa ação. Na literatura (IEEE Standard 493, 1998) encontra-se normalmente não mais do que 3 níveis de manutenção. Os níveis dependem do tipo da ação e do tipo do elemento ao qual são aplicadas, variando de acordo com as práticas das empresas.

### 3.2.3 A confiabilidade do sistema de distribuição

Um dos principais parâmetros definidores de qualidade em sistemas de distribuição é a continuidade no fornecimento de energia elétrica. Esse parâmetro pode ser avaliado através de indicadores que representam o grau de disponibilidade da energia para o consumidor. Os indicadores mais comuns são: a frequência equivalente de interrupção por consumidor (*FEC*) e a duração equivalente de interrupção por consumidor (*DEC*) (Billinton e Billinton, 1989). O *DEC* indica a duração média, em horas, das interrupções de energia e o *FEC* o número médio de vezes que ocorreram interrupções no sistema.

O *FEC* pode ser calculado através de aproximação da taxa de falha dos elementos, permitindo sua utilização como medida de confiabilidade. Para calcular o *FEC* os alimentadores da rede são divididos em seções, cada seção correspondendo à área de cobertura de um equipamento de proteção. Essa divisão é adotada porque os equipamentos de proteção definem a parte da rede que perderá o fornecimento de energia no caso de uma falha no sistema, conforme discutido na Seção 2.2 do capítulo anterior.

O valor do *FEC* do sistema de distribuição pode ser calculado pela Equação 3.1.

$$FEC = \frac{\sum_{i=1}^n \lambda_i N_i}{NT} \quad (3.1)$$

sendo  $n$  o número de seções da rede,  $\lambda_i$  a taxa de falha da seção  $i$ ,  $N_i$  o número de consumidores na seção  $i$  e  $NT$  o número total de consumidores na rede.

### 3.2.4 Alternativas para a modelagem do problema

Uma forma de abordar o problema de planejamento de manutenção em *SDEE* é considerar os custos decorridos da execução de um plano de manutenção. Tendo como perspectiva o problema em questão podemos citar dois componentes desse custo: o custo de manutenção preventiva (*CMP*) e o custo devido à baixa confiabilidade (*CBC*). O *CMP* representa o custo das ações preventivas programadas enquanto o *CBC* corresponde às perdas de faturamento e despesas da empresa em decorrência das falhas.

A Fig. 3.4 apresenta curvas de comportamentos típicas do *CMP* e do *CBC* na relação entre custo e confiabilidade. A curva inferior mostra que quanto maior a confiabilidade menor os custos decorrentes de falhas. A curva correspondente ao *CMP* mostra que para aumentar a confiabilidade deve haver um aumento de recursos para manutenção. O ideal seria encontrar o ponto de mínimo na curva de custo total, correspondente à soma dos custos *CBC* e *CMP*. Esse ponto representa o balanço ótimo entre fazer e não fazer manutenção.

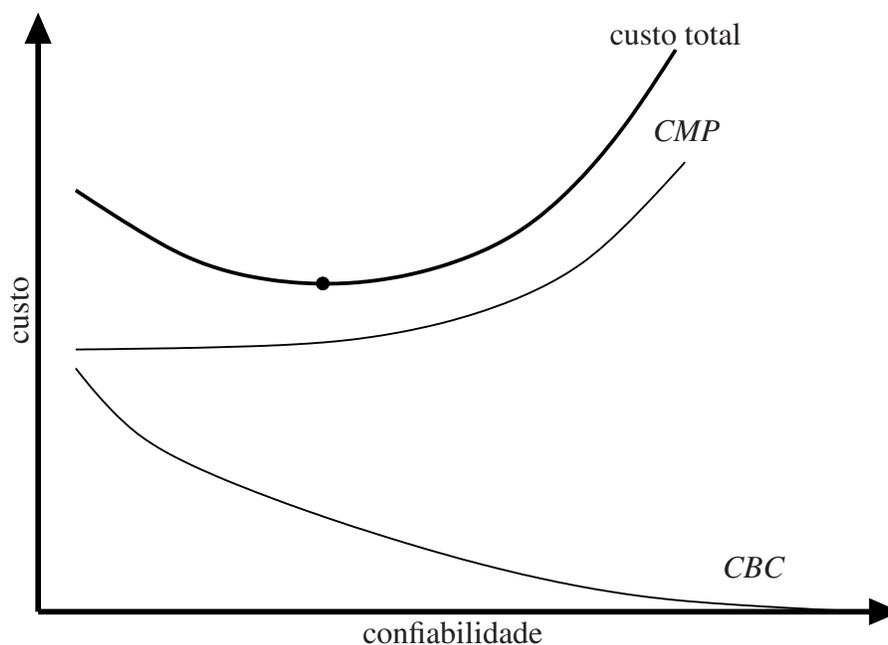


Fig. 3.4: Custo x confiabilidade (Gönen, 1986)

Ao contrário do *CMP*, o *CBC* geralmente não corresponde a um valor determinístico que possa ser calculado facilmente para o planejamento de manutenção. No modelo, o *CBC* poderia ser representado por uma estimativa do custo de reparo e substituição de equipamentos e pelo custo de podas de árvores emergenciais. Entretanto, o custo de uma falha, em decorrência de uma baixa confiabilidade de elementos da rede pode ser bem maior, levando em consideração, por exemplo, possíveis danos causados aos consumidores por interrupções no fornecimento de energia, muitas provocadas por uma

baixa qualidade no serviço e despesas na restauração da rede ao estado normal de operação. A difícil avaliação e ponderação dos componentes do *CBC* dificulta sua consideração no modelo, prejudicando a adoção dessa abordagem.

Em uma abordagem alternativa, ao invés de estimar o custo do sistema para um determinado nível de confiabilidade, pode-se incorporar no modelo uma medida de confiabilidade. Neste caso, pode-se considerar dois objetivos: reduzir despesas com manutenção e aumentar a confiabilidade, o que leva a uma redução dos custos devido às falhas. Esse problema multiobjetivo pode ser tratado tomando um deles como objetivo a ser otimizado e o outro como uma restrição. Assim, pode-se abordar o problema das seguintes formas:

- Minimizar os custos de manutenção considerando um valor determinado para a confiabilidade do sistema de distribuição;
- Maximizar a confiabilidade limitada a um investimento máximo em manutenção.

Na primeira abordagem garante-se uma confiabilidade mínima enquanto busca-se a redução do investimento necessário. Na segunda abordagem busca-se maximizar a eficiência, no que se refere à confiabilidade, na utilização de recursos aplicados à manutenção.

O problema de manutenção apresentado com os objetivos de minimizar custos e maximizar a confiabilidade poderia ser abordado com uma formulação multiobjetivo ao invés de adotar um deles como restrição. Esta modelagem permitiria a apresentação de várias soluções alternativas com um compromisso entre confiabilidade e custo, dando mais liberdade para a escolha de um plano de manutenção adequado.

Neste trabalho o problema de manutenção será modelado com o objetivo de reduzir custos com uma restrição de confiabilidade mínima, deixando-se para trabalhos futuros o tratamento do problema com uma abordagem multiobjetivo.

### **3.3 Formulação matemática do problema**

Empresas do setor de distribuição de energia elétrica são sujeitas a uma série de regulamentações quanto à continuidade no fornecimento. Assim, elas devem garantir um nível mínimo de confiabilidade do sistema, mesmo enquanto busca-se a redução de custo de operação e manutenção da rede. Em função dessa característica, a modelagem adotada neste trabalho para o problema de planejamento de manutenção em *SDEE* considera a redução de custos como objetivo a ser otimizado e toma a confiabilidade como restrição.

Adota-se a taxa de falha para representar a confiabilidade individual dos elementos do *SDEE*. O horizonte de planejamento é dividido em períodos anuais, sendo a taxa de falha em cada um desses períodos calculada por meio de multiplicadores de taxa de falha, conforme definido na seção 3.2.1.

A taxa de falha do elemento  $e$  no período  $t$  é calculada pela Equação 3.2 (Sittithumwat et al., 2004).

$$\lambda_e^t = \lambda_e^{(t-1)} \sum_{n \in N_{k_e}} \delta_{k_e n} x_{en}^t, \quad (3.2)$$

sendo:

- $\lambda_e^{(t-1)}$  a taxa de falha do elemento  $e$  no período anterior (ou a taxa de falha inicial para  $t = 1$ );
- $N_{k_e}$  o conjunto de ações (níveis de ações) preventivas que podem ser programadas para o componente de tipo  $k_e$ ;
- $\delta_{k_e n}$  o multiplicador de taxa de falha do componente de tipo  $k_e$  para a ação de nível  $n$ ;
- $x_{en}^t$  a variável de decisão binária; indica se foi programada uma ação de manutenção nível  $n$  para o elemento  $e$  no período  $t$  ( $x_{en}^t = 1$ ), ou não ( $x_{en}^t = 0$ ).

Observa-se que não existe uma única ação que pode ser programada para um determinado elemento. As ações possuem níveis de complexidade tendo um impacto diferente nos elementos, representado na Equação 3.2 pelo parâmetro  $\delta_{(k_e)n}$ . A Equação 3.3 garante que apenas uma ação de manutenção pode ser programada para um mesmo elemento em um dado período de tempo.

$$\sum_{n \in N_{k_e}} x_{en}^t = 1 \quad (3.3)$$

A taxa de falha dos elementos representa a confiabilidade dos mesmos, entretanto, é necessário avaliar a confiabilidade dos elementos em conjunto. A frequência equivalente de interrupções por consumidor (*FEC*) foi a medida adotada para representar a confiabilidade do sistema como um todo. Para o cálculo do *FEC*, os circuitos primários da rede de distribuição são divididos em seções. Cada seção corresponde à área de cobertura de um equipamento de proteção (conceito apresentado na seção 2.2 e ilustrado através das Fig. 2.1 e 2.2).

A Equação 3.4 estima o *FEC* para o período  $t$  usando a aproximação da taxa de falha dos componentes da rede, apresentada na Equação 3.5 (Sittithumwat et al., 2004).

$$FEC^t = \frac{\sum_{s \in S} \lambda_s^t N_s}{NT}, \quad (3.4)$$

sendo:

- $S$  o conjunto de seções da rede;
- $\lambda_s^t$  a taxa de falha da seção  $s$  no período  $t$  (calcula através da Equação 3.5);
- $N_s$  o número de consumidores da seção  $s$ ;
- $NT$  o número total de consumidores da rede.

$$\lambda_s^t = \lambda_s + \sum_{e \in E_s} \lambda_e^{(t)} \quad (3.5)$$

Na Equação 3.5,  $E_s$  representa o conjunto formado por todos os elementos sujeitos à manutenção na seção  $s$  e  $\lambda_s$  a taxa de falha base dessa seção. A taxa de falha base é uma constante que representa a parcela da taxa de falha associada aos fatores não incorporados no modelo.

A avaliação do custo de um plano de manutenção no modelo adotado tem dois componentes: o custo de manutenção preventiva ( $CMP$ ) e o custo de manutenção corretiva ( $CMC$ ). O  $CMP$  representa as despesas diretas do plano de manutenção; corresponde ao custo da mão de obra e de equipamentos utilizados na ações preventivas programadas para os componentes da rede. O  $CMC$  representa uma ponderação sobre as despesas associadas aos custos de reparo ou substituição dos elementos, calculado sobre a taxa de falha do componente e seu custo de manutenção corretiva.

Utilizando-se a representação matemática apresentada, o problema de otimização da manutenção pode ser caracterizado pelas equações 3.6 e 3.7. O objetivo é minimizar os custos alocados para as manutenções preventivas e eventuais manutenções corretivas (Equação 3.6), garantindo um nível mínimo de confiabilidade desejado (Equação 3.7).

$$\min \quad \sum_{t=1}^{HP} \left\{ \sum_{e \in E} \left[ \sum_{n=1}^{N_{k_e}} (p_{(k_e)n} x_{en}^t) + \lambda_e^{t C(k_e)} \right] \times g^t \right\} \quad (3.6)$$

$$\text{s.a:} \quad FEC^t \leq FEC_{perm} \quad \forall t = 1, \dots, HP, \quad (3.7)$$

sendo:

- $E$  o conjunto de elementos sujeitos a manutenções (transformadores, religadores, chaves fusíveis e seções de condutores);
- $FEC_{perm}$  o valor máximo permitido para o FEC;
- $p_{(k_e)n}$  o custo da ação preventiva de nível  $n$  no elemento de tipo  $k_e$ ;

- $c_{(k_e)}$  o custo de manutenção corretiva do elemento de tipo  $k_e$ ;
- $HP$  o horizonte de planejamento adotado para o problema;
- $g^t$  peso sobre o custo anual de manutenção.

Na função objetivo do modelo foi necessário associar um peso ao custo anual de manutenção. Esse peso, inserido pela Equação 3.8, tem como objetivo equilibrar o custo/benefício das ações dentro do horizonte de planejamento, evitando que as ações programadas se concentrassem nos primeiros anos do mesmo.

$$g^t = (HP - t + 1) \quad (3.8)$$

### 3.4 Comentários

Este capítulo descreveu o modelo de planejamento de manutenção em *SDEE* adotado neste trabalho. Este modelo representa o problema como a busca por um menor investimento em manutenções preventivas e menor riscos de gastos com manutenções corretivas sujeito a um nível mínimo de confiabilidade da rede.

A confiabilidade da rede é representada por um índice de continuidade no fornecimento de energia, o *FEC* (Frequência Equivalente de Interrupções por Consumidor). O *FEC* foi estimado sobre a taxa de falha dos elementos, que por sua vez, foi aproximada através de um modelo baseado nos multiplicadores de taxas de falha.

Os multiplicadores de taxas de falha associados a cada classe de elementos representam a variação das taxas de falha em um período em função da ação preventiva planejada nesse período para o elemento. O modelo de taxa de falha, implementado pelos multiplicadores, possibilitou a avaliação da confiabilidade de planos de manutenção, permitindo através da avaliação das soluções a modelagem do problema como um problema de otimização combinatória.

A abordagem por métodos heurísticos foi escolhida para resolver o problema de alocação de recursos de manutenção formulada neste capítulo. A escolha desta alternativa se deu pela característica combinatorial do modelo e pela grande dimensão dos casos de teste tratados neste trabalho. As duas abordagens heurísticas desenvolvidos para tratar o problema são discutidas nos capítulos 4 e 5 apresentados a seguir.

# Capítulo 4

## Método GRASP para abordagem do problema de manutenção de SDEE

### 4.1 Introdução

Neste capítulo, será discutida a complexidade do modelo adotado para o problema de planejamento de manutenção em sistemas de distribuição de energia elétrica (*SDEE*), fundamentando a adoção de heurísticas para sua resolução. Em seguida, será apresentado o *GRASP*, uma meta-heurística com múltiplos reinícios adaptada ao problema, como primeira alternativa para o seu tratamento.

### 4.2 Problemas de otimização combinatória

O modelo formulado no final do capítulo anterior representa o problema de planejamento de manutenção em *SDEE* como um problema de otimização combinatória. O número de soluções candidatas em problemas de otimização combinatória é finito, porém, geralmente, esse número cresce exponencialmente com o tamanho do problema.

No modelo adotado, a variável de decisão ( $x_{en}^t$ ) possui três dimensões: níveis de manutenção ( $n$ ), elementos ( $e$ ) e períodos de tempo ( $t$ ), conforme representado na Figura 4.1. Sendo a variável de decisão binária, o espaço de busca para o problema tem a dimensão  $2^{|E|*|N_{ke}|*HP}$ , sendo  $|E|$  o número de elementos sujeitos à manutenção,  $|N_{ke}|$  o número de níveis de ações de manutenção preventivas que podem ser programadas para cada elemento<sup>1</sup> e  $HP$  o número de anos do horizonte de planejamento. O menor problema tratado nesse trabalho possui cerca de 900 elementos; considerando a adoção de

---

<sup>1</sup>Consideramos, a título de ilustração, que esse número é igual para todos os tipos de elementos.

três níveis de manutenção e um horizonte de planejamento de três anos, a dimensão do espaço de busca seria  $2^{900 \cdot 3 \cdot 3} = 2^{8100}$ .

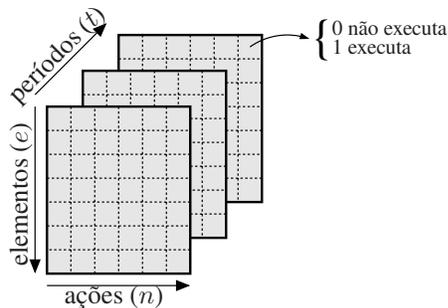


Fig. 4.1: Representação da variável de decisão  $x_{en}^t$ .

O número finito de soluções em problemas de otimização combinatória permite na teoria sua resolução por enumeração explícita das soluções. Entretanto, essa abordagem é geralmente inviável na prática devido à alta complexidade computacional de tal procedimento. Existem alternativas de métodos exatos<sup>2</sup> que trabalham fazendo um particionamento e redução do espaço de busca (Papadimitriou e Steiglitz, 1998), porém, estes métodos ainda podem apresentar uma complexidade elevada para resolver problemas de maior dimensão como os de manutenção em redes de distribuição de grande porte.

### 4.3 Métodos Heurísticos

Métodos heurísticos ganharam espaço na literatura por se mostrarem uma alternativa para resolver problemas intratáveis computacionalmente por métodos exatos. Na prática, muitos métodos heurísticos apresentam soluções de qualidade em um tempo computacional aceitável. Normalmente, são eficientes por indicarem formas de reduzir o número de avaliações e obter soluções em tempos aceitáveis. Pode-se citar três classes de métodos heurísticos: heurísticas de construção, heurísticas de melhoramento (buscas locais) e meta-heurísticas.

As heurísticas de construção escolhem passo a passo elementos do problema, inserindo-os na solução parcial até se chegar a uma solução completa e factível. Um exemplo de heurística construtiva é a *greedy* (gulosa), caracterizada pela escolha a cada passo do elemento mais “atrativo” de acordo com algum critério definido. Vale ressaltar que a melhor escolha em cada passo da construção não garante necessariamente a melhor solução para um dado problema.

Heurísticas de melhoramento partem de uma solução inicial, geralmente factível, e buscam sucessivamente encontrar soluções melhores, movimentando-se pelo espaço de busca na “vizinhança”

<sup>2</sup>Métodos que garantem encontrar a solução ótima para o problema.

da solução corrente. A vizinhança de uma solução em uma heurística de melhoramento consiste nas soluções que podem ser alcançadas a partir desta através do movimento definido para exploração do espaço de busca, denominado mecanismo de geração de vizinhança.

Sendo  $\beta(\cdot)$  o mecanismo de geração de vizinhança e  $f(\cdot)$  a função de avaliação das soluções, o procedimento de melhoramento gera uma seqüência de pontos  $x_1, x_2, \dots, x_n$  onde  $x_{k+1} \in \beta(x_k)$  e, para problemas de minimização,  $f(x_{k+1}) < f(x_k)$ . A busca termina quando um ótimo local  $x^*$  é encontrado. O ponto  $x^*$  é tal que  $f(x^*) \leq f(x) \quad \forall x \in \beta(x^*)$  (Evans, 1987).

As heurísticas normalmente são específicas aos problemas pelo fato de serem desenvolvidas explorando particularidades e o conhecimento sobre eles. As meta-heurísticas, entretanto, são uma classe de heurísticas que possuem estruturas e princípios básicos que podem ser adaptadas e utilizadas para resolver problemas independentemente de suas características particulares.

As meta-heurísticas possuem mecanismos que possibilitam escapar de ótimos locais aumentando as chances de encontrar soluções mais próximas do ótimo global.

Dentre as meta-heurísticas encontradas na literatura podemos destacar os algoritmos genéticos (Holland, 1975; Michalewicz, 1996; Reeves, 2003) e o *GRASP* (Resende e Ribeiro, 2003), utilizados neste trabalho. Os algoritmos genéticos são métodos de busca inspirados nos mecanismos de evolução dos sistemas biológicos. O *GRASP* (*greedy randomized adaptive search procedure*) corresponde a um procedimento com múltiplos reinícios em duas fases: construção e busca local.

A escolha do método *GRASP* foi motivada por sua fácil adaptação a partir de uma heurística construtiva e de uma busca local desenvolvidos inicialmente para explorar o problema. O algoritmo genético foi desenvolvido com o objetivo de escapar da alta complexidade do método *GRASP* desenvolvido.

As seções a seguir apresentam as principais idéias do método *GRASP* e sua especialização para abordar o problema de planejamento de manutenção de sistemas de distribuição, formulado na seção 3.3 do Capítulo 3.

## 4.4 GRASP

O Pseudo-código 1 mostra as etapas do método *GRASP*. Cada iteração do *GRASP* consiste em duas fases: construção e busca local. A fase de construção gera uma solução factível, explorada em seguida pela busca local para alcançar um ótimo local (Resende e Ribeiro, 2003). A melhor solução encontrada durante esse processo é a solução final apresentada pelo método.

O Pseudo-código 2 detalha a fase de construção do método *GRASP*. Nesta fase, seleciona-se aleatoriamente na lista restrita de candidatos (*RCL - restricted candidate list*) os elementos a serem incluídos na solução parcial. A lista *RCL* é formada pelos melhores elementos determinados através

---

**Pseudo-código 1** GRASP( $num\_Iteracoes$ )

---

- 1: **para**  $k \leftarrow 1$  até  $num\_Iteracoes$  **faça**
- 2:    $solucao \leftarrow Construc\tilde{a}o\_gulosa\_comAleatoriedade$
- 3:    $solucao \leftarrow Busca\_Local(solucao)$
- 4:    $Atualizar\_MelhorSolucao(solucao)$

5: **fim para**

**Return:**  $melhorSolucao$

---

de uma função de avaliação “gulosa”<sup>3</sup>. Geralmente, essa função calcula o custo incremental da inclusão deste elemento na solução parcial (Resende e Ribeiro, 2003). Dessa forma, a construção tem um caráter “guloso” (na definição da lista *RCL*) e probabilística (com a seleção aleatória dos elementos nessa lista).

---

**Pseudo-código 2** Construc $\tilde{a}$ o\_gulosa\_comAleatoriedade

---

- 1:  $solucao \leftarrow \phi$
- 2: avaliar os custos incrementais dos elementos candidatos
- 3: **enquanto**  $solucao$  não é uma solução completa **faça**
- 4:   construir a lista restrita de candidatos (*RCL*)
- 5:   Selecionar um elemento  $s$  da lista *RCL* aleatoriamente
- 6:    $solucao \leftarrow solucao \cup \{s\}$
- 7:   reavaliar os custos incrementais
- 8: **fim enquanto**

**Return:**  $solucao$

---

A busca local é utilizada para explorar a vizinhança das soluções geradas na fase construtiva. O Pseudo-código 3 apresenta uma representação simplificada desse procedimento. Neste Pseudo-código  $\beta$  é o mecanismo de geração de vizinhança e  $f(\cdot)$  é a função que avalia as soluções.

---

**Pseudo-código 3** Busca\_Local( $solucao$ )

---

- 1: **enquanto**  $solucao$  não é um ótimo local **faça**
- 2:   Encontrar  $s' \in \beta(solucao)$  com  $f(s') < f(solucao)$
- 3:    $solucao \leftarrow s'$
- 4: **fim enquanto**

**Return:**  $solucao$

---

Nesta seção, foram descritos os conceitos básicos do método *GRASP* e seus dois componentes responsáveis pela fase de construção e melhoramento. Nas seções seguintes, serão apresentadas a heurística construtiva e a busca local desenvolvidas especificamente para o problema de planejamento de manutenção em *SDEE*.

---

<sup>3</sup>A função é chamada gulosa por avaliar apenas localmente o resultado da inclusão de um elemento na solução parcial.

### 4.4.1 Heurística construtiva para o problema de planejamento de manutenção

A heurística construtiva do método *GRASP* é detalhada no Pseudo-código 4. Ela utiliza como função de avaliação para a construção da lista *RCL* a relação custo/benefício de aumentar o nível de manutenção de um elemento  $e$  qualquer (Equação 4.1). No Pseudo-código 4  $FEC^t$  valoriza o *FEC* do sistema no período  $t$  para a solução  $x$  do problema de manutenção,  $FG_e$  é o resultado da Equação 4.1 que avalia a relação custo/benefício de aumentar o nível de manutenção do elemento  $e$ ,  $\alpha$  é um parâmetro da heurística que define o tamanho da lista *RCL* e  $FEC_{perm}$  é um parâmetro do problema que indica o valor máximo permitido para o *FEC*.

---

#### Pseudo-código 4 Heurística\_Construtiva

---

**Entrada:**  $FEC_{perm}$

- 1:  $x \leftarrow \phi$
- 2: **enquanto**  $FEC^t > FEC_{perm} | t \leq HP$  **faça**
- 3:  $FG^{min} \leftarrow \min FG_e | e \in E$
- 4:  $FG^{max} \leftarrow \max FG_e | e \in E$
- 5:  $RCL \leftarrow e \in E | FG_e \geq (FG^{max} - \alpha(FG^{max} - FG^{min}))$
- 6: selecionar um elemento  $i \in RCL$  aleatoriamente
- 7:  $nivel\_Manutencao \leftarrow ObtemProximoNivelAcoes(x, i)$
- 8:  $acoes \leftarrow ObtemAcoes(nivel\_Manutencao)$
- 9: **para**  $t \leftarrow 1$  até *HP* **faça**
- 10:  $n \leftarrow acoes^t$
- 11:  $x_{in}^t \leftarrow 1$
- 12: **fim para**
- 13: **fim enquanto**

**Return:**  $x$

---

$$FG_e = \frac{\Delta FEC_{e,atual} - \Delta FEC_{e,minimo}}{custo_{e,maximo} - custo_{e,atual}} \quad (4.1)$$

Na Equação 4.1  $\Delta FEC_{e,atual}$  é a contribuição atual do elemento  $e$  para com o *FEC* total do sistema,  $\Delta FEC_{e,minimo}$  é o valor da contribuição desse elemento para com o *FEC* no maior nível de manutenção,  $custo_{e,maximo}$  é o custo do maior nível de manutenção e  $custo_{e,atual}$  é o custo do nível atual de manutenção. O valor obtido pela Equação 4.1 indica o custo relativo entre o nível atual e o maior nível possível de manutenção para o elemento.

Chamamos de nível de manutenção o número de ações de cada tipo programadas para um elemento. Pode-se modificar o planejamento para um elemento aumentando ou reduzindo os níveis de manutenção, na seqüência definida pelo seu custo total. Tomemos, como exemplo, um elemento  $e$  qualquer, com três tipos de ações: não fazer manutenção, fazer manutenção mínima e fazer manutenção intensiva, com custos 0, 10 e 15, respectivamente. Esse elemento teria os níveis de manutenção

apresentados na Tabela 4.1, para um horizonte de planejamento de três anos, implicando, de acordo com o modelo adotado, o planejamento de três ações preventivas para cada elemento.

Tab. 4.1: Exemplo dos níveis de manutenção para um elemento, considerando um horizonte de planejamento de três anos

Nível	NM <sup>a</sup>	MM <sup>b</sup>	MI <sup>c</sup>	Custo
1	3	0	0	0
2	2	1	0	10
3	2	0	1	15
4	1	2	0	20
5	1	1	1	25
6	1	0	2	30
7	0	2	1	35
8	0	1	2	40
9	0	0	3	45

<sup>a</sup>Número de ações do tipo 'Nenhuma manutenção'.

<sup>b</sup>Número de ações do tipo 'Manutenção mínima'.

<sup>c</sup>Número de ações do tipo 'Manutenção intensiva'.

A cada iteração da heurística construtiva, um elemento (equipamento ou seção da rede) é selecionado na lista *RCL* e tem seu nível de manutenção aumentado (linhas 6 a 12 do pseudo-código 4), ou seja, destina-se mais recursos de manutenção ao elemento selecionado. Em seguida, a lista *RCL* é redefinida, após a atualização do valor guloso do elemento escolhido. Esse processo se repete, até atingir a factibilidade da solução em construção (linha 2 no pseudo-código 4).

O passo da linha 7, da heurística construtiva, busca um novo nível de manutenção para o elemento escolhido, enquanto o passo 8 escolhe onde programar as ações correspondentes ao nível de manutenção. Por exemplo, se o nível de manutenção corresponde a uma manutenção mínima e duas intensivas para um horizonte de planejamento de três anos, o passo 8 decide, dentre os anos, onde alocar a manutenção mínima. Essa decisão é tomada buscando a configuração com o menor custo, se a solução é factível ( $FEC(x) > FEC_{perm}$ ), ou com a maior confiabilidade, se a solução ainda é infactível. Nos passos 9 a 12 são atualizadas as novas ações de manutenção definidas para o elemento no passo 8.

A relação entre os níveis de manutenção, o custo e o impacto no *FEC* estão representadas na Fig. 4.2, onde se pode verificar que quanto maior o nível de manutenção programado para um elemento maior o custo de manutenção preventiva, menor o *CMC* e menor o *FEC*. Entretanto, o *CMC* e o *FEC* serão únicos para um nível de manutenção apenas se o horizonte de planejamento for igual a 1. Caso contrário, esses valores irão variar de acordo com onde as ações referentes ao nível de manutenção serão programadas dentro do horizonte de planejamento.

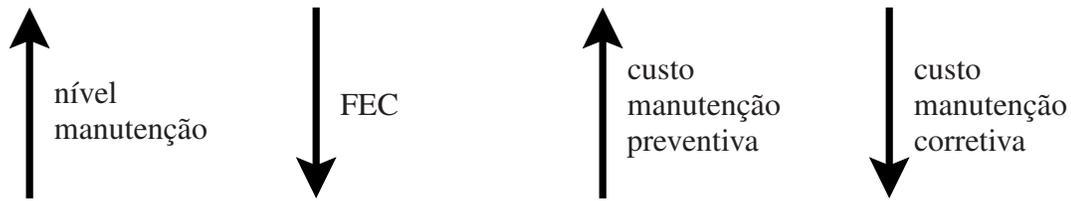


Fig. 4.2: Relação entre nível de manutenção, custo e impacto no FEC

Como exemplo da variação do *CMC* e o *FEC* para um mesmo nível de manutenção, vamos considerar novamente um elemento com três ações de manutenção. A Tabela 4.2 mostra os multiplicadores de taxa de falha associados a cada ação e a Fig. 4.3 apresenta a taxa de falha calculada para os três anos do horizonte de planejamento, em cada possível permutação do nível de manutenção formado por uma de cada possível ação: uma nenhuma manutenção (*NM*), uma manutenção mínima (*MM*) e uma manutenção intensiva (*MI*).

Tab. 4.2: Multiplicadores de taxas de falha para exemplo da variação entre o nível de manutenção e os valores do *FEC* e da *CMC*

Ação	Multiplicador Tx Falha
Manutenção intensiva	0,95
Manutenção mínima	1,05
Nenhuma manutenção	1,51

A Tabela 4.3 apresenta a taxa de falha inicial do elemento, o custo de manutenção corretiva ( $c_{k_e}$ ), o total de consumidores da rede ( $NT$ ) e o número de consumidores dependentes da seção da rede na qual ele está ligado ( $N_s$ ). Esses valores foram utilizados, no exemplo, para calcular a contribuição do elemento para com o *FEC* (equação 4.2) e o *CMC* (Equação 4.3) apresentados na Tabela 4.4.

Tab. 4.3: Dados de manutenção usados no exemplo da variação entre o nível de manutenção e os valores do *FEC* e da *CMC*

Parâmetro	Valor
Taxa de falha Inicial	0,5
Custo Manutenção corretiva	20
Num. Consumidores	50
Total Consumidores	500

$$\Delta FEC_e^t = \frac{\lambda_e^t N_s}{NT} \quad (4.2)$$

$$CMC_e^t = \lambda_e^t c_{k_e} \quad (4.3)$$

	ano 1   ano 2   ano 3		ano 1   ano 2   ano 3				
Permutação 1 :	NM	MM	MI	Permutação 2 :	NM	MI	NM
Taxa de Falha :	0,76	0,79	0,75	Taxa de Falha :	0,76	0,72	0,75
	ano 1   ano 2   ano 3		ano 1   ano 2   ano 3				
Permutação 3 :	MM	NM	MI	Permutação 4 :	MM	MI	NM
Taxa de Falha :	0,53	0,79	0,75	Taxa de Falha :	0,53	0,50	0,75
	ano 1   ano 2   ano 3		ano 1   ano 2   ano 3				
Permutação 5 :	MI	NM	MM	Permutação 6 :	MI	MM	NM
Taxa de Falha :	0,48	0,72	0,75	Taxa de Falha :	0,48	0,50	0,75

Fig. 4.3: Taxa de falha anual para cada permutação de ações de um nível de manutenção formado por três ações diferentes (NM - nenhuma manutenção, MM - manutenção mínima e MI - manutenção intensiva)

Nas equações 4.2 e 4.3 os parâmetros  $N_s$ ,  $NT$  e  $c_{k_e}$  são aqueles presentes na tabela 4.3 e  $\lambda_e^t$  é a taxa de falha do elemento  $e$  no período  $t$  do horizonte de planejamento (valores apresentados na Fig. 4.3 para cada permutação das ações, calculados através dos multiplicadores de taxa de falha também presentes na Tabela 4.3).

A Tabela 4.4 mostra os valores anuais e a soma do  $CMC$  e da variação no  $FEC$ , para as possíveis permutações de ações de um determinado nível de manutenção. Pode-se observar na Tabela 4.4 que o  $FEC$  e o  $CMC$  variam dependendo das permutações das ações.

Tab. 4.4: Valores do  $FEC$  e da  $CMC$  das permutações de ações de um nível de manutenção formado por 3 ações diferentes e um  $HP=3$

Perm	$CMC$				$\Delta FEC$			
	ano 1	ano 2	ano 3	Total	ano 1	ano 2	ano 3	Total
1	15,10	15,86	15,06	46,02	0,076	0,079	0,075	0,230
2	15,10	14,35	15,06	44,51	0,076	0,072	0,075	0,223
3	10,50	15,86	15,06	41,42	0,053	0,079	0,075	0,207
4	10,50	9,98	15,06	35,54	0,053	0,050	0,075	0,178
5	9,50	14,35	15,06	38,91	0,048	0,072	0,075	0,195
6	9,50	9,98	15,06	34,54	0,048	0,050	0,075	0,173

Independentemente do custo e do  $FEC$  poderem não ser únicos para as permutações de ações

de um nível de manutenção, as relações apresentadas na Fig. 4.2 ainda são válidas. A heurística construtiva utiliza essas relações e inicia no menor nível de manutenção (com custo 0 de manutenção preventiva e sem nenhuma contribuição para a redução do FEC) e, gradativamente, vai aumentando o investimento até atingir a factibilidade. Busca-se, assim, gerar soluções factíveis com o menor investimento possível.

Abaixo segue um exemplo ilustrativo do processo de construção pela heurística construtiva. O exemplo é constituído de três elementos sujeitos à manutenção, com três níveis de manutenção cada um e um horizonte de planejamento de um ano. Adotou-se o  $FEC$  inicial igual a 1, 1 e consideramos esse mesmo valor como o valor máximo permitido para o  $FEC$ . O custo associado a cada nível de manutenção corresponde ao custo de manutenção preventiva e a variação no  $FEC$  ( $\Delta FEC$ ) corresponde à diferença entre o  $FEC$  no período anterior e seu valor no período atual.

No exemplo, serão necessários duas iterações para atingir o critério de parada do método (a factibilização da solução). A Fig. 4.5 apresenta a situação inicial para a heurística construtiva: todos os elementos estão no menor nível de manutenção. Essa configuração de níveis de manutenção tem um custo total 0 e um  $FEC$  igual ao valor do período anterior (1, 1) mais a variação no período. No período,  $\Delta FEC$  é igual a +0,03, +0,01 e +0,06 para os três elementos, respectivamente, resultando em um  $FEC$  total igual a 1, 2 ao final deste período (Fig. 4.5).

elemento 1			elemento 2			elemento 3		
<i>nível</i>	<i>custo</i>	$\Delta FEC$	<i>nível</i>	<i>custo</i>	$\Delta FEC$	<i>nível</i>	<i>custo</i>	$\Delta FEC$
1	0	+0,03	1	0	+0,01	1	0	+0,06
2	12	-0,03	2	8	-0,01	2	10	-0,08
3	20	-0,08	3	15	-0,05	3	25	-0,12

$$FG_{e_1} = \frac{0,03 - (-0,08)}{20 - 0} = 0,0055 \quad FG_{e_2} = \frac{0,01 - (-0,05)}{15 - 0} = 0,004 \quad FG_{e_3} = \frac{0,06 - (-0,12)}{25 - 0} = 0,0072$$

Fig. 4.4: Nível inicial de manutenção no exemplo da heurística construtiva

$$CMP = 0$$

$$FEC_{atual} = 1,2$$

$$RCL = \boxed{e_3} \boxed{e_1} \boxed{e_2}$$

Fig. 4.5: Configuração da lista  $RCL$  e valores iniciais do custo e do  $FEC$  no exemplo da heurística construtiva

Abaixo dos níveis de manutenção na Fig. 4.4 encontra-se o cálculo do valor guloso para cada

elemento (Equação 4.1). A Fig. 4.5 mostra uma lista com os três elementos ordenados de forma decrescente pelo valor guloso. Os dois primeiros elementos formam a lista  $RCL^4$ .

Como mostra a Fig. 4.5, o critério de parada da heurística construtiva não foi atingido, pois o  $FEC$  do período (1, 2) é maior que o  $FEC$  permitido (1, 1). Por isso, o método executa a primeira iteração aumentando o nível de manutenção de um elemento escolhido aleatoriamente na lista  $RCL$ . O elemento escolhido está evidenciado na lista (nesta iteração, o elemento 1 que ocupava a posição 2).

As Fig. 4.6 e 4.7 apresentam a situação após a variação do nível de manutenção do elemento 1. Essa mudança ocasionou um aumento do custo da solução em 12 unidades e uma redução do  $FEC$  para 1, 14, obtido pela soma do  $FEC$  inicial para esta iteração (1, 2) com o valor da variação no período, igual a  $-0,06$  (Fig. 4.7). A Figura 4.6 mostra o novo valor guloso do elemento 1, utilizado para reorganizar a lista  $RCL$  que ficou com a mesma configuração, porque o elemento 1 continuou sendo o segundo mais atrativo.

elemento 1			elemento 2			elemento 3		
<i>nível</i>	<i>custo</i>	$\Delta FEC$	<i>nível</i>	<i>custo</i>	$\Delta FEC$	<i>nível</i>	<i>custo</i>	$\Delta FEC$
1	0	+0,03	1	0	+0,01	1	0	+0,06
2	12	-0,03	2	8	-0,01	2	10	-0,08
3	20	-0,08	3	15	-0,05	3	25	-0,12

$$FG_{e_1} = \frac{-0,03 - (-0,08)}{20 - 12} = 0,0063 \quad FG_{e_2} = \frac{0,01 - (-0,05)}{15 - 0} = 0,004 \quad FG_{e_3} = \frac{0,06 - (-0,12)}{25 - 0} = 0,0072$$

Fig. 4.6: Nível de manutenção após iteração 1 no exemplo da heurística construtiva

$$CMP = 12$$

$$FEC_{atual} = 1,14$$

$$RCL = \boxed{e_3} \boxed{e_1} \boxed{e_2}$$

Fig. 4.7: Configuração da lista  $RCL$  e valores do custo e do  $FEC$  após iteração 1 no exemplo da heurística construtiva

O valor 1, 14 para o  $FEC$  ainda não representa um nível de confiabilidade aceitável; portanto, uma segunda iteração é necessária. Nesta iteração o elemento 3 (na primeira posição da lista  $RCL$ ) é selecionado e recebe mais recursos para manutenção. A solução parcial obtida é apresentada nas Fig.

<sup>4</sup>A lista  $RCL$  pode ser formada por vários elementos; adotou-se 2 para fins de exemplo.

4.8 e 4.9. Nessa iteração há um aumento de 10 unidades no custo e uma redução de 0,08 no *FEC*, que atinge o valor de 1,09 (Fig. 4.9). Atendida a factibilidade da solução, a heurística construtiva pára.

elemento 1			elemento 2			elemento 3		
<i>nível</i>	<i>custo</i>	$\Delta FEC$	<i>nível</i>	<i>custo</i>	$\Delta FEC$	<i>nível</i>	<i>custo</i>	$\Delta FEC$
1	0	+0,03	1	0	+0,01	1	0	+0,06
2	12	-0,03	2	8	-0,01	2	10	-0,08
3	20	-0,08	3	15	-0,05	3	25	-0,12

$$FG_{e_1} = \frac{-0,03 - (-0,08)}{20 - 12} = 0,0063 \quad FG_{e_2} = \frac{0,01 - (-0,05)}{15 - 0} = 0,004 \quad FG_{e_3} = \frac{-0,08 - (-0,12)}{25 - 10} = 0,0027$$

Fig. 4.8: Nível de manutenção após iteração 2 no exemplo da heurística construtiva

$$CMP = 22$$

$$FEC_{atual} = 1,00$$

$$RCL = \begin{array}{|c|c|c|} \hline e_1 & e_2 & e_3 \\ \hline \end{array}$$

Fig. 4.9: Configuração da lista *RCL* e valores do custo e do *FEC* após iteração 2 no exemplo da heurística construtiva

Neste exemplo adotou-se um horizonte de planejamento igual a um, permitindo associar um custo e uma variação no *FEC* a cada nível de manutenção. Entretanto, para horizontes de planejamento maiores do que um esses valores vão depender do período em que as ações de manutenção são programadas no horizonte de planejamento.

Na heurística construtiva não é problema a relação não única entre o nível de manutenção e seu impacto na solução, porque a função 4.1 utilizada para criar a lista *RCL* usa o nível atual de manutenção (cujo impacto é conhecido) e o nível máximo para o qual o custo e a variação no *FEC* são únicos. O custo e a variação no *FEC* no último nível de manutenção são únicos, porque só existe uma configuração para as ações dentro do horizonte de planejamento, visto que este nível é formado por uma mesma ação, repetida em cada ano do horizonte (para exemplo veja a Tabela 4.1 na página 27).

#### 4.4.2 Busca Local para o problema de planejamento de manutenção

No problema tratado, os movimentos da busca local (*BL*) ocorrem entre pares de elementos, buscando reduzir despesas através da realocação de recursos em ações mais efetivas quanto à redução do *FEC*. O procedimento, descrito no Pseudo-código 5, percorre cada par de elementos testando o

impacto de reduzir o nível de manutenção de um deles e aumentar o do outro. O melhor movimento entre os dois elementos seleccionados é executado; esta estratégia é denominada *best-improvement* e é implementada no procedimento *buscar\_MelhorMovimento*, detalhada no Pseudo-código 6. A busca local pára quando não existe nenhum movimento factível que reduza o custo da solução (linha 10 no pseudo-código 5).

---

**Pseudo-código 5** *Busca\_Local(solucao)*


---

```

1: repita
2:   melhorou  $\leftarrow$  false
3:   para  $\forall e, f \in E$  faça
4:     mov  $\leftarrow$  buscar_MelhorMovimento(e, f)
5:     se mov melhora a solução solucao então
6:       solucao  $\leftarrow$  executar_Movimento(solucao, mov)
7:       melhorou  $\leftarrow$  true
8:     fim se
9:   fim para
10: até que melhorou = false
Return: solucao

```

---



---

**Pseudo-código 6** *buscar\_MelhorMovimento(e,f)*


---

```

1: para ano  $\leftarrow$  1 até HP faça
2:   N  $\leftarrow$  conjunto de níveis de manutenção inferiores ao nível atual do elemento e (como exemplo na tabela 4.1)
3:   M  $\leftarrow$  conjunto de níveis de manutenção igual ou superiores ao nível atual do elemento f (como exemplo na tabela 4.1)
4:   para  $\forall n \in N$  e  $\forall m \in M$  faça
5:     mov  $\leftarrow$  testa_Movimento(n, m)
6:     atualizar_MelhorMov(mov, melhorMov)
7:   fim para
8: fim para
Return: melhorMov

```

---

A idéia explorada na busca local é melhorar a solução atual por meio de movimentos entre os níveis de manutenção dos elementos.

Sejam os níveis de manutenção  $nm_e$  e  $nm_f$  para dois elementos  $e$  e  $f$ , quaisquer, com custos  $c_e$  e  $c_f$ , respectivamente. A *BL* procura por uma configuração para os níveis de manutenção dos elementos  $e$  e  $f$  onde  $nm'_e < nm_e$  e  $nm'_f \geq nm_f$ , ou o contrário ( $nm'_e \geq nm_e$  e  $nm'_f < nm_f$ ), de forma que a variação no custo da solução ( $c'_e + c'_f - (c_e + c_f)$ ) seja menor do que zero e a solução resultante seja factível.

A seguir é apresentado um exemplo, que ilustra os testes realizados pela busca local para a exploração dos movimentos dos níveis de manutenção entre dois elementos (Pseudo-código 6). Suponha, inicialmente, que o elemento 1 está no nível dois de manutenção de um total de três e o elemento 2 está no nível três, também de um total de três (Fig. 4.10). Serão testados os movimentos com o nível de manutenção do primeiro elemento igual ou superior ao atual e com níveis de manutenção inferiores para o segundo elemento (linhas 2 e 3 do pseudo-código 6). Existem duas possibilidades para o elemento 1 e duas para o elemento 2 resultando em um total de quatro combinações possíveis, ou seja, quatro movimentos a serem testados.

elemento 1			elemento 2		
<i>nível</i>	<i>custo</i>	$\Delta FEC$	<i>nível</i>	<i>custo</i>	$\Delta FEC$
1	0	+0,03	1	0	+0,06
2	15	-0,03	2	8	-0,08
3	20	-0,07	3	22	-0,12

Fig. 4.10: Nível de manutenção inicial dos dois elementos na ilustração dos movimentos da Busca Local

Tab. 4.5: Avaliação pela Busca Local dos possíveis movimentos entre um par de elementos

	Atual	Mov1	Mov2	Mov3	Mov4
<i>Nível de e<sub>1</sub></i>	2	2	2	3	3
<i>Nível de e<sub>2</sub></i>	3	2	1	2	1
<i>custo</i>	100	86	78	91	83
<i>FEC</i>	1,05	1,09	1,23	1,05	1,19

A Tabela 4.5 apresenta o custo e o *FEC* resultantes da realização de cada um dos movimentos. Esses valores são determinados calculando as variações em função dos valores atuais, apresentados na segunda coluna da Tabela 4.5. Considerando o valor de 1,1 para o *FEC* máximo permitido, os movimentos 2 e 4 são descartados, por levarem, respectivamente, a soluções infactíveis com valores 1,23 e 1,19 para o *FEC*. Dentre os demais movimentos, ambos levaram a melhores soluções, pois reduziram o custo para 86, no caso do movimento 1, e para 91, no caso do movimento 3. O movimento 1 é executado pela busca local por resultar na solução com o menor custo. Em seguida, a busca local prossegue explorando os demais pares de elementos até atingir um ótimo local.

Como mencionado na Seção 4.4.1 (Página 26), se o horizonte de planejamento for maior que 1 o custo e o *FEC* da solução dependem do período onde as ações serão programadas. Por isso, a

avaliação dos movimentos realizados na busca local tem um passo adicional em relação aos apresentados na ilustração anterior. Nesse passo, contido no passo 5 do Pseudo-código 6 da busca local e apresentado na linha 8 do Pseudo-código 4 da heurística construtiva, são verificadas as combinações das ações dentro do horizonte de planejamento. O valor do custo e do *FEC* tomados para avaliar um movimento são aqueles da configuração que resulta em uma solução factível com o menor custo.

## 4.5 Comentários

Este capítulo apresentou o método *GRASP* e sua adaptação ao problema de planejamento de manutenção em *SDEE*, por meio de uma heurística construtiva e de uma busca local, desenvolvidos especialmente para explorar o modelo do problema em questão.

A heurística construtiva adotada no método gera uma solução para o modelo escolhendo iterativamente para quais elementos do sistema destinar mais recursos para manutenção. A escolha do elemento a cada iteração é feita em função do custo/benefício de aumentar o investimento nos elementos. A busca local explora o espaço de soluções por meio de movimentos entre pares de elementos, buscando reduzir custos e transferindo recursos a elementos com um maior impacto na confiabilidade da rede.

A estratégia de exploração de pares de elementos adotada pela busca local apresentou uma alta exigência de recursos computacionais, devido à característica combinatorial do espaço explorado. Esta alta complexidade da busca local levou à consideração de um método alternativo ao *GRASP*, procurando-se reduzir o tempo de processamento na busca de melhores planos de manutenção. A alternativa adotada no trabalho foi um método baseado em algoritmos genéticos, discutido no capítulo a seguir.

## Capítulo 5

# Algoritmo Genético para abordagem do problema de manutenção de SDEE

### 5.1 Introdução

Este capítulo descreve sucintamente os conceitos gerais dos algoritmos evolutivos e, em mais detalhes, aqueles empregados neste trabalho para a resolução do modelo apresentado no Capítulo 3. Como aspectos principais do algoritmo evolutivo apresentado neste capítulo estão: a representação das soluções por vetores reais, a utilização de um procedimento de decodificação para o mapeamento de indivíduos nessa representação para soluções do problema, a adoção de uma heurística construtiva para a inicialização da população e a incorporação no método de uma busca local para auxiliar a exploração do espaço de busca.

### 5.2 Algoritmos Evolutivos

Algoritmos genéticos são uma variante de um paradigma de resolução de problemas: os algoritmos evolutivos (*AEs*). O termo algoritmo evolutivo congrega diferentes abordagens baseadas na simulação de vários aspectos da evolução. Essas técnicas têm fundamentalmente em comum os processos de reprodução, variação aleatória, competição e seleção de indivíduos em uma população (Bäck et al., 2000). O pseudo-código 7 mostra as etapas básicas de um algoritmo evolutivo (Michalewicz, 1996).

Um algoritmo evolutivo é um método probabilístico que trabalha com uma população de indivíduos representando soluções potenciais para o dado problema. A população inicial  $P(0) = \{x_1^0, x_2^0, \dots, x_n^0\}$  é gerada, usualmente de forma aleatória (linha 2). A cada indivíduo  $x_i^0 \in P(0)$  é associada uma medida de sua “adaptação” (ou *fitness*) determinada por meio de uma função de avaliação (linha 3), então, iterativamente alguns indivíduos são selecionados probabilisticamente em

---

**Pseudo-código 7** Algoritmo Evolutivo

---

```
1:  $t \leftarrow 0$ 
2: inicializar  $P(t)$ 
3: avaliar  $P(t)$ 
4: enquanto não atingir a condição de parada faça
5:    $t \leftarrow t + 1$ 
6:   selecionar  $P(t)$  de  $P(t - 1)$ 
7:   alterar  $P(t)$ 
8:   avaliar  $P(t)$ 
9: fim enquanto
```

---

função de seu *fitness* (linha 6). A partir desses indivíduos são gerados novos indivíduos por meio dos operadores de recombinação e mutação (linhas 6 e 7). Os novos indivíduos são avaliados (linha 8), formando uma nova população que substituirá a anterior (Bäck et al., 2000). Esse processo é repetido até atingir uma condição de parada e espera-se que o melhor indivíduo da população represente uma solução considerada “boa” para o problema (Michalewicz, 1996).

## 5.3 Algoritmos Genéticos para o problema

Os algoritmos genéticos (*AGs*), propostos inicialmente por Holland (1975), enfatizam a recombinação como operador de busca mais importante. A mutação algumas vezes é tratada como um operador secundário, para buscar assegurar que a população consistirá de características diversas que poderão ser exploradas na recombinação (Bäck et al., 2000). Essa é a principal característica que diferencia os *AGs* das demais classes de algoritmos evolutivos.

Nas seções seguintes serão discutidos os principais pontos de um algoritmo genético, apresentando-se em seguida as escolhas feitas para a aplicação dos conceitos ao problema de planejamento de manutenção em *SDEE*.

### 5.3.1 A representação dos indivíduos

Em algoritmos genéticos a estrutura de uma solução pode ser representada de diversas formas. A representação adotada para um problema influencia a definição do espaço de busca deste problema e normalmente tem um impacto na eficiência do método de busca (Bäck et al., 2000).

Michalewicz (1996) comenta que a representação de um indivíduo na população e os operadores utilizados para alterar seu conteúdo são interdependentes e correspondem aos dois componentes principais em um *AE*. Sendo assim, as decisões quanto à escolha desses componentes deve ser feita considerando a ligação de dependência entre eles.

No AG desenvolvido para o problema de planejamento de manutenção em *SDEE*, adotou-se como representação para os indivíduos um vetor de números reais (Fig. 5.1). Cada elemento da rede de distribuição sujeito a manutenções possui uma posição (locus) neste vetor, indicando o valor do investimento destinado à manutenção desse elemento. A Fig. 5.1 mostra que o investimento dos elementos foi normalizado; assim, este estará no intervalo entre 0 e 1, independente do tipo dos elementos.

$$\begin{array}{|c|c|c|c|} \hline inv_{e_1} & inv_{e_2} & \dots & inv_{e_n} \\ \hline e_1 & e_2 & & e_n \\ \hline \end{array} \quad inv_{e_i} \in [0, 1]$$

Fig. 5.1: Representação das soluções no algoritmo genético

Problemas reais naturalmente impõem restrições sobre as variáveis de decisão de seus modelos. As restrições fazem com que certas configurações das variáveis de decisão não correspondam a soluções factíveis para o problema e, dessa forma, não tenham valor como resultado da busca. Segundo Michalewicz e Fogel (2002), é difícil em *AEs* o desenvolvimento de operadores que evitem totalmente a geração de indivíduos infactíveis enquanto ainda são eficazes na determinação de soluções factíveis de qualidade. Assim, durante o processo de busca deve-se prever o tratamento de indivíduos factíveis e infactíveis.

Uma maneira de tratar a infactibilidade em algoritmos genéticos é através de decodificadores. Nessa abordagem, a estrutura de um indivíduo não representa diretamente uma solução, mas possui dados para a construção de uma solução factível (Michalewicz e Fogel, 2002). Um indivíduo corresponde ao genótipo de uma solução que é mapeada para um determinado fenótipo para sua avaliação.

A representação real adotada no AG desenvolvido para abordar o problema de manutenção de *SDEE* corresponde ao genótipo dos indivíduos. A utilização dessa representação permite a decisão de quanto de recursos destinar para cada elemento, sem decidir diretamente quais ações programar para os elementos. O mapeamento do investimento para as ações preventivas é realizado pelo procedimento de decodificação, discutido a seguir.

A decodificação é um procedimento determinístico que percorre os elementos em uma seqüência determinada pelas suas prioridades. A prioridade de cada elemento é calculada através da Equação 5.1 e estabelece a seqüência da programação das ações em função do investimento programado e ainda não alocado. A seqüência da escolha dos elementos é importante porque o procedimento de decodificação explora apenas um subconjunto dos elementos, suficiente para a construção de uma solução factível. O objetivo desta estratégia é evitar o aumento do custo da solução após a factibilização, visto que o problema é formulado para minimizar custos.

$$P_e = inv_e - invJaAlocado_e \quad (5.1)$$

Na Equação 5.1  $inv_e$  é o investimento destinado ao elemento  $e$  e  $invJaAlocado_e$  é o investimento já alocado ao elemento  $e$ .

O procedimento de decodificação, detalhado no Pseudo-código 8, possui duas fases. A primeira fase (entre as linhas 2 e 12) programa ações para os elementos em função do investimento alocado. A segunda fase (entre as linhas 13 e 21) é executada no caso da fase anterior não ter conseguido gerar uma solução factível. Esta fase consiste na busca pela factibilização da solução, aumentando o nível de manutenção de um elemento selecionado a cada iteração de acordo com a prioridade calculada através da Equação 5.1.

---

**Pseudo-código 8** Decodificação( $gen$ )
 

---

```

1:  $cont \leftarrow 0$ 
2: repita
3:   escolha um  $e \in E | P_e > P_i \quad \forall i \in E$  (equação 5.1)
4:    $inv \leftarrow gen[e]$ 
5:    $nivel\_Manutencao \leftarrow ObtemNivel\_Manutencao(inv, e)$ 
6:    $acoes \leftarrow ObtemAcoes(nivel\_Manutencao)$ 
7:   para  $t \leftarrow 1$  até  $HP$  faça
8:      $n \leftarrow acoes^t$ 
9:      $fen_{en}^t \leftarrow 1$ 
10:  fim para
11:   $cont \leftarrow cont + 1$ 
12: até que ( $fen$  é factível) ou ( $cont > |E|$ )
13: enquanto ( $fen$  não é factível) faça
14:   escolha um  $e \in E | P_e > P_i \quad \forall i \in E$  (equação 5.1)
15:    $nivel\_Manutencao \leftarrow ObtemProximoNivelAcoes(fen, e)$ 
16:    $acoes \leftarrow ObtemAcoes(nivel\_Manutencao)$ 
17:   para  $t \leftarrow 1$  até  $HP$  faça
18:      $n \leftarrow acoes^t$ 
19:      $fen_{en}^t \leftarrow 1$ 
20:  fim para
21: fim enquanto
Return:  $fen$ 

```

---

Nas linhas 5 e 15 do procedimento de decodificação, determina-se o nível de manutenção para o elemento escolhido. Esse nível corresponde às ações que serão determinadas para o elemento, por exemplo: duas manutenções mínimas e uma manutenção intensiva. Na linha 5 o nível de manutenção escolhido é aquele com o custo equivalente ao investimento disponível, enquanto que na linha 15 o nível de manutenção escolhido é o nível seguinte ao atual programado para o elemento, ou seja, o nível com o custo imediatamente superior ao programado, obtido da mesma forma apresentada na Seção 4.4.1. A Tab. 4.1 da Seção 4.4.1 é novamente apresentada a seguir para esclarecer o conceito de

nível de manutenção adotado no trabalho. No exemplo ilustrado nesta tabela, existem três possíveis ações de manutenção com custos 0, 10 e 15 respectivamente. Pode-se observar que um nível de manutenção corresponde a uma configuração de três ações, dado o horizonte de planejamento de três anos.

Tab. 5.1: Exemplo dos níveis de manutenção para um elemento, considerando um horizonte de planejamento de três anos

Nível	NM <sup>a</sup>	MM <sup>b</sup>	MI <sup>c</sup>	Custo
1	3	0	0	0
2	2	1	0	10
3	2	0	1	15
4	1	2	0	20
5	1	1	1	25
6	1	0	2	30
7	0	2	1	35
8	0	1	2	40
9	0	0	3	45

<sup>a</sup>Número de ações do tipo 'Nenhuma manutenção'.

<sup>b</sup>Número de ações do tipo 'Manutenção mínima'.

<sup>c</sup>Número de ações do tipo 'Manutenção intensiva'.

A função *ObtemAcoes()*, nas linhas 6 e 16 do procedimento de decodificação, define quando as ações determinadas no passo anterior devem ser programadas dentro do horizonte de planejamento. Essa função faz a escolha examinando todas as permutações das ações. A permutação escolhida é aquela que resultar na maior redução na infactibilidade da solução.

O procedimento de decodificação é ilustrado a seguir em um problema com três elementos, em um horizonte de planejamento de um ano. Foi usado um horizonte de planejamento igual a um para simplificar o exemplo, pois isso torna desnecessária a exploração das permutações das ações dos níveis de manutenção (linhas 6 e 16 do pseudo-código 8).

No exemplo, utiliza-se o vetor apresentado na Fig. 5.2 como o genótipo da solução a ser mapeada e adota-se o valor 1,2 como o *FEC* máximo permitido ( $FEC_{perm}$ ) e o mesmo valor para o *FEC* inicial (*FEC* no período  $t = 0$ ). O *FEC* atual é calculado através da Equação 5.2. A Equação 5.2 é uma simplificação da Equação 3.4 (Página 19), é utilizada para calcular o *FEC* em função da variação do *FEC* de cada elemento no período, evitando refazer todos os cálculos a cada alteração na solução.

$$FEC^t = FEC^{t-1} + \Delta FEC_{e_1}^t + \Delta FEC_{e_2}^t + \Delta FEC_{e_3}^t \quad (5.2)$$

Sendo:

- $FEC^{t-1}$  o *FEC* inicial, no período 0;

- $\Delta FEC_{e_i}^t$  a variação no  $FEC$  relativa às ações programadas para o elemento  $e_i$ .

$e_1$	$e_2$	$e_3$
0,5	0,7	0,9

Fig. 5.2: Genótipo da solução para o exemplo do processo de decodificação

Observe na Fig. 5.2 que o investimento de cada elemento está no intervalo entre 0 e 1, assim como o custo dos níveis de manutenção na Fig. 5.3. A normalização destes valores é importante no processo de decodificação para permitir a comparação entre a prioridade dos elementos independentemente do custo real das ações de manutenção.

Na Fig. 5.3, abaixo dos níveis de manutenção, são mostrados os cálculos das prioridades  $P_{e_i}$  para cada elemento  $e_i$  nesta situação inicial.

elemento 1			elemento 2			elemento 3		
nível	custo	$\Delta FEC$	nível	custo	$\Delta FEC$	nível	custo	$\Delta FEC$
1	0	+0,03	1	0	+0,01	1	0	+0,06
2	0,60	-0,03	2	0,53	-0,02	2	0,40	-0,04
3	1,00	-0,08	3	1,00	-0,05	3	1,00	-0,09

$P_{e_1} = 0,50 - 0,00 = 0,50$     
 $P_{e_2} = 0,70 - 0,00 = 0,70$     
 $P_{e_3} = 0,90 - 0,00 = 0,90$

$$FEC^1 = 1,30$$

Fig. 5.3: Nível inicial de manutenção no exemplo do procedimento de decodificação

A decodificação inicia com todos os elementos no menor nível de manutenção, sem nenhuma ação preventiva programada, conforme o fenótipo apresentado na Fig. 5.3, e aumenta os investimentos até atingir a factibilidade da solução. A escolha dos elementos é realizada de forma determinística, em função da prioridade. Na primeira iteração, o elemento escolhido é o terceiro por sua prioridade ser maior. Este elemento passa ao terceiro nível de manutenção, porque este é o nível com custo mais próximo do investimento destinado a ele. O fenótipo resultante dessa alteração é apresentado na Fig. 5.4. A solução parcial ainda é infactível ( $FEC^1 < FEC_{perm}$ ). Por isso, é realizada mais uma iteração destinando recursos ao elemento 2, que possui a maior prioridade.

A Fig. 5.5 apresenta o fenótipo associado à solução final do processo de decodificação que representa uma solução factível para o problema encontrada no segundo passo do procedimento de decodificação. Observe que, apesar do investimento para o elemento 1 ser diferente de 0 no genótipo,

elemento 1			elemento 2			elemento 3		
nível	custo	$\Delta FEC$	nível	custo	$\Delta FEC$	nível	custo	$\Delta FEC$
1	0	+0,03	1	0	+0,01	1	0	+0,06
2	0,60	-0,03	2	0,53	-0,02	2	0,40	-0,04
3	1,00	-0,08	3	1,00	-0,05	3	1,00	-0,09

$P_{e_1} = 0,50 - 0,00 = 0,50$     
 $P_{e_2} = 0,70 - 0,00 = 0,70$     
 $P_{e_3} = 0,90 - 1,00 = -0,10$

$FEC^1 = 1,21$

Fig. 5.4: Nível de manutenção no exemplo do procedimento de decodificação após iteração 1

elemento 1			elemento 2			elemento 3		
nível	custo	$\Delta FEC$	nível	custo	$\Delta FEC$	nível	custo	$\Delta FEC$
1	0	+0,03	1	0	+0,01	1	0	+0,06
2	0,60	-0,03	2	0,53	-0,02	2	0,40	-0,04
3	1,00	-0,08	3	1,00	-0,05	3	1,00	-0,09

$P_{e_1} = 0,50 - 0,00 = 0,50$     
 $P_{e_2} = 0,70 - 0,53 = 0,17$     
 $P_{e_3} = 0,90 - 1,00 = -0,10$

$FEC^1 = 1,19$

Fig. 5.5: Nível de manutenção no exemplo do procedimento de decodificação após iteração 2

ele continua no nível 1 de manutenção, porque a factibilidade foi atingida sem precisar programar manutenções para ele.

Uma situação que pode ocorrer após mapear os investimentos de todos os elementos em ações de manutenção é que não seja atingida a factibilidade. Nesse caso, é executada a segunda parte do procedimento de decodificação (trecho entre as linhas 13 e 21 do pseudo-código 8), que corresponde a um procedimento para factibilizar a solução.

A Equação 5.1 tem uma grande importância no procedimento de decodificação por determinar a ordem de alocação de recursos aos elementos. Esta ordem tem um impacto mais significativo quando o horizonte de planeamento é maior do que um ano, nesta situação, os primeiros elementos escolhidos tenderão a receber mais recursos de manutenção nos primeiros anos por proporcionar um aumento da confiabilidade em um período maior de tempo. Em outras palavras, com um horizonte de planeamento maior do que um a ordem de decodificação pode levar a soluções diferentes.

Uma estratégia para a escolha dos elementos avaliando o custo/benefício, como é feito na heurística construtiva, poderia levar a soluções melhores. No entanto, a estratégia adotada no trabalho tem

a vantagem de ser rápida. A velocidade da decodificação das soluções é importante visto que este componente do AG teve uma significativa contribuição com o consumo de tempo do método. Porém, a heurística para determinar a escolha dos elementos para decodificação é um aspecto que pode ser explorado, possivelmente contribuindo para melhorar os resultados do AG.

Vale ressaltar que uma mesma solução pode ser codificada de mais de uma forma neste AG, ou seja, um mesmo fenótipo pode ser construído a partir de genótipos diferentes. Apesar disso, a presença na população de indivíduos diferentes que codificam a mesma solução será reduzida pela estratégia lamarckista adotada neste trabalho.

Na abordagem lamarckista ganhos dos indivíduos pela “aprendizagem” são mapeados de volta no genótipo e, assim, podem ser usados na produção de novos indivíduos. Esse processo é proposto na teoria evolutiva de Lamarck, que afirma que características adquiridas durante a vida dos pais são passadas para os filhos (Bäck et al., 2000).

Esse processo de mapeamento inverso não é aceito como mecanismo que ocorre realmente na natureza (Bäck et al., 2000), mas pode ser usado nos algoritmos evolutivos para permitir a exploração direta de características inseridas nos indivíduos, através de algum procedimento de alteração do seu fenótipo.

No AG desenvolvido, alterações no fenótipo dos indivíduos podem ocorrer em dois momentos: o primeiro é na decodificação dos indivíduos, como comentado anteriormente; o segundo é na aplicação da busca local, após a geração de cada novo indivíduo, como será apresentado na Seção 5.3.6.

### 5.3.2 Avaliação dos indivíduos da população

O procedimento de decodificação, discutido anteriormente, é necessário para determinar uma solução a partir do genótipo codificado em um indivíduo da população, para permitir a avaliação desta solução e possibilitar a orientação do processo de busca.

Uma solução do modelo do problema é avaliada pela soma dos custos das ações preventivas programadas, somado à penalização sobre o custo de manutenções corretivas, conforme a Equação 3.6, presente na página 20. O objetivo no modelo é reduzir o valor obtido por esta equação, entretanto, conceitualmente, os AGs trabalham buscando maximizar uma função de aptidão dos indivíduos. Para compatibilizar este conceito podemos considerar a função de aptidão como apresentado na Equação 5.3, tratando no AG o problema como de maximização. Na equação 5.3  $F(solucão)$  representa a função objetivo do modelo (Equação 3.6).

$$\frac{1}{F(solucão)} \quad (5.3)$$

### 5.3.3 Inicialização da população

A geração aleatória é uma alternativa simples de inicializar os indivíduos da população em um AG. Entretanto, geralmente são disponíveis informações que podem auxiliar a construção de boas soluções iniciais para o método (Michalewicz e Fogel, 2002). O uso de tais informações pode levar a um ganho de tempo na resolução do problema, mas deve-se evitar baixa diversidade na população inicial, para não permitir uma convergência prematura.

A população no AG para o problema de manutenção foi criada com a utilização da heurística construtiva descrita na Seção 4.4.1. Como apresentado anteriormente, esse procedimento é guloso com aleatoriedade, fazendo a escolha a cada passo da construção em uma lista restrita de elementos. O tamanho dessa lista define o grau de aleatoriedade do procedimento. O objetivo deste método foi gerar boas soluções iniciais para o AG porém, garantindo diversidade na população, para possibilitar uma boa exploração do espaço de busca.

### 5.3.4 Operadores de recombinação e mutação

A busca no espaço de soluções em AGs é realizada basicamente através dos operadores de recombinação e mutação. Enquanto a mutação gera soluções com características “novas”, a recombinação limita-se a explorar combinações entre o conjunto de características presentes na população — com maior probabilidade para as características das melhores soluções.

Adotou-se para o problema de planejamento de manutenção o *crossover* aritmético, em conformidade com a escolha da representação por vetores reais. Esse *crossover* gera o novo indivíduo,  $I'$ , como uma combinação linear dos indivíduos pai (Michalewicz, 1996) usando um vetor auxiliar  $\beta$ , sendo  $\beta_i \in [0 \ 1]$ . Esta alternativa de *crossover* permite explorar no AG níveis de manutenção de características hereditárias intermediárias, em relação às dos pais. Em uma nova solução pode ser que o melhor investimento para um elemento  $e$  qualquer não seja o definido no pai 1 ( $I_e^1$ ), nem no pai 2 ( $I_e^2$ ), mas um valor  $I'_e \in [I_e^1 \ I_e^2]$ .

O operador de mutação adotado gera um novo indivíduo  $I'$  provocando uma perturbação em cada posição  $e$  do vetor real que codifica um novo indivíduo conforme a Equação 5.4.

$$I'_e = \begin{cases} I_e^i + \cup(-\Delta \ \Delta) & \text{se } \tau \leq \rho \\ I_e^i & \text{caso contrário} \end{cases} \quad \forall e \in E \quad (5.4)$$

Na equação 5.4,  $\tau$  é um número aleatório no intervalo  $[0 \ 1)$ ,  $\rho$  é a taxa de mutação (parâmetro do AG que determina a probabilidade da ocorrência de mutação),  $\Delta$  define a variação máxima permitida,  $E$  é o conjunto de elementos do problema e  $\cup(-\Delta \ \Delta)$  é um valor aleatório no intervalo  $(-\Delta \ \Delta)$ .

Com a execução do AG, o intervalo de valores do investimento para cada elemento vai dimin-

uindo com a convergência das soluções na população. Esta estratégia de mutação busca aumentar esse intervalo reintroduzindo diversidade na população (principal objetivo da mutação em algoritmos genéticos).

### 5.3.5 Atualização da população

A abordagem mais usual para a atualização da população em um *AG* é a *generational*, onde a população é substituída como um todo a cada iteração, por novos indivíduos gerados. Com essa estratégia pode-se descartar boas soluções, impedindo que continuem participando da busca (Reeves, 2003).

Em um *AG* que usa a estratégia *steady-state* um indivíduo (ou às vezes um par de indivíduos) é gerado a cada iteração. Esse novo indivíduo é inserido na população no lugar de outro escolhido para ser removido (Reeves, 2003). Nessa abordagem, indivíduos podem permanecer na população indefinidamente, “concorrendo” com seus descendentes. Apesar de evitar a perda de indivíduos bons, essa estratégia pode levar o *AG* a perder diversidade rapidamente. A convergência prematura pode ser evitada, ou retardada, impedindo a inserção de indivíduos duplicados na população ou inserindo o novo indivíduo no lugar de um de seus pais (Bäck et al., 2000).

O *AG* desenvolvido usa a estratégia *steady-state* inserindo o novo indivíduo no lugar de seu pior pai, no caso deste ter um *fitness* menor do que o novo indivíduo; caso contrário o novo indivíduo é descartado. Assim, são mantidos na população os dois melhores indivíduos dentre os três relacionados à recombinação, inserindo um número menor de características “redundantes” no espaço a ser explorado pelo *AG*.

### 5.3.6 Hibridização

A busca de soluções realizada por um *AG* pode ser melhorada com a incorporação de características adicionais ao modelo de um *AG* clássico (Reeves, 2003). Essas extensões geralmente são chamadas de algoritmos genéticos híbridos e são determinadas pela incorporação de uma ou mais dentre as seguintes características: buscas locais, representações e operadores específicos para o problema e heurísticas para a inicialização da população inicial (Bäck et al., 2000).

No método evolutivo proposto caracterizou-se a hibridização com a adoção de uma representação e operadores adaptados ao problema (seções 5.3.1 e 5.3.4), com a utilização de uma heurística para a inicialização da população (seção 5.3.3) e também, com a inclusão de uma busca local para a exploração local do espaço de busca, como será apresentado a seguir.

Em Merz (2000), uma busca local é aplicada em cada nova solução gerada — tanto na inicialização quanto após a recombinação e mutação. Em um *AG* esse procedimento pode ser muito custoso

computacionalmente para ser executado a cada iteração.

Lim et al. (2000) utilizam uma busca local “parcial”, onde o procedimento pára em um determinado número de iterações. O objetivo desta estratégia para incorporação de buscas locais em AGs é realizar algumas iterações de exploração local, sem, entretanto, comprometer o tempo de resposta do AG.

A *BL* incorporada no AG deste trabalho utiliza os mesmos movimentos apresentados no Pseudo-código 6 da Seção 4.4.2. Esses movimentos tentam reduzir os custos das soluções, buscando realocar o investimento entre pares de elementos em ações que sejam mais efetivas (contribuam mais para a redução do *FEC*). Os passos dessa busca são apresentados a seguir.

---

**Pseudo-código 9** Busca\_LocalParcial(*solucao*)

---

```

1: Inicializar  $E'$ 
2: para  $\forall e \in E'$  faça
3:   para  $\forall f \in E'$  faça
4:      $mov \leftarrow buscar\_MelhorMovimento(e, f)$  (pseudo-código 6 na seção 4.4.2)
5:     se  $mov$  melhora a solução solucao então
6:        $solucao \leftarrow executar\_Movimento(solucão, mov)$ 
7:        $melhorou \leftarrow true$ 
8:     fim se
9:   fim para
10: fim para
Return: solucao

```

---

A diferença desta *BL* para àquela utilizada no *GRASP* está no número de pares de elementos explorados. A *BL* do *GRASP* testa todos os pares, enquanto a *BL* do AG testa apenas um subconjunto dos elementos. Este subconjunto é formado por aqueles elementos com um desvio entre o investimento alocado nos dois pais selecionados para recombinação. Essa estratégia reduz o número de pares testados pela *BL* de  $|E| * |E|$  para  $|E'| * |E'|$ , sendo  $E'$  um subconjunto de  $E$  formado pelos elementos  $e \in E$  tais que  $I_e^1 \neq I_e^2$ , sendo  $I_e^1$  e  $I_e^2$  o investimento alocado ao elemento  $e$  pelas soluções pai 1 e 2, respectivamente.

A idéia principal dessa estratégia para redução do espaço de busca da *BL* é concentrar os esforços apenas nos elementos para os quais o investimento ainda não tenha convergido para um determinado valor.

Ao invés de executar poucas iterações de *BL*, poderia ter sido adotada no AG a estratégia de aplicar buscas locais completas em um conjunto reduzido de soluções da população. Entretanto, esta alternativa poderia ser elitista ou tendenciosa. Por isso, adotou-se a estratégia descrita anteriormente, permitindo a exploração igualitária das soluções.

### 5.3.7 Operador de seleção

A seleção é o filtro pelo qual um AG determina a composição da próxima geração baseado na qualidade de cada indivíduo (Michalewicz e Fogel, 2002). Dentre os vários métodos de seleção encontrados na literatura está a seleção por torneio. Na seleção por torneio um grupo de indivíduos é escolhido aleatoriamente na população. Esse grupo participa de um torneio que determina o indivíduo vencedor dependendo de seu *fitness*; normalmente, o indivíduo com maior *fitness* é escolhido deterministicamente (Bäck et al., 2000). Esse método foi o adotado no AG, particularmente envolvendo no torneio apenas dois indivíduos (torneio binário).

### 5.3.8 Critério de parada

Em um AG deve haver uma condição para determinar quando a busca deve parar. Essa condição pode ser simplesmente um número máximo de iterações, ou algum critério que verifique a convergência da população.

Basicamente, a convergência em um AG pode ser verificada de duas formas: pela diversidade de características na população ou medindo o progresso feito pelo método em um número pré-definido de iterações; se esse progresso for menor do que um parâmetro  $\varepsilon$ , a busca deve parar.

O AG proposto utiliza o critério de parada por número de iterações (parâmetro *NumIt*) e também por convergência (parâmetro  $\varepsilon$ ) acompanhando o progresso da busca.

### 5.3.9 Parâmetros

Um AG possui um conjunto de parâmetros cujos valores devem ser iniciados de forma adequada às dimensões e demais características das instâncias específicas do problema. No caso do método desenvolvido, esses parâmetros são: o tamanho da população (*tamPop*), a taxa de mutação ( $\rho$ ), o número máximo de iterações (*NumIt*) e o progresso mínimo ( $\varepsilon$ ) no AG e o tamanho da lista *RCL* ( $\alpha$ ) na heurística construtiva.

Uma observação importante é que a taxa de recombinação não foi considerada um parâmetro; seu valor foi iniciado em 1 para forçar a recombinação a cada iteração do AG e evitar a inserção de indivíduos duplicados na população.

Os valores para os parâmetros foram determinados empiricamente, para cada caso de teste. Esses valores serão apresentados no Capítulo 6, juntamente com os resultados dos demais experimentos realizados.

## 5.4 Comentários

Este capítulo descreveu o *AG* desenvolvido para a resolução do modelo de planejamento de manutenção em *SDEE*, apresentado no Capítulo 3. O *AG* adotou um vetor de números reais como representação das soluções, o que permitiu a aplicação de operadores rápidos de reprodução e mutação beneficiando o tempo de resposta do método. A utilização dessa representação dividiu o problema em duas partes: os operadores genéticos têm a responsabilidade de definir o investimento para os elementos sem, entretanto, decidir sobre as ações de manutenção; o mapeamento do investimento (genótipo) em planos de manutenção (fenótipo) é realizado pelo procedimento de decodificação, responsável por “traduzir” os valores em níveis de manutenção e, em seguida, definir a melhor permutação das ações dentro do horizonte de planejamento.

No *AG* incorporou-se a heurística construtiva e a busca local desenvolvidos para o método *GRASP*. A heurística construtiva foi utilizada para a inicialização da população e a busca local para a exploração de novas soluções geradas pelos operadores genéticos.

A busca local do *AG* usa o mesmo movimento da busca local do *GRASP*, porém, no *AG* não são explorados todos os elementos. No *AG* foi necessário definir um critério para reduzir o espaço de busca da *BL* e viabilizar sua incorporação, pois se observou no *GRASP* que a fase de melhoramento consumia grande parte dos recursos computacionais utilizados pelo método<sup>1</sup>.

A solução proposta para evitar que a busca local comprometesse o desempenho computacional do *AG* foi reduzir a exploração a um subconjunto dos elementos (aqueles que divergem no investimento alocado). Procura-se, desta forma, que a busca local se concentre nos elementos para os quais a busca realizada pelo *AG* como um todo ainda não tenha conseguido determinar uma boa programação de investimento.

O capítulo seguinte mostra uma análise dos métodos apresentados neste capítulo e no anterior, comparando seus resultados e discutindo os aspectos que contribuiram para o *AG* ter alcançado resultados melhores do que o *GRASP*.

---

<sup>1</sup>Será apresentada uma análise dos tempos dos métodos no Capítulo 6.

# Capítulo 6

## Estudos de casos

### 6.1 Introdução

Este capítulo apresenta os três casos de teste utilizados nos experimentos realizados como parte deste trabalho, discutindo em seguida, estes experimentos, que tiveram como primeiro objetivo justificar e avaliar dois pontos do modelo do problema: a adoção de um peso sobre o risco de manutenções corretivas e a consideração de um horizonte maior do que um ano para realizar o planejamento do primeiro ano, avaliando o impacto nos anos seguintes. Ao final do capítulo, o *GRASP* e o *AG* são avaliados na resolução dos casos de teste, tendo seus desempenhos comparados quanto aos resultados alcançados e os tempos de processamento.

### 6.2 Casos de teste

A inexistência na literatura de dados suficientes para o problema de planejamento de manutenção em *SDEE* exigiu, em uma fase inicial do trabalho, a criação de casos de teste. Esta seção apresenta esses casos de teste descrevendo como foram construídos. Um objetivo complementar desta seção é, enquanto se discute os dados dos problemas, esclarecer alguns pontos do modelo apresentado nas seções anteriores.

Os dados que compõem os casos de teste foram classificados em dois grupos: dados da rede e dados de manutenção. Os dados da rede correspondem aos dados da estrutura do sistema (equipamentos, comprimento dos condutores e número de consumidores), enquanto os dados de manutenção incluem os dados para o tratamento do problema de planejamento de manutenção (taxas de falha iniciais dos elementos, multiplicadores de taxas de falha e custos de manutenções preventiva e corretiva associados a cada tipo de elemento). As seções seguintes descrevem como esses dados foram determinados.

### 6.2.1 Dados da rede

Os dados das redes utilizados nos casos de teste foram obtidos de redes reais de grande porte. A Tabela 6.1 apresenta as dimensões das redes utilizadas nos casos de teste.

Tab. 6.1: Dados das redes utilizadas nos casos de testes

	número de nós	número de arcos	número de alimentadores
Caso de Teste I	2568	2596	5
Caso de Teste II	1294	1313	3
Caso de Teste III	5718	5832	27

Na construção dos casos as seguintes considerações foram feitas:

1. As ações preventivas são podas de árvores em seções da rede e manutenções em transformadores, religadores e chaves fusíveis;
2. Religadores e chaves fusíveis são equipamentos de proteção que atuam na rede para o isolamento automático das falhas.

Os dois pontos anteriores são importantes para determinação da dimensão dos casos de teste (número de elementos sujeitos à manutenção) e para determinação das seções da rede, respectivamente, e desta forma estabelecer a dimensão dos efeitos das falhas na perda do fornecimento.

A Tabela 6.2 apresenta o número de elementos, o comprimento dos condutores e o número de consumidores das redes, para os três casos de teste.

Tab. 6.2: Dados das redes

	CT1	CT2	CT3
Comprimento (km)	559,606	212,578	348,274
Demanda total (kW)	22313	26311	79538
Transformadores	1435	802	1678
Religadores	7	4	6
Chaves fusível	473	146	258
Seções	481	151	265
Total Elementos	2396	1103	2207

O número de consumidores ligados aos transformadores é um parâmetro necessário no modelo para o cálculo do *FEC*, conforme apresentado na Seção 3.3 do Capítulo 3. A ausência desses dados foi tratada no trabalho adotando a demanda nos transformadores no lugar do número de consumidores. A demanda não representa o número de consumidores mas é um parâmetro semelhante a este no que diz

respeito à ponderação das seções para o cálculo do *FEC*, ou seja, uma demanda maior, assim como um maior número de consumidores em uma seção, pode ser uma medida da importância relativa dessa seção.

### 6.2.2 Dados de manutenção

Os dados disponíveis para a construção dos casos de teste eram aqueles apresentados na seção anterior, referentes à rede. Os demais dados, necessários para o planejamento de manutenção, precisaram ser determinados como apresentado a seguir.

#### Taxas de falha iniciais

Neste trabalho, as condições dos elementos são representadas por suas taxas de falha e seu processo de deterioração será modelado através de parâmetros chamados multiplicadores de taxa de falha. Tais parâmetros determinam a taxa de falha em um período sobre a variação esperada desta em função da ação programada e do seu valor no período anterior. Dessa forma, são requeridos no modelo valores da taxa de falha inicial para o cálculo da taxa de falha de cada elemento.

Horton et al. (1991) desenvolveram um estudo considerando 95 alimentadores urbanos para estimar valores típicos das taxas de falha de elementos do sistema de distribuição. A Tabela 6.3 apresenta os valores de taxas de falha anuais estimados para transformadores, religadores, chaves fusíveis e cabos em alimentadores urbanos.

Tab. 6.3: Taxas de falha de componentes em alimentadores urbanos segundo estudo de Horton et al. (1991)

<i>Componente</i>	<i>taxa de falha</i>
Transformador	0,000614
Switch	0,000775
Fuse	0,00374
Capacitor	0,085
Religador	0,0144
Condutor	0,0198 <sup>a</sup>

<sup>a</sup>por milha

Os valores típicos da taxa de falha dos componentes descritos na Tabela 6.3 foram utilizados para determinar a taxa de falha inicial dos elementos nos casos de teste, através do procedimento descrito em seguida.

Os elementos de redes de distribuição reais encontram-se em estágios diferentes de deterioração, dependendo de sua idade ou da parcela de recursos de manutenção aplicada a eles. Para simular

esta condição nos casos de teste, gera-se valores iniciais de taxas de falha de forma a representar os diversos estágios de deterioração nos quais os elementos podem se encontrar.

O procedimento detalhado no pseudo-código 10 foi usado para determinar os valores iniciais da taxa de falha de cada elemento das redes nos casos de teste. Este procedimento simula a deterioração dos elementos que ocorre no sistema de distribuição em uma dada janela de tempo.

---

**Pseudo-código 10** SimulaDeterioração

---

Seja:

$TxFalha(t)$  a taxa de falha inicial dos casos de teste para o planejamento no período  $t$ ;

$HP$  o horizonte de planejamento.

1:  $HP \leftarrow 5$

2:  $p \leftarrow 1$

3:  $TxFalha(t) \leftarrow$  taxa de falha típica de acordo com a classe do elemento (tabela 6.3)

4: **enquanto**  $t \leq HP$  **faça**

5:   executar o *GRASP* sobre os casos de teste

6:    $TxFalha(t + 1) \leftarrow$  taxa de falha resultante do planejamento no período  $t$

7:    $t \leftarrow t + 1$

8: **fim enquanto**

**Return:**  $TxFalha(t)$

---

No procedimento, o próprio modelo proposto neste trabalho e um dos métodos desenvolvidos - o *GRASP* - foram utilizados para simular a variação da taxa de falha no decorrer do tempo. O planejamento foi realizado pelo *GRASP* ano a ano sequencialmente. Para o planejamento do ano 1 adotou-se como taxa de falha inicial dos elementos os valores propostos por Horton et al. (1991) (Tabela 6.3) e para os anos seguintes adotou-se a taxa de falha resultante do planejamento do ano anterior. A taxa de falha adotada nos casos de teste foi a taxa de falha resultante do planejamento no horizonte de 5 anos. Os gráficos 6.1, 6.2 e 6.3 apresentam o comportamento dos componentes da função objetivo do modelo (o custo de manutenção preventiva, *CMP*, e o custo de manutenção corretiva, *CMC*) em função do planejamento realizado a cada ano.

Como pode ser verificado nos gráficos, ambos o *CMP* e o *CMC* crescem conforme a taxa de falha dos elementos aumenta. Pode-se notar, em função do comportamento do *CMC*, que a taxa de falha cresce de forma exponencial. O crescimento da taxa de falha leva à necessidade de um maior investimento com manutenção para garantir a mesma confiabilidade ao sistema, como é notado com o crescimento do *CMP*.

Vale ressaltar que, como sugere o crescimento exponencial do *CMC* nos gráficos 6.1, 6.2 e 6.3, o modelo não incorpora manutenções corretivas no processo de decisão, ou seja, o modelo busca somente tirar o máximo do sistema em operação. A penalização da manutenção corretiva visa ponderar

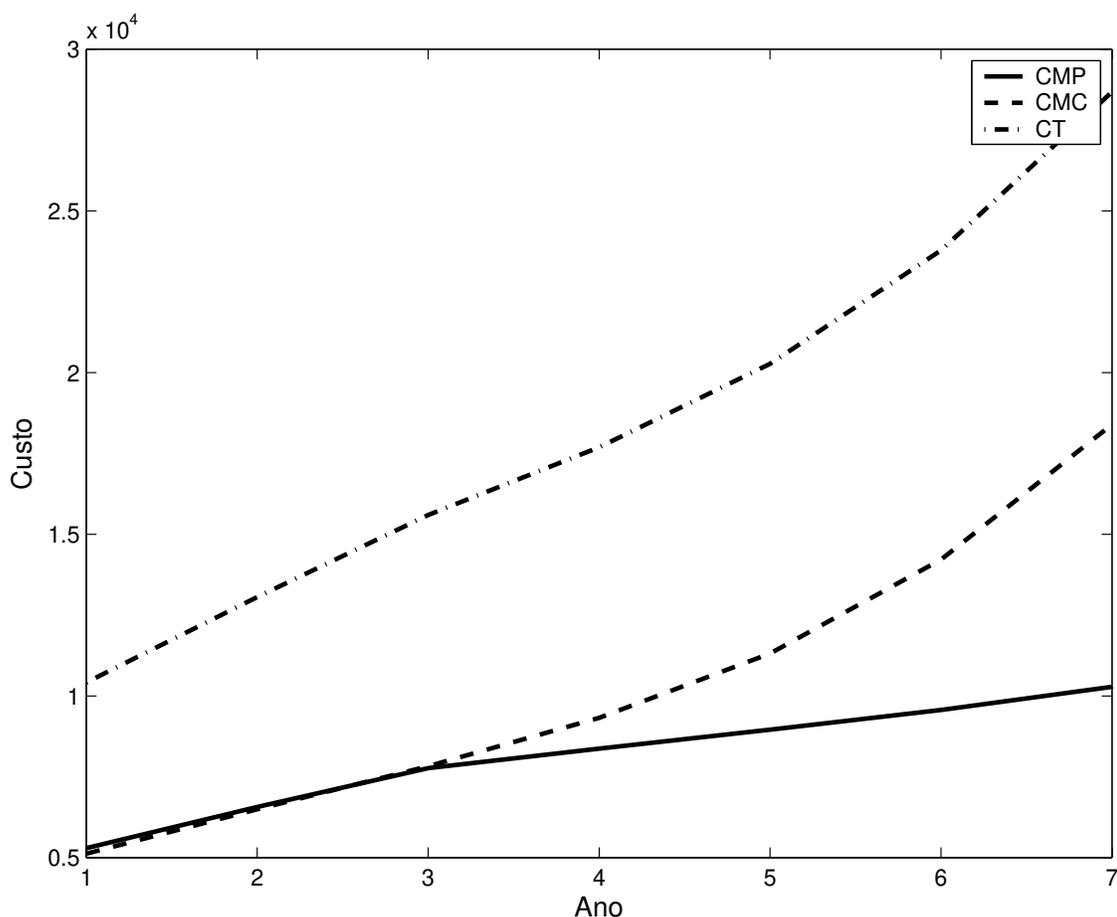


Fig. 6.1: Comportamento dos componentes da função objetivo no decorrer dos anos (Caso de teste I)

sobre o risco de gastos com ações corretivas no processo de decisão<sup>1</sup>, entretanto, essas ações não fazem parte do processo de decisão.

Os gráficos anteriores apresentam o comportamento geral do modelo quando realizado um planejamento a longo prazo, porém, é importante destacar que o multiplicador de taxa de falha não é um parâmetro preciso para modelar o processo de deterioração, e dessa forma, não é viável sua utilização para o planejamento de manutenção em um horizonte maior do que um ano devido ao erro cumulativo que poderia levar a soluções pouco realistas. Na Seção 6.3.2 alguns experimentos são realizados para avaliar o impacto em utilizar um *HP* maior do que 1 no modelo. Contudo, esse experimento tem como objetivo apenas avaliar o impacto da ponderação dos anos seguintes para o planejamento no presente e não adotar efetivamente o programa de manutenção para cada um desses anos.

<sup>1</sup>Sua importância no modelo será avaliada na seção 6.3.1.

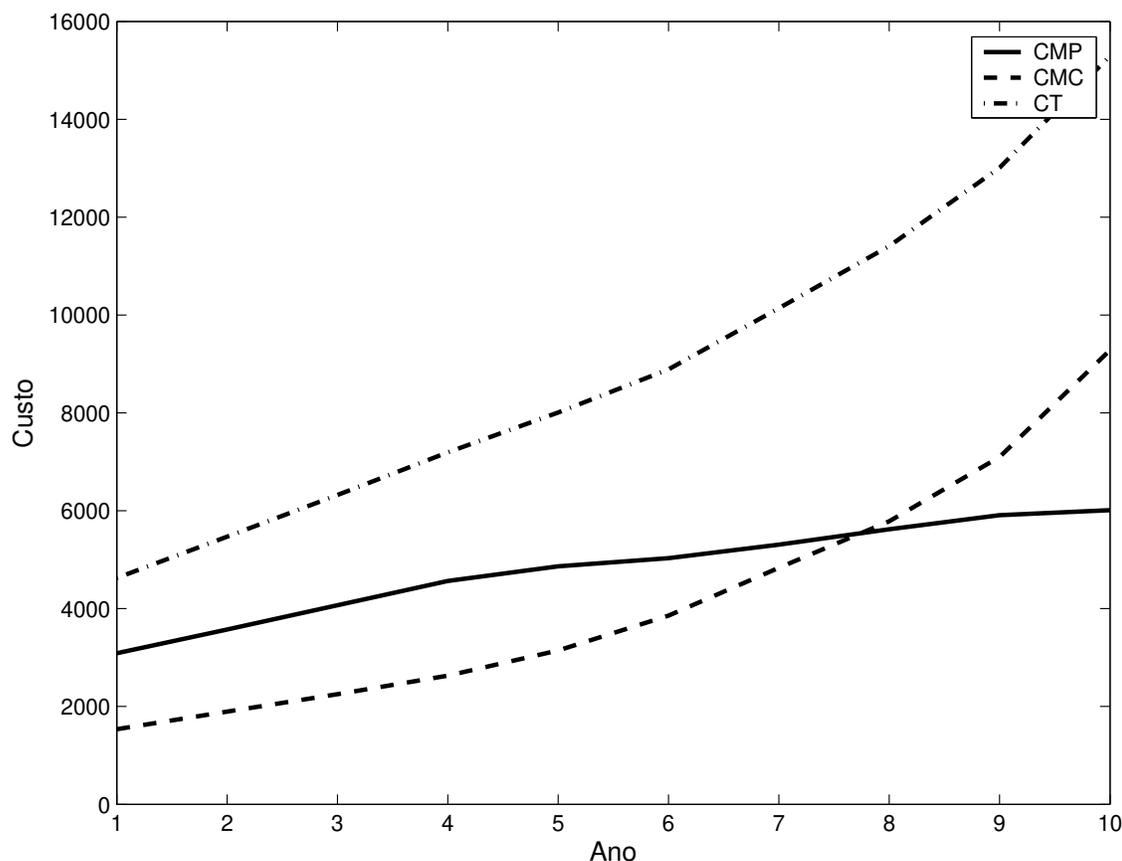


Fig. 6.2: Comportamento dos componentes da função objetivo no decorrer dos anos (Caso de teste II)

### Taxas de falha base

Cada seção da rede tem um componente da taxa de falha chamada taxa de falha base que representa a parcela da taxa de falha devido aos fatores não considerados no modelo. Esse parâmetro é tomado como um valor constante e determinado para cada seção como um valor aleatório dentro de um intervalo sobre um valor de referência. O valor de referência adotado foi 0,1 com desvio de 10%. Assim, a taxa de falha base foi determinada para cada seção como um valor aleatório no intervalo  $[0,9 \quad 1, 1]$ .

### Multiplicadores de taxa de falha

Os multiplicadores de taxa de falha foram definidos para cada classe de elementos de acordo com os valores encontrados em (Power Systems Reliability Subcommittee of the Power Systems Engineering Committee of the IEEE Industry Applications Society, 1991). Os valores adotados para os multiplicadores são apresentados nas tabelas 6.4, 6.5, 6.6 e 6.7, para cada nível de manutenção

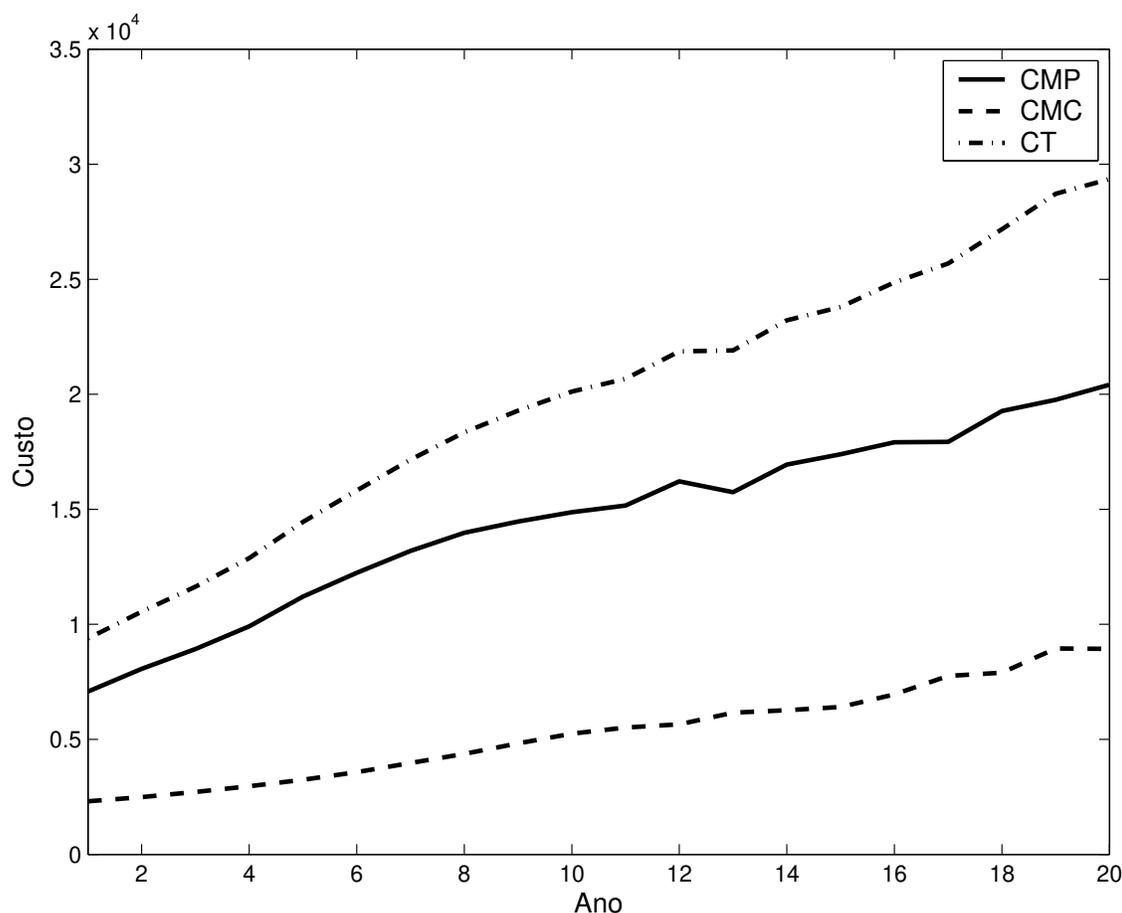


Fig. 6.3: Comportamento dos componentes da função objetivo no decorrer dos anos (Caso de teste III)

de cada classe de elementos. Tomou-se 3 ações para transformadores, chaves fusíveis e condutores e 2 ações para religadores, sendo que uma das ações para os 4 tipos de elementos corresponde a não realizar nenhuma ação preventiva.

Tab. 6.4: Dados de manutenção para os transformadores

Ação	Mult. Tx Falha	Custo
Manutenção intensiva	0,95	13
Manutenção mínima	1,05	5
Nenhuma manutenção	1,51	0
Custo Manutenção corretiva		16

Tab. 6.5: Dados de manutenção para os religadores

Ação	Mult. Tx Falha	Custo
Manutenção intensiva	0,91	9
Nenhuma manutenção	1,28	0
Custo Manutenção corretiva		19

Tab. 6.6: Dados de manutenção para as chaves fusíveis

Ação	Mult. Tx Falha	Custo
Manutenção intensiva	0,91	3,7
Manutenção mínima	1,06	0,23
Nenhuma manutenção	1,28	0
Custo Manutenção corretiva		4

Tab. 6.7: Dados de manutenção para os condutores

Ação	Mult. Tx Falha	Custo (por km)
Manutenção intensiva	0,95	25
Manutenção mínima	1,05	10
Nenhuma manutenção	1,51	0
Custo Manutenção corretiva		56

### Custos de manutenções preventivas e de manutenções corretivas

Os custos de cada possível ação preventiva como também o custo de manutenção corretiva para cada tipo de elemento estão apresentados nas tabelas 6.4, 6.5, 6.6 e 6.7. Esses valores representam as despesas com equipamentos e mão de obra para a execução das ações e foram determinados aproximadamente em função da complexidade dos elementos e das ações.

### FEC máximo permitido

O  $FEC$  máximo permitido (variável  $FEC_{perm}$  na equação 3.7 do modelo) foi escolhido verificando os valores de  $FEC_{min}$  e  $FEC_{max}$  em cada problema. O  $FEC_{min}$  é o valor mínimo do  $FEC$ , alcançado se o máximo de manutenção fosse executada. O  $FEC_{max}$  é o valor máximo do  $FEC$ , atingido se nenhuma manutenção fosse executada. O valor de  $FEC_{perm}$  foi escolhido no intervalo entre  $FEC_{min}$  e  $FEC_{max}$  (Tabela 6.8).

Normalizando o  $FEC_{perm}$  em relação ao  $FEC_{min}$  e ao  $FEC_{max}$  chegamos aos valores de 0, 148, 0, 134 e 0, 138 para os três casos de teste. Esses valores mostram o quanto a restrição 3.7 é apertada em cada um deles. De acordo com esses números, o caso de teste II é aquele que exige uma maior parte dos recursos possíveis de manutenção para atingir o índice mínimo de confiabilidade. Entretanto, como será visto nos resultados da Seção 6.3.3, a complexidade relativa entre os três casos de teste é

Tab. 6.8: Dados de manutenção para os condutores

	$FEC_{perm}$	$FEC_{min}$	$FEC_{max}$
Caso de Teste I	0,620	0,596	0,758
Caso de Teste II	0,580	0,557	0,729
Caso de Teste III	1,200	1,132	1,624

determinada em grande parte pela dimensão deste, e não pela restrição de confiabilidade.

### 6.3 Experimentos realizados

Os experimentos realizados como neste trabalho têm dois objetivos: avaliar alguns aspectos do modelo adotado do problema e comparar os dois métodos utilizados para a sua resolução.

Testes preliminares foram executados para a determinação de valores para os parâmetros do *GRASP* e do *AG*. O parâmetro ajustado do *GRASP* foi o tamanho da lista *RCL* ( $\alpha$ ). O número de iterações foi tomado como 100 para todos dos testes. Quanto ao *AG*, os parâmetros analisados foram: o tamanho da população (*tamPop*), a taxa mínima de mutação ( $\rho$ ) e o tamanho da lista *RCL* ( $\alpha$ ). Os parâmetros do critério de parada do *AG* também não foram determinados nestes testes, tendo sido adotados, respectivamente, os valores 20000 e 0,01% para o número máximo de interações (parâmetro *NumIt*) e a avaliação da convergência (parâmetro  $\varepsilon$ ).

A tabela 6.9 apresenta os valores testados para cada parâmetro. Dentre estes valores, as Tabelas 6.10 e 6.11 apresentam aqueles com os quais foram obtidos os melhores resultados. Esses valores foram adotados no trabalho, tendo sido utilizados em todos os experimentos relatados em seguida.

Tab. 6.9: Valores testados para os parâmetros do *GRASP* e do *AG*

Parâmetro	Valores testados
$\alpha$ ( <i>GRASP</i> )	0.1, 0.2, 0.4 e 0.6
$\alpha$ ( <i>AG</i> )	0.1, 0.2, 0.4 e 0.6
$\rho$ ( <i>AG</i> )	0.05, 0.1, 0.3 e 0.5
<i>tamPop</i> ( <i>AG</i> )	30, 60, 100 e 200

Tab. 6.10: Valores adotados para os parâmetros do *GRASP*

	Parâmetros
Caso de teste	$\alpha$
Caso de teste I	0,4
Caso de teste II	0,4
Caso de teste III	0,4

Tab. 6.11: Valores adotados para os parâmetros do algoritmo genético

Caso de teste	Parâmetros		
	$tamPop$	$\rho$	$\alpha$
Caso de teste I	200	0,5	0,4
Caso de teste II	60	0,1	0,4
Caso de teste III	200	0,5	0,4

A Tabela 6.11 mostra que os valores adotados para o tamanho da população e para a taxa de mutação para o caso de teste II foram inferiores àqueles adotados para os demais problemas. Esta variação dos valores dos parâmetros do AG se justifica pela diferente dimensão dos casos de teste.

Com relação à taxa de mutação, a grande variação para o caso de teste II ocorreu devido ao modo como este operador foi utilizado. Como apresentado na Equação 5.4 da Página 44, a mutação é aplicada independentemente em cada locus do genótipo, assim, quanto menor o problema maior o impacto de uma variação em um locus da solução e maior a distorção global provocada pelo operador de mutação.

Poderia ter sido adotado no AG um critério para determinar os valores dos parâmetros em função das características principais dos casos de teste, entretanto, este ponto não foi abordado ficando em aberto para trabalhos futuros.

### 6.3.1 Experimento 1: Penalização da manutenção corretiva

No problema de planejamento de manutenção o *CMP* corresponde às despesas diretas de uma solução, entretanto, existem também as despesas indiretas da adoção de um plano de manutenção, aquelas que não se referem aos custos das ações preventivas programadas mas aos possíveis custos pelo sistema não estar em uma condição 100% confiável (o custo devido a baixa confiabilidade — *CBC*). Este custo não é uma medida determinística — o risco de falhas aumenta de acordo com a deterioração dos elementos mas só decorre uma despesa quando uma falha efetivamente ocorre. No modelo determinístico adotado neste trabalho considerou-se o *CBC* no que se refere ao custo de reparo dos elementos<sup>2</sup>. Esse componente do modelo tem a função de atribuir um peso ao risco de reparo.

O experimento 1 foi realizado objetivando a avaliação do efeito da penalização da manutenção corretiva adotada na função objetivo do modelo. Para tal avaliação, foram realizados testes considerando (cenário 1) e não considerando (cenário 2) a penalização da manutenção corretiva, ambos com um horizonte de planejamento igual a um. Foram realizadas cinco execuções para cada caso de

<sup>2</sup>Como apresentado no Capítulo 3 na página 17 o *CBC* representa não só o custo de reparo mas todas as despesas decorrentes das falhas.

teste nos dois cenários. A Tabela 6.12 apresenta a média dos custos das cinco execuções em cada cenário.

Pode-se observar que a adoção do componente *CMC* na função objetivo levou a soluções com menor custo. A Tabela 6.13 apresenta a média da taxa de falha inicial de cada classe de componentes e as tabelas 6.14, 6.15 e 6.16 apresentam a variação dessa média para o planejamento de manutenções para os dois cenários. Estas três últimas tabelas mostram que no cenário com a *CMC* há um aumento da taxa de falha média das chaves fusível e dos transformadores e uma redução da taxa de falha dos condutores. A variação da taxa de falha média dos religadores é a mesma por estarem próximos das subestações e por esse motivo terem um alto impacto no *FEC*. A variação da taxa de falha das demais classes de elementos se deu para beneficiar os componentes com o maior risco de falha, no caso, os condutores que possuem taxas de falha iniciais mais de 10 vezes maiores do que os outros componentes da rede, como indicado na Tabela 6.13. Assim, pode-se afirmar que a incorporação da *CMC* na função objetivo além de levar a soluções com um menor custo também assegurou uma maior confiabilidade para a rede, garantindo uma redução maior da taxa de falha dos componentes mais críticos.

Tab. 6.12: Custo médio das cinco soluções encontradas no experimento 1 para os 3 casos de teste

Cenário	CT1	CT2	CT3
com CMC	10417,924	4626,222	9382,369
sem CMC	10727,017	4959,265	10343,597
Aumento	2,97%	7,20%	10,25%

Tab. 6.13: Média da taxa de falha inicial para cada classe de componentes

Componente	Tx Falha Inicial ( $10^{-3}$ )		
	CT1	CT2	CT3
Chaves Fusíveis	8,18	9,53	6,05
Transf.	3,89	4,16	3,36
Religadores	7,07	7,53	10,96
Condutores	108,60	122,58	121,10

### 6.3.2 Experimento 2: Horizonte de planejamento

Como já discutido, no modelo adotado o planejamento para um horizonte maior do que um ano poderia apresentar soluções não confiáveis devido à inexatidão na modelagem da confiabilidade dos elementos que se multiplicaria a cada ano do horizonte de planejamento. Contudo, pode-se utilizar um horizonte de planejamento maior do que um ano para realizar o planejamento do primeiro ano

Tab. 6.14: Variação da taxa de falha no experimento 1 para o Caso de Teste I

Componente	Tx Falha sem CMC	Tx Falha com CMC
Chaves Fusível	16,09%	18,42%
Transformadores	43,18%	45,04%
Religadores	-9,00%	-9,00%
Condutores	40,94%	39,20%

Tab. 6.15: Variação da taxa de falha no experimento 1 para o Caso de Teste II

Componente	Tx Falha sem CMC	Tx Falha com CMC
Chaves Fusível	11,92%	13,67%
Transf.	45,84%	46,38%
Religadores	-9,00%	-9,00%
Condutores	36,02%	33,21%

Tab. 6.16: Variação da taxa de falha no experimento 1 para o Caso de Teste III

Componente	Tx Falha sem CMC	Tx Falha com CMC
Chaves Fusível	10,73%	11,10%
Transformadores	45,87%	46,24%
Religadores	-9,00%	-9,00%
Condutores	33,83%	14,79%

avaliando seu impacto aproximado nos anos seguintes. O objetivo do experimento 2 foi avaliar o efeito do horizonte de planejamento na estratégia de manutenção a ser adotada no primeiro ano. Essa avaliação foi realizada em função de testes executados sobre os dois seguintes cenários:

#### Cenário 1:

- Executar o método três vezes com horizonte de planejamento igual a um iniciando a taxa de falha com o resultado da execução anterior (Figura 6.4);

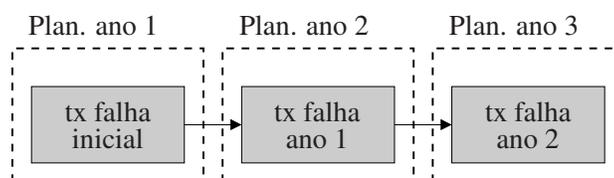


Fig. 6.4: Horizonte de planejamento no experimento 2 utilizando o cenário 1

#### Cenário 2:

- Executar o método três vezes com horizonte de planejamento igual a três porém, adotando apenas o planejamento do primeiro ano de cada execução (Figura 6.3.2);

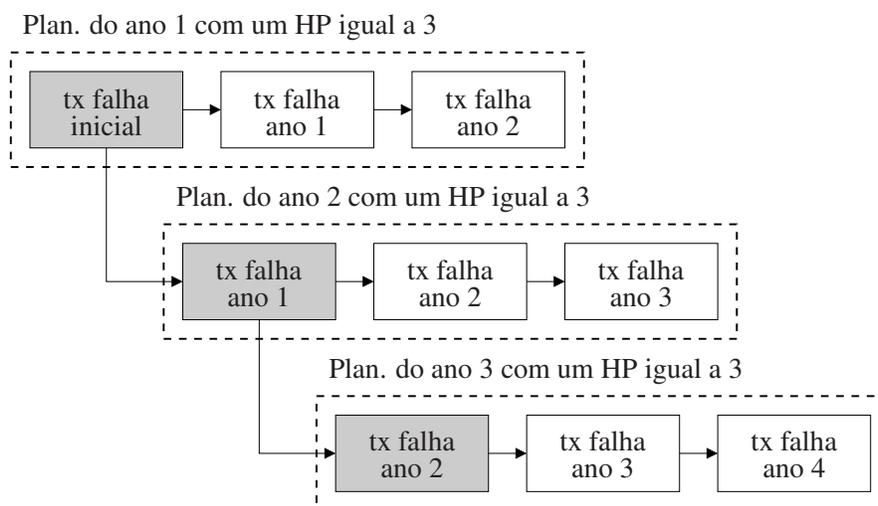


Fig. 6.5: Horizonte de planejamento no experimento 2 utilizando o cenário 2

No experimento 2 um cenário “intermediário” entre os dois testados poderia ser avaliado - com um horizonte de planejamento igual a três para o planejamento conjunto dos três anos (figura 6.6). Esse cenário foi descartado porque, como já reforçado, não é realista neste modelo o planejamento de mais de um ano. Apesar do planejamento dos mesmos três anos ter sido feito, esse experimento foi realizado para determinar se o *HP* para o planejamento de um ano deve ser maior do que um, sem a pretensão de sugerir as soluções para os três anos no sistema.

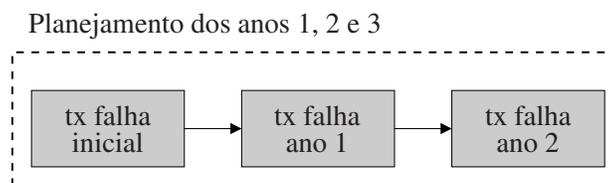


Fig. 6.6: Horizonte de planejamento em um cenário intermediário alternativo

As Tabelas 6.17, 6.18 e 6.19 apresentam os dados da média de cinco execuções para os três casos de teste nos cenários 1 e 2. Como mostram as Figuras 6.7, 6.8 e 6.9, o custo total para os três anos foi inferior no cenário 1, entretanto, observa-se que enquanto no primeiro cenário o *CMP* foi menor do que no segundo, o *CMC* foi maior. O investimento maior em manutenção preventiva se deve ao fato de a decisão no segundo cenário englobar não apenas a taxa de falha do ano atual, mas dos dois anos seguintes, colocando um peso maior no *CMC* e na avaliação do impacto de não fazer manutenção.

Os resultados dos dois cenários não apontam no sentido da adoção de um deles, pelo contrário, ambos podem ser utilizados de acordo com os objetivos do planejamento, se o sistema está em boas

Tab. 6.17: Custo médio de cinco soluções encontradas no experimento 2 (caso de teste I)

Cenário	CMP	penMC	CT
HP=1	19727,098	19410,743	39137,841
HP=3	23933,525	16523,132	40456,657

Tab. 6.18: Custo médio de cinco soluções encontradas no experimento 2 (caso de teste II)

Cenário	CMP	penMC	CT
HP=1	11549,323	6488,438	18037,761
HP=3	13089,601	5003,195	18092,796

Tab. 6.19: Custo médio de cinco soluções encontradas no experimento 2 (caso de teste III)

Cenário	CMP	penMC	CT
HP=1	24039,845	7507,773	31547,618
HP=3	27194,374	7376,507	34570,881

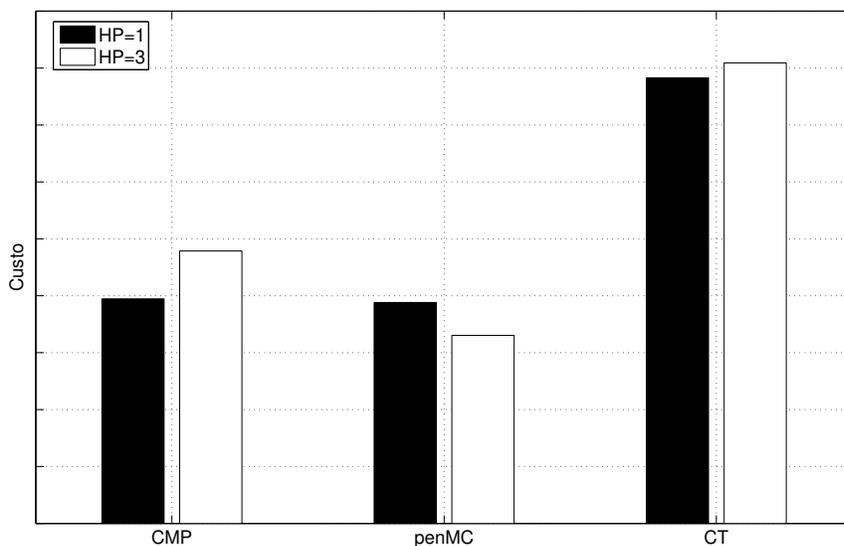


Fig. 6.7: Experimento sobre o HP no caso de teste I

condições operacionais pode ser vantajoso investir menos em manutenção e permitir um aumento maior do risco de falhas (como no cenário 1). Em contrapartida, se o sistema já está em um estado mais precário, pode haver a necessidade de um programa de manutenção mais cauteloso, investindo mais em manutenções preventivas para reduzir os riscos de falhas (como no cenário 2).

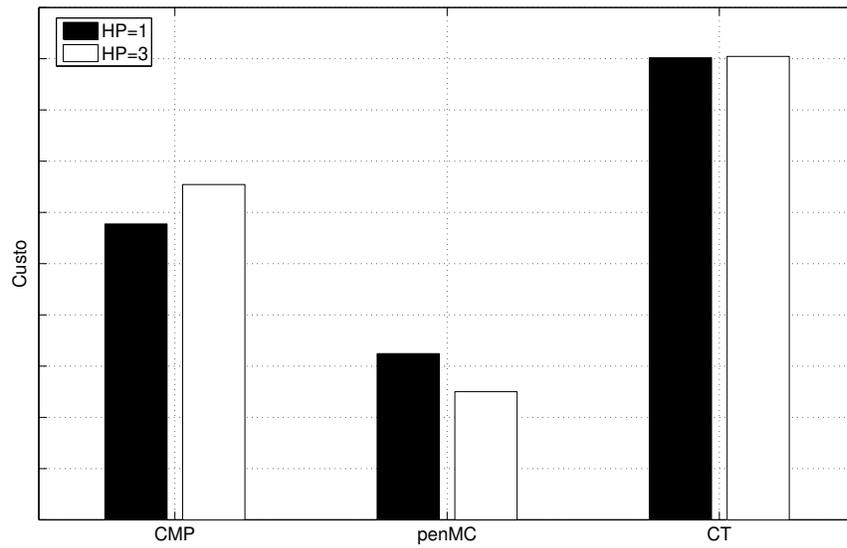


Fig. 6.8: Experimento sobre o HP no caso de teste II

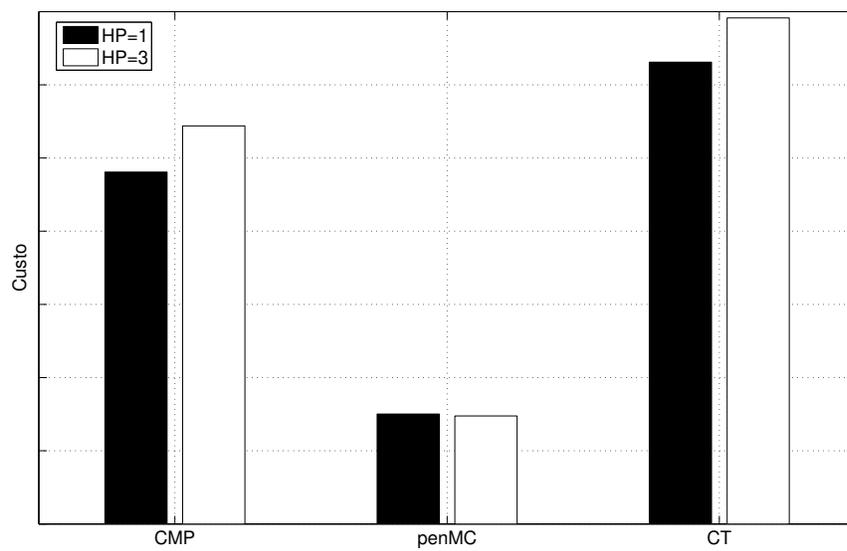


Fig. 6.9: Experimento sobre o HP no caso de teste III

### 6.3.3 Comparação entre os métodos

Em função das conclusões chegadas após os experimentos 1 e 2 justifica-se o modelo proposto na Seção 3.3 do Capítulo 3. Nesse modelo temos na função objetivo, além do *CMP*, uma penalização sobre a manutenção corretiva calculada sobre a taxa de falha dos elementos e o custo de manutenção

corretiva. Outra característica importante é que, para o planejamento de cada ano consideram-se dois cenários: o primeiro com um horizonte de planejamento igual a um e o segundo com um horizonte de planejamento maior do que um, tomando apenas o planejamento do primeiro ano (nos testes adotou-se um horizonte de três anos). Como comentado, os dois cenários levam a busca à soluções diferentes mas que de acordo com a situação podem ser igualmente utilizadas para o apoio à decisão.

Definido o modelo para o problema, os próximos testes se concentraram na avaliação das metodologias desenvolvidas. Esses testes foram executados com um horizonte de planejamento igual a três, por ser um problema mais desafiador. A primeira característica a ser avaliada corresponde à robustez dos métodos. A robustez de um método, ou seja, sua habilidade em devolver soluções de qualidade em cada execução, indica a eficiência do método na exploração para evitar ótimos locais.

Os resultados da distribuição de 10 soluções para 10 execuções do *GRASP* e do *AG* para cada caso de teste são apresentados em seguida através de gráficos *boxplot*. Um gráfico *boxplot* pode ser utilizado para descrever a distribuição de amostras de dados. A linha central em um *boxplot* corresponde à mediana dos dados. A linha inferior e a linha superior definem o limite dos valores para os 25% e 75% dos dados. As linhas tracejadas indicam o intervalo que compreende o restante dos dados.

A distribuição nos gráficos *boxplot* apresentados a seguir se refere ao desvio das soluções com relação à melhor solução encontrada por cada método em cada um dos casos de teste. A Equação 6.1 é usada para o cálculo do desvio da solução  $i$ .

$$Desvio(S_i) = [Custo(S_i) - Custo(S_{melhor})] / Custo(S_{melhor}) \quad \text{para } i = 1, \dots, 10. \quad (6.1)$$

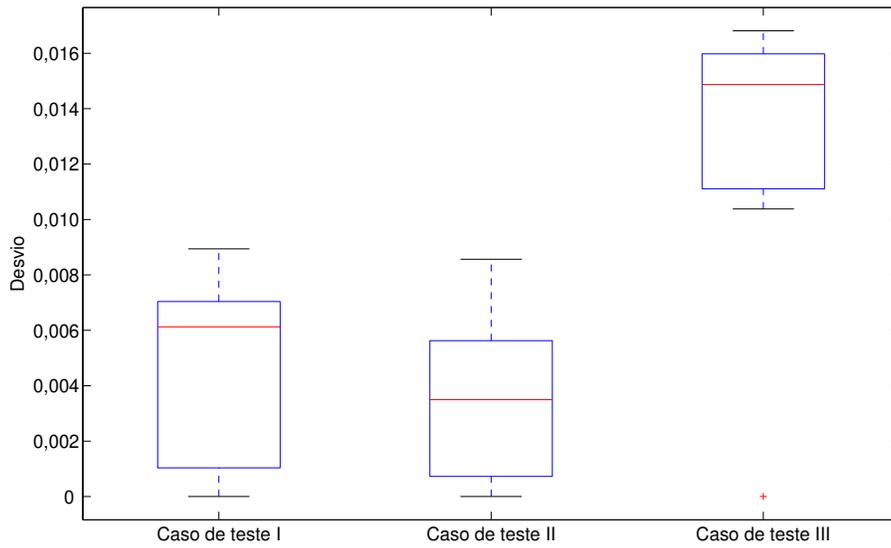
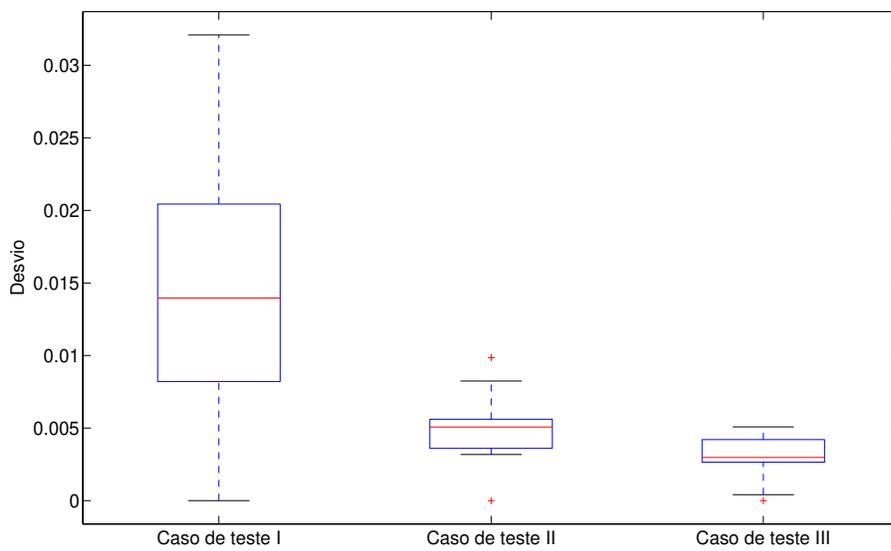
Sendo  $Custo(S_i)$  o custo da solução  $S_i$  e  $S_{melhor}$  a melhor solução entre as dez soluções obtidas.

As Fig. 6.10 e 6.11 mostram os gráficos *boxplot* para os métodos *GRASP* e *AG*, respectivamente. Os desvios máximos para os casos de teste foram aproximadamente 0,9%, 0,9% e 1,6% para o *GRASP* e 3,5%, 0,8% e 0,5% para o *AG*. Pode-se observar que os dois métodos tiveram um comportamento estável, nenhum deles tendo se sobressaído em relação a este aspecto.

A Tabela 6.20 apresenta o custo das soluções encontradas pelos dois métodos e o tempo computacional utilizado para a resolução dos casos de teste. Como pode ser observado, o *AG* apresentou melhores resultados nos dois aspectos, foi capaz de encontrar soluções melhores utilizando menos recursos computacionais.

Os tempos computacionais foram obtidos utilizando um computador Pentium 4 2,8 Ghz com 1 GB de memória RAM e os métodos foram desenvolvidos na linguagem Java.

A Tabela 6.21 apresenta os resultados do *AG* em relação aos resultados do *GRASP*. Os aspecto mais positivo do *AG* é o tempo de processamento, em especial nos dois casos mais desafiadores, o

Fig. 6.10: Desvio das 10 soluções encontradas pelo *GRASP*Fig. 6.11: Desvio das 10 soluções encontradas pelo *AG*

primeiro e o terceiro, o *AG* necessitou de cerca de 80% menos recursos para resolver os problemas.

A discrepância entre os tempos de processamento dos dois métodos foi devido à busca local empregada no *GRASP*. A grande maioria dos recursos computacionais utilizados no *GRASP*, mais de 96%, como é apresentado na Tabela 6.22, foram consumidos nesta fase do método. No *AG* a

Tab. 6.20: Comparação das soluções e do tempo de processamento entre o *GRASP* e o *AG*

Caso de teste	GRASP		AG	
	Custo	Tempo (h:mm:ss)	Custo	Tempo (h:mm:ss)
Caso de teste I	41277,330	1:33:17	41174,993	0:14:05
Caso de teste II	18380,002	0:20:08	17768,512	0:10:39
Caso de teste III	38249,445	1:43:13	36313,434	0:24:35

Tab. 6.21: Comparação relativa entre os resultados do *GRASP* e do *AG*

Caso de teste	Redução	
	Custo	Tempo
Caso de teste I	0,25%	84,90%
Caso de teste II	3,33%	47,07%
Caso de teste III	5,06%	76,18%

complexidade da busca local foi menor, pelo método de redução de vizinhança empregado. Essa estratégia teve um impacto ainda maior do que os números anteriores indicam, lembrando que enquanto o *GRASP* teve 100 iterações o *AG* teve cerca de 20000.

Tab. 6.22: Porcentagem do consumo de tempo dos componentes do *GRASP*

Caso de teste	HC	BL
Caso de teste I	1,90%	98,10%
Caso de teste II	1,50%	98,50%
Caso de teste III	3,50%	96,50%

A Tabela 6.23 apresenta os componentes do *AG* onde o tempo computacional foi consumido. O procedimento de decodificação no *AG* superou a busca local na quantidade de recursos utilizados. Isso ocorreu pela necessidade de decodificar as novas soluções geradas para avaliá-las e, então, decidir se estas devem entrar na população.

Tab. 6.23: Porcentagem do consumo de tempo dos componentes do *AG*

Caso de teste	PopInicial	operadores genéticos	decodificação	BL	BLFinal
Caso de teste I	3,20%	5,80%	57,40%	27,10%	5,80%
Caso de teste II	3,50%	5,70%	56,50%	31,90%	1,50%
Caso de teste III	9,20%	5,90%	70,90%	8,90%	3,80%

Uma análise foi realizada para tentar identificar porque altas taxas de mutação aplicadas no *AG* levaram a soluções melhores. A Tabela 6.24 apresenta o que chamamos de taxa de sobrevivência dos indivíduos mutados. Esses valores representam a proporção de indivíduos que sofreram mutação que conseguiram entrar na população. Uma baixa taxa de sobrevivência indica que o operador de mutação

não está tendo um desempenho satisfatório em promover a diversidade da população. Essa situação poderia levar a necessidade de altas taxas de mutação como ocorreu no *AG* desenvolvido.

A baixa taxa de sobrevivência pode ter ocorrido em parte pela estratégia de atualização da população adotada no *AG*. Como discutido na Seção 5.3.5, no algoritmo genético desenvolvido um novo indivíduo entra na população no lugar de um dos pais apenas se este for melhor do que o pai. Essa abordagem de troca por um dos pais pode ser eficiente para retardar a convergência do *AG* mas por outro lado pode comprometer a função do operador de mutação em promover a diversidade.

Tab. 6.24: Sobrevivência dos indivíduos mutados no *AG*

Caso de teste	Sobrevivência (%)
Caso de teste I	12%
Caso de teste II	31%
Caso de teste III	47%

## 6.4 Comentários

Neste capítulo discutiu-se os experimentos realizados para avaliar o modelo do problema e os métodos adotados para sua resolução. Estes experimentos foram conduzidos em três casos de teste. A Seção 6.2 apresentou os valores adotados para as diversas variáveis destes casos de teste.

No que se refere aos experimentos sobre o modelo do problema os resultados do experimento 1 justificam a ponderação sobre os custos de manutenções corretivas para obter melhores soluções quanto à confiabilidade dos elementos individualmente. Os resultados do experimento 2 confirmam que um horizonte maior do que um para o planejamento de um ano leva a planos de manutenção mais prudentes - investindo mais em manutenções preventivas para reduzir riscos de gastos com manutenções corretivas.

Quanto aos dois métodos heurísticos propostos, ambos tiveram um comportamento estável quanto a diversidade das soluções apresentadas em diversas execuções. Entretanto, o *AG* se sobressaiu em relação ao *GRASP* na qualidade das soluções e principalmente no tempo de execução. Apesar da busca local ter um papel importante também no *AG*, os resultados sugerem que no modelo adotado um método heurístico tendo uma busca local como principal (ou único) mecanismo de exploração seria ineficiente pela característica altamente combinatorial do espaço de busca.

## Capítulo 7

# Conclusões e Propostas de Trabalhos Futuros

O problema de manutenção em sistemas de distribuição de energia elétrica apenas recentemente tem ganhado um maior espaço na literatura. Até então, a maioria dos trabalhos sobre manutenção em sistemas de potência se concentravam nos sistemas de geração e de transmissão. A pequena literatura sobre manutenção em sistemas de distribuição relata estratégias baseadas em tentativas e erros para ajustar planos de manutenção.

Este trabalho apresentou uma abordagem para o problema de manutenção em sistemas de distribuição baseada na confiabilidade da rede. Especificamente, adota um modelo de otimização das ações de manutenção utilizando idéias de Sittithumwat et al. (2004), desenvolve dois métodos para resolução do problema e analisa a metodologia em três casos de teste, construídos a partir de redes reais de grande porte.

O modelo de otimização apresentado busca reduzir os custos sob restrição de um nível mínimo de confiabilidade, medida por um índice de continuidade no fornecimento denominado *FEC* (Frequência Equivalente de Interrupção por Consumidor).

No modelo, a confiabilidade é estimada a partir da taxa de falha de cada um dos componentes da rede que, por sua vez, é estimada por parâmetros que indicam a variação esperada no período, em função da ação programada.

O custo de um plano de manutenção é formado no modelo por dois componentes: o custo de manutenção preventiva (*CMP*) e a penalização sobre manutenção corretiva (*CMC*). O *CMP* é o custo das ações preventivas programadas e o *CMC* atribui uma penalização às atividades de manutenções corretivas procurando priorizar a atenção sobre os componentes mais críticos.

Os estudos de casos realizados indicaram que a incorporação do componente *CMC* na função objetivo leva a soluções em que os elementos com maior risco de falha recebem mais atenção em manutenções preventivas reduzindo a probabilidade da necessidade de manutenções corretivas.

Outra análise realizada nos estudos de casos avaliou o impacto do horizonte de planejamento. A

adoção de um horizonte de planejamento com mais de um intervalo (de um ano) leva a soluções mais cautelosas, havendo investimentos maiores em manutenções preventivas para reduzir riscos de falhas. A garantia de melhora na confiabilidade do sistema através de um maior investimento em manutenções preventivas pode ser desejável ou não dependendo da confiabilidade da rede no momento de definição dos planos de manutenção.

A característica combinatorial do modelo do problema de otimização de manutenção e a grande dimensão dos casos estudados levaram ao desenvolvimento de dois métodos heurísticos para resolução do problema. O primeiro método desenvolvido foi baseado no método *GRASP* (*greedy randomized adaptive search procedure*), que resolve o problema por meio de uma heurística construtiva e de uma busca local. Durante o desenvolvimento da busca local do *GRASP*, houve dificuldade em se escolher um mecanismo de definição de vizinhança que permitisse uma exploração satisfatória do espaço de busca. Esta dificuldade levou à escolha de um método baseado em Algoritmos Genéticos como alternativa ao *GRASP*. A escolha de Algoritmos Genéticos (*AGs*) foi motivada pelo fato deste método não basear a busca em movimentos de exploração de vizinhança, apesar de poderem incorporar tais movimentos para auxiliar a busca.

O *AG* obteve melhores resultados do que o *GRASP* nos estudos de casos realizados, apresentando soluções melhores e menores tempos computacionais. Os piores resultados obtidos com a abordagem *GRASP* se devem parcialmente à busca local adotada que, como mostrado no capítulo anterior, consumiu cerca de 96% do tempo gasto pelo método. Esta exigência computacional da busca local dificultou o aumento do número de iterações do *GRASP* o que permitiria a exploração de um maior número de pontos do espaço de busca e poderia melhorar a qualidade das soluções apresentadas pelo método. A exploração de buscas locais alternativas ou a adoção de critérios para a redução de vizinhança podem ser realizadas em continuação ao trabalho, podendo levar o método *GRASP* a resultados mais competitivos.

No *AG*, foi possível uma maior exploração do espaço de busca porque os operadores genéticos adotados consomem pouco tempo computacional. A rapidez dos operadores de reprodução e mutação do *AG* se deve à representação por vetores reais adotada. Esta representação permitiu a exploração do investimento alocado aos componentes, deixando para uma fase seguinte a tarefa mais custosa que é mapear este investimento em ações de manutenção preventiva.

Ressalta-se que o trabalho mostrou que é possível a abordagem do problema de manutenção em sistemas reais de distribuição de energia elétrica por otimização das relações entre confiabilidade e custos. Suas principais contribuições são a elaboração do modelo matemático proposto por Sittithumwat et al. (2004) para otimização do problema de manutenção baseado em confiabilidade, a construção de duas alternativas para solução do problema em sistemas de porte real e o desenvolvimento de estudos de casos para avaliar as alternativas. O trabalho apresentou uma alternativa que pode

auxiliar no planejamento de manutenção em *SDEE*, dado que, em boa parte dos casos, esta tarefa é realizada definindo intervalos regulares para manutenção, podendo levar a manutenções muito frequentes e não retardando as falhas tanto quanto seria possível.

Em relação a trabalhos futuros, destaca-se que no modelo adotado a variação da taxa de falha independe de qualquer fator que influencie no processo de deterioração dos elementos. Entretanto, a taxa de falha dos elementos varia em função de vários fatores como, por exemplo, a idade dos equipamentos, o histórico de manutenções, o volume de chuvas e a proximidade de árvores. Assim, um modelo ideal do processo de deterioração dos componentes das redes de distribuição deveria considerar os principais fatores que influem na taxa de falha procurando estimar de forma mais precisa as condições de cada elemento. No entanto, as empresas do setor de distribuição, em geral, ainda não possuem dados referentes a esses parâmetros para cada um dos componentes da rede.

Dada a indisponibilidade de dados suficientes para a construção de um modelo que leve em consideração os principais parâmetros que influenciam na deterioração dos elementos, poderia ser incorporada ao modelo uma estratégia para representar a inexatidão presente em seus dados. A exploração destes aspectos é um importante ponto a ser explorado em continuação a este trabalho.

Outro aspecto que pode ser explorado em trabalhos futuros é o tratamento multiobjetivo do problema de manutenção. Em tal abordagem, ao invés de uma única solução para o problema, seria apresentado um conjunto de soluções com compromisso entre confiabilidade e custo, desde soluções com um grande investimento para garantir alta confiabilidade até soluções com pouco investimento e conseqüentemente baixo impacto na confiabilidade. A apresentação de soluções diversas daria um maior suporte à tomada de decisão independentemente do objetivo específico desejado.

# Referências Bibliográficas

- Billinton, R. e Billinton, J. E. (1989). Distribution system reliability indices, *IEEE Transactions on power delivery* **4**(1): 561–568.
- Bueno, E. A. (2005). *Redução das Perdas Técnicas através de Reconfigurações de Redes de Distribuição de Energia Elétrica sob Demandas Variáveis*, PhD thesis, UNICAMP, Campinas-Brasil.
- Bäck, T., Fogel, D. B. e Michalewicz, Z. (eds) (2000). *Evolutionary computation 1: Basic algorithms and operators*.
- Chow, M. e Taylor, L. (1995). Analysis and prevention of animal-caused faults in power distribution systems, *IEEE Transactions on power delivery* **10**(2): 995–1001.
- Dahal, K. P., Aldridge, C. J. e McDonald, J. R. (1999). Generator maintenance scheduling using a genetic algorithm with a fuzzy evaluation function, *FSS* (102): 21–29.
- El-Amin, I., Duffuaa, S. e Abbas, M. (2000). A tabu search algorithm for maintenance scheduling of generating units, *EPSR* (54): 91–99.
- Endrenyi, J., Aboresheid, S., Allan, R. N., Anders, G. J., Asgarpoor, S., Billinton, R., Chowdhury, N., Dialynas, E. N., Fipper, M., Fletcher, R. H., Grigg, C., McCalley, J., Meliopoulos, S., Mielnik, T. C., Nitu, P., Rau, N., Reppen, N. D., Salvaderi, L., Schneider, A. e Singh, C. (2001). The present status of maintenance strategies and the impact of maintenance on reliability, *IEEE Transactions on power systems* **16**(4): 638–646.
- Endrenyi, J., Anders, G. J. e da Silva, A. M. L. (1998). Probabilistic evaluation of the effect of maintenance on reliability - an application, *IEEE transactions on power systems* **13**(2): 576–583.
- Evans, J. R. (1987). Structural analysis of local search heuristics combinatorial optimization, *Computers and Operations Research* **14**(6): 465–477.
- Gönen, T. (1986). *Electric power distribution system engineering*, McGraw-Hill.

- Holland, J. H. (1975). *Adaption in Natural and Artificial Systems*, Ann Arbor. University of Michigan Press.
- Horton, W. F., Goldberg, S. e Volkmann, C. A. (1991). The failure rates of overhead distribution system components, *Proceedings of the 1991 IEEE Transmission and Distribution Conference*, Dallas, TX, USA, pp. 713–717.
- IEEE Standard 493 (1998). *IEEE Recommended Practice for the Design of Reliable Industrial and Commercial Power Systems (Gold Book)*, IEEE.
- Kralj, B. e Petrovic, R. (1995). A multiobjective optimization approach to thermal generating units maintenance scheduling, *European Journal of Operational Research* (84(2)): 481–493.
- Kuntz, P. A., Christie, R. D. e Venkata, S. S. (2002). Optimal vegetation maintenance scheduling of overhead electric power distribution systems, *IEEE Transactions on power delivery* **17**(4): 1164–1175.
- Langdon, W. B. e Treleaven, P. C. (1997). Scheduling maintenance of electrical power transmission networks using genetic programming, in K. Warwick, A. Ekwue e R. Aggarwal (eds), *Artificial Intelligence Techniques in Power Systems*, IEE, pp. 220–237.
- Lim, M. H., Yuan, Y. e Omatu, S. (2000). Efficient genetic algorithms using simple genes exchange localsearch policy for the quadratic assignment problem, *Comput. Optim. Appl.* **15**(3): 249–268.
- Marwali, M. K. C. e Shahidehpour, S. M. (1998). A deterministic approach to generation and transmission maintenance scheduling with network constraints, *EPSR* (47): 101–113.
- Merz, P. (2000). *Memetic Algorithms for Combinatorial Optimization Problems: Fitness Landscapes and Effective Search Strategies*, PhD thesis, University of Siegen, Germany.
- Michalewicz, Z. (1996). *Genetic Algorithms + Data Structures = Evolution Programs*, Springer.
- Michalewicz, Z. e Fogel, D. B. (2002). *How to Solve It: Modern Heuristics*, Springer-Verlag, Berlin.
- Mohanta, D. K., Sadhu, P. K. e Chakrabarti, R. (2004). Fuzzy reliability evaluation of captive power plant maintenance scheduling incorporating uncertain forced outage rate and load representation, *Electric Power Systems Research* **72**(1): 73–84.
- Papadimitriou, C. H. e Steiglitz, K. (1998). *Combinatorial Optimization: Algorithms and Complexity*, Dover Publications.

- Power Systems Reliability Subcommittee of the Power Systems Engineering Committee of the IEEE Industry Applications Society, U. (1991). *IEEE Std 493-1990*, IEEE Press, chapter IEEE recommended practice for the design of reliable industrial and commercial power systems, pp. 99–104.
- Radmer, D., Kuntz, P., Christie, R., Venkata, S. e Fletcher, R. (2002). Predicting vegetation-related failure rates for overhead distribution feeders, *IEEE Transactions on power delivery* **17**(4): 1170–1175.
- Rausand, M. (1998). Reliability centered maintenance, *Reliability engineering and system safety* **60**: 121–132.
- Reeves, C. (2003). Genetic algorithms, in F. Glover e G. Kochenberger (eds), *Handbook of Metaheuristics*, Kluwer Academic Publishers, pp. 55–82.
- Resende, M. G. C. e Ribeiro, C. C. (2003). *Handbook of metaheuristics*, chapter Greedy randomized adaptive search procedures, pp. 219–249.
- Sergaki, A. e Kalaitzakis, K. (2002). A fuzzy knowledge based method for maintenance planning in power system, *RESS* (77): 19–30.
- Sittithumwat, A., Soudi, F. e Tomsovic, K. (2004). Optimal allocation of distribution maintenance resources with limited information, *Electric Power Systems Research* **68**: 208–220.
- Valdez-Flores, C. e Feldman, R. M. (1989). A survey of preventive maintenance models for stochastically deteriorating single-unit systems, *Naval research logistics* **36**: 419–446.
- Wang, H. (2002). A survey of maintenance policies of deteriorating systems, *European Journal of Operational Research* **139**: 469–489.
- Yang, S. K. (2004). A condition-based preventive maintenance arrangement for thermal power plants, *EPSR* (72): 49–62.
- Yellen, J., Al-Khamis, T. M., Vemuri, S. e Lemonidis, L. (1992). A decomposition approach to unit maintenance scheduling, *7*(2): 726–733.