

Eduardo Tadeu Bacalhau

OTIMIZAÇÃO DE POLÍTICAS DE MANUTENÇÃO EM REDES DE
DISTRIBUIÇÃO DE ENERGIA ELÉTRICA POR ESTRATÉGIAS
HÍBRIDAS BASEADAS EM PROGRAMAÇÃO DINÂMICA

Campinas

2015

Universidade Estadual de Campinas
Faculdade de Engenharia Elétrica e de Computação

Eduardo Tadeu Bacalhau

OTIMIZAÇÃO DE POLÍTICAS DE MANUTENÇÃO EM REDES DE DISTRIBUIÇÃO DE ENERGIA
ELÉTRICA POR ESTRATÉGIAS HÍBRIDAS BASEADAS EM PROGRAMAÇÃO DINÂMICA

Tese de doutorado apresentada à Faculdade de Engenharia Elétrica e de Computação como parte dos requisitos exigidos para a obtenção do título de Doutor em Engenharia Elétrica. Área de concentração: Automação.

Orientador: Christiano Lyra Filho

Coorientador: Fábio Luiz Usberti

Este exemplar corresponde à versão final da tese defendida pelo aluno Eduardo Tadeu Bacalhau e orientada pelo Prof. Christiano Lyra Filho

Campinas
2015

Ficha catalográfica
Universidade Estadual de Campinas
Biblioteca da Área de Engenharia e Arquitetura
Rose Meire da Silva - CRB 8/5974

B12o Bacalhau, Eduardo Tadeu, 1982-
Otimização de políticas de manutenção em redes de distribuição de energia elétrica por estratégias híbridas baseadas em programação dinâmica / Eduardo Tadeu Bacalhau. – Campinas, SP : [s.n.], 2015.

Orientador: Christiano Lyra Filho.
Coorientador: Fábio Luiz Usberti.
Tese (doutorado) – Universidade Estadual de Campinas, Faculdade de Engenharia Elétrica e de Computação.

1. Programação dinâmica. 2. Confiabilidade (Engenharia). 3. Energia elétrica. 4. Manutenção preventiva. 5. Otimização. I. Lyra Filho, Christiano, 1951-. II. Usberti, Fábio Luiz, 1982-. III. Universidade Estadual de Campinas. Faculdade de Engenharia Elétrica e de Computação. IV. Título.

Informações para Biblioteca Digital

Título em outro idioma: Maintenance policies optimization on electric power distribution networks by hybrid strategies based on dynamic programming

Palavras-chave em inglês:

Dynamic programming
Reliability (Engineering)
Electric power
Preventive maintenance
Optimization

Área de concentração: Automação

Titulação: Doutor em Engenharia Elétrica

Banca examinadora:

Iony Patriota de Siqueira
Vinícius Jacques Garcia
Fernando José Von Zuben
Rafael Santos Mendes

Data de defesa: 16-04-2015

Programa de Pós-Graduação: Engenharia Elétrica

COMISSÃO JULGADORA - TESE DE DOUTORADO

Candidato: Eduardo Tadeu Bacalhau

Data da Defesa: 16 de abril de 2015

Título da Tese: "Otimização de Políticas de Manutenção em Redes de Distribuição de Energia Elétrica por Estratégias Híbridas Baseadas em Programação Dinâmica"

Prof. Dr. Christiano Lyra Filho (Presidente):

Dr. Iony Patriota de Siqueira:

Prof. Dr. Vinicius Jacques Garcia:

Prof. Dr. Fernando José Von Zuben:

Prof. Dr. Rafael Santos Mendes:

Resumo

Este trabalho explora alternativas para a determinação das melhores políticas de planejamento das ações de manutenção preventiva em redes de distribuição de energia elétrica. O problema é uma extensão de abordagens da área de manutenção centrada em confiabilidade (MCC), que vem sendo objeto de pesquisas ao longo das últimas décadas. Por se tratar de um problema de otimização combinatória de difícil solução, são poucos os artigos publicados que envolvem sistemas de escala real, e a maioria dentre esses utiliza meta-heurísticas como estratégia de solução.

A abordagem desenvolvida neste trabalho é baseada na técnica de otimização denominada programação dinâmica. Duas estratégias para a redução do espaço de busca são adotadas: uma delas procura identificar e eliminar soluções dominadas; a segunda estratégia envolve a aplicação do processo de otimização da programação dinâmica em torno de uma vizinhança de uma solução promissora, movendo iterativamente em um espaço de soluções — uma abordagem inspirada na programação dinâmica diferencial discreta. A combinação dessas duas estratégias é denominada Programação Dinâmica com Reduções de Espaço de Estados (PDREE).

O trabalho investiga também a construção de estratégias híbridas. Uma das alternativas utiliza um algoritmo genético híbrido para a construção de planos de manutenção iniciais de boa qualidade, posteriormente otimizados pela PDREE. A segunda estratégia híbrida utiliza a PDREE para a construção de boas populações iniciais de soluções, posteriormente otimizada pelo algoritmo genético híbrido.

As abordagens desenvolvidas são aplicadas a problemas de escala real e comparadas à abordagem por algoritmo genético híbrido. Explora-se também a combinação das duas estratégias híbridas. Os resultados mostram que as ideias desenvolvidas na tese estendem o estado-da-arte sobre a otimização de políticas de manutenção em redes de distribuição de grande porte.

Palavras-chave: Manutenção preventiva, redes de distribuição, confiabilidade, programação dinâmica com redução de espaço de estados.

Abstract

This work explores alternatives to determine the best planning policies for preventive maintenance on electric power distribution systems. The problem is an extension of approaches of the reliability-centered maintenance area that has been studied along the last decades. Since this problem is a hard combinatorial optimization problem, there are few works that address real-life systems, and most of these works use methods based on metaheuristic as solution strategy.

The approaches proposed in this work are based on the optimization technique named dynamic programming. Two strategies are developed to reduce the search space of dynamic programming: the first strategy seeks to identify and eliminate dominated solutions; the second strategy confines the dynamic programming optimization procedures to the neighborhood of good solutions that move iteratively in the solution space—an approach inspired by the discrete differential dynamic programming method. The combination of both strategies is denominated Dynamic Programming with State Space Reductions (DPSSR).

The work also investigates the development of hybrid strategies. One of the alternatives uses a hybrid genetic algorithm to obtain a promising initial maintenance strategy, further optimized by the DPSSR. The second hybrid strategy uses the DPSSR for constructing an initial good population, further optimized by a hybrid genetic algorithm.

All the approaches are applied to real-life problems and compared to a pure hybrid genetic algorithm approach. An additional strategy of combining the hybrid approaches is also explored. The results show that the ideas developed in the thesis improve the state-of-the-art in obtaining the best maintenance policies for large distribution networks.

Key-words: Preventive maintenance, distribution networks, reliability, dynamic programming with state space reductions.

Sumário

1	Apresentação do Trabalho	1
2	Caracterização do Problema de Otimização da Manutenção Preventiva em Sistemas de Distribuição	3
2.1	Introdução	3
2.2	Aspectos da Manutenção Preventiva	3
2.3	Representação do Problema	5
2.3.1	Redes de Distribuição Radial	6
2.3.2	Modelo de Taxa de Falha	6
2.3.3	Restrição de Confiabilidade	8
2.3.4	Formulação Matemática	8
2.4	Revisão Bibliográfica	11
2.4.1	Manutenção Centrada em Confiabilidade	11
2.4.2	Problema de Manutenção em Sistemas de Distribuição de Energia Elétrica	11
2.4.3	Métodos de Solução para o Problema de Manutenção em Sistemas de Distribuição de Energia Elétrica	12
2.5	Considerações Finais	15
3	Algoritmo Genético Híbrido Aplicado ao Problema de Otimização de Manutenção Preventiva	17
3.1	Introdução	17
3.2	Algoritmos Genéticos	17
3.3	Especialização do AG para o Problema de Manutenção Preventiva em Sistemas de Distribuição de Energia Elétrica	20
3.3.1	Codificação dos Indivíduos	20
3.3.2	População Inicial	21
3.3.3	Avaliação	22

3.3.4	Seleção	22
3.3.5	Operadores Genéticos	23
3.3.6	Atualização da População	25
3.3.7	Cr�terios de Parada	25
3.3.8	Par�metros de Controle	26
3.4	Hibridiza��o do Algoritmo Gen�tico	26
3.5	Coment�rios Finais	27
4	Programa��o Din�mica Aplicada ao Problema de Otimiza��o de Manuten��o Preventiva	29
4.1	Introdu��o	29
4.2	Programa��o Din�mica	29
4.3	Programa��o Din�mica Aplicada ao Problema de Otimiza��o da Manuten��o Preventiva em Sistemas de Distribui��o de Energia El�trica	33
4.4	Coment�rios Finais	41
5	Estudo de Complexidade e T�cnica de Redu��o de Solu��es Dominadas	43
5.1	Introdu��o	43
5.2	Estudo de Complexidade do M�todo de Programa��o Din�mica	43
5.3	Aplica��o do M�todo de Programa��o Din�mica	46
5.4	T�cnica de Redu��o de Solu��es Dominadas	47
5.5	Aplica��o do M�todo de Programa��o Din�mica Modificado	49
5.6	Coment�rios Finais	52
6	Programa��o Din�mica com Redu��es de Espa�o de Estados	55
6.1	Introdu��o	55
6.2	Programa��o Din�mica com Redu��es de Espa�o de Estados	55
6.2.1	Programa��o Din�mica Diferencial Discreta	56
6.2.2	Caracteriza��o da Metodologia de PDREE	59
6.3	Abordagem por PDREE Aplicado ao Problema de Otimiza��o de Manuten��o Preventiva em Sistemas de Distribui��o de Energia El�trica	59
6.3.1	Constru��o da Trajet�ria de Refer�ncia	60
6.3.2	PDDD Aplicada ao Problema de Otimiza��o de Manuten��o Preventiva em sistemas de Distribui��o de Energia El�trica	61
6.3.3	Caracteriza��o da Abordagem por PDREE	63
6.3.4	Coment�rios sobre a Abordagem por PDREE	64
6.4	Coment�rios Finais	65

7	Abordagens Híbridas Aplicadas ao Problema de Manutenção Preventiva em Redes de Distribuição	67
7.1	Introdução	67
7.2	Abordagem Híbrida 1	67
7.3	Comentários sobre a Abordagem AH1	68
7.4	Abordagem Híbrida 2	69
7.5	Comentários sobre a Abordagem AH2	71
7.6	Comentários Finais	71
8	Estudo de Casos	73
8.1	Introdução	73
8.2	Redes de Distribuição Radial	74
8.3	Dados dos Equipamentos	75
8.4	Experimentos	75
8.4.1	Restrições de Confiabilidade	76
8.4.2	Parâmetros	77
8.5	Experimento I	80
8.5.1	Resultados para a Rede de Distribuição 1	80
8.5.2	Análise dos Resultados para a Rede de Distribuição 1	80
8.5.3	Resultados para a Rede de Distribuição 2	81
8.5.4	Análise dos Resultados para a Rede de Distribuição 2	81
8.5.5	Resultados para a Rede de Distribuição 3	82
8.5.6	Análise dos Resultados - Rede de Distribuição 3	84
8.5.7	Análise Geral do Experimento	85
8.6	Experimento II	85
8.6.1	Resultados para o Experimento II	85
8.6.2	Análise dos Resultados do Experimento II	86
8.7	Experimento III	87
8.7.1	Dados para o Experimento III	87
8.7.2	Resultados para o Experimento III	88
8.7.3	Análise dos Resultados do Experimento III	92
8.8	Comentários Finais	96
9	Conclusões e Perspectivas	97
	Bibliografia	100

À MINHA AMADA MÃE,
ANGELA MARIA BUSNARDO.

Agradecimentos

À minha amada família, pelo amor e carinho.

Aos muitos amigos, que incentivaram e fizeram parte de toda a caminhada. Em especial, os amigos da Ufscar, Unicamp e Curitiba.

Aos amigos do Labore, pela companhia diária.

À minha companheira, Denise, pelo apoio e amor que recebo a todo momento.

A Christiano e Fábio, pela orientação.

À banca examinadora, por aceitar o convite para participar da avaliação.

Ao CNPq, pelo suporte financeiro.

À força maior, por me guiar.

Talvez seja bom ter uma mente bonita, mas um dom ainda maior é descobrir um coração bonito.

John Forbes Nash Jr.

Lista de Figuras

2.1	Evolução da manutenção.	4
2.2	Representação de uma rede radial separada por seções.	6
2.3	Custo x Confiabilidade.	9
3.1	Estrutura do algoritmo genético.	18
3.2	Cromossomo de comprimento $L = 10$	19
3.3	Interação entre os espaços genotípico e fenotípico (Atmar 1994).	20
3.4	Codificação do indivíduo para a abordagem	20
3.5	Recombinação em cromossomos de comprimento $L = 10$	24
3.6	Mutação em cromossomos de comprimento $L = 10$	24
4.1	Processo de otimização de decisão multiestágio - Função de custo ótimo	32
4.2	Diagrama de estados	32
4.3	Vetores de estados possíveis	35
4.4	Exemplo Simples	37
5.1	Rede de referência	46
5.2	Diagrama de estados - Trajetória Ótima	48
5.3	Diagrama de estados - Trajetória Final	53
6.1	Exemplo de subdomínio no estágio k	58
6.2	Diagrama de estados para a metodologia de PDREE	58
7.1	Fluxograma da Abordagem Híbrida 1	69
7.2	Fluxograma da Abordagem Híbrida 2	72
8.1	Resultados - Rede 1	86
8.2	Resultados - Rede 2	86
8.3	Resultados - Rede 3	86

8.4	Gráfico de distribuição cumulativa de probabilidade - Rede 1.	88
8.5	AGH - Rede 1.	89
8.6	AH1 - Rede 1.	89
8.7	AH2 - Rede 1.	90
8.8	Gráfico de distribuição cumulativa de probabilidade - Rede 2.	90
8.9	AGH - Rede 2.	91
8.10	AH1 - Rede 2.	91
8.11	AH2 - Rede 2.	92
8.12	Gráfico de distribuição cumulativa de probabilidade - Rede 3.	93
8.13	AGH - Rede 3.	93
8.14	AH1 - Rede 3.	94
8.15	AH2 - Rede 3.	94

Lista de Tabelas

3.1	Algoritmo Genético	19
3.2	Algoritmo Genético Híbrido	26
3.3	Busca Local Parcial	27
3.4	Busca do Melhor Movimento	28
4.1	Programação Dinâmica	33
4.2	Transformadores - Rede de Distribuição Fictícia	37
4.3	Programação Dinâmica para o Problema de Manutenção Preventiva	41
5.1	Número de vetores de estado calculados a cada estágio para um ano de horizonte de planejamento.	44
5.2	Número de vetores de estado calculados a cada estágio para dois anos de horizonte de planejamento.	45
5.3	Número de vetores de estado calculados a cada estágio para três anos de horizonte de planejamento.	45
5.4	Equipamentos - Rede de distribuição fictícia	47
5.5	Técnica de Redução de Soluções Dominadas	49
5.6	Programação Dinâmica Modificada	50
6.1	Metodologia de PDREE	60
6.2	Heurística construtiva	61
6.3	Construção do túnel	63
6.4	Abordagem por PDREE	64
7.1	Abordagem Híbrida 1	68
7.2	Abordagem Híbrida 2	70
7.3	Abordagem por PDREE modificado	71
8.1	Equipamentos	75

8.2	Equipamentos	76
8.3	Equipamentos	76
8.4	Restrições de confiabilidade	77
8.5	Restrições de confiabilidade	78
8.6	Restrições de confiabilidade	78
8.7	Resultados - Rede 1	81
8.8	Resultados - Rede 1	81
8.9	Resultados - Rede 1	82
8.10	Resultados - Rede 2	82
8.11	Resultados - Rede 2	83
8.12	Resultados - Rede 2	83
8.13	Resultados - Rede 3	83
8.14	Resultados - Rede 3	84
8.15	Resultados - Rede 3	84

Apresentação do Trabalho

O trabalho aborda o problema de otimização de políticas de planejamento para alocação ótima de recursos de manutenção preventiva em redes de distribuição de energia elétrica. A otimização da manutenção preventiva é um ramo da área de manutenção centrada em confiabilidade, e tem como objetivo encontrar as melhores alternativas para reduzir as consequências das falhas dos componentes, preservando suas capacidades funcionais e a operação do sistema. Aplicada aos sistemas de distribuição de energia elétrica, o problema de otimização da manutenção preventiva busca as melhores alternativas para aumentar a vida útil dos equipamentos e reduzir o impacto das falhas e, conseqüentemente, aumentar a confiabilidade do sistema. Este trabalho propõe um modelo matemático de otimização que procura encontrar o melhor orçamento para o planejamento de ações de manutenção preventiva sob restrições de níveis mínimos de confiabilidade do sistema, ao longo de um horizonte de planejamento.

O Capítulo 2 faz uma breve apresentação dos conceitos envolvendo a metodologia de manutenção preventiva e a manutenção preventiva aplicada em sistemas de distribuição de energia elétrica. Em seguida, apresenta a formulação matemática para o problema de otimização de manutenção, que é um aperfeiçoamento do modelo proposto por Reis (2007). O Capítulo 2 apresenta também uma revisão bibliográfica de trabalhos relacionados ao problema investigado.

O fato do problema de otimização ser NP-difícil justifica a aplicação de métodos heurísticos para a obtenção de soluções, tal como o algoritmo genético híbrido proposto por Reis (2007), que trata o problema de manutenção em redes de distribuição em escala real. Sendo assim,

o Capítulo 3 apresenta os conceitos do método de algoritmo genético e as principais ideias do Algoritmo Genético Híbrido (AGH) proposto por Reis (2007) para o problema de otimização da manutenção preventiva em sistemas de distribuição de energia elétrica, adotado como referência para os estudos de casos elaborados neste trabalho.

Os Capítulos 4, 5, 6 e 7 descrevem a principal parte da pesquisa realizada. O Capítulo 4 resume o método de programação dinâmica e discute a adaptação do método ao problema de otimização da manutenção preventiva abordado. O estudo de complexidade do método de programação dinâmica aplicado ao problema de otimização da manutenção e o desenvolvimento de uma técnica de redução de soluções dominadas são apresentados no Capítulo 5. O Capítulo 6 apresenta uma nova abordagem para o método de programação dinâmica, denominado Programação Dinâmica com Reduções de Espaço de Estados (PDREE), que utiliza a técnica de redução de soluções dominadas desenvolvida, em conjunto com a técnica de programação dinâmica diferencial discreta, desenvolvida por Heidari, Chow, Kokotovic & Meredith (1971). O Capítulo 7 apresenta duas abordagens híbridas, combinando a abordagem por PDREE e a abordagem AGH desenvolvida por Reis (2007). Uma das estratégias, denominada AH1, consiste na aplicação da abordagem AGH para a construção de políticas de manutenção iniciais, posteriormente otimizadas pela PDREE. A outra estratégia híbrida, denominada AH2, utiliza a abordagem por PDREE como um procedimento de otimização para criar uma boa população de soluções, otimizadas em seguida pela abordagem AGH.

O Capítulo 8 apresenta os estudos de casos realizados no trabalho. Na essência, os estudos de casos são três experimentos distintos realizados para simulações de redes de distribuição de escala real, que buscam produzir uma análise comparativa de desempenho entre as abordagens desenvolvidas e a abordagem AGH.

O Capítulo 9 apresenta as conclusões e discute possibilidades de desdobramentos das ideias desenvolvidas.

Caracterização do Problema de Otimização da Manutenção Preventiva em Sistemas de Distribuição

2.1 Introdução

Este capítulo discute os principais aspectos do problema de otimização da manutenção preventiva de sistemas de distribuição de energia elétrica. Em seguida, apresenta as características do modelo matemático desenvolvido e a formulação matemática do problema.

Além disso, uma revisão bibliográfica das principais pesquisas desenvolvidas na literatura da área também é apresentada.

2.2 Aspectos da Manutenção Preventiva

A otimização da manutenção preventiva é um nicho da metodologia de Manutenção Centrada na Confiabilidade, MCC (em inglês, *Reliability-Centered Maintenance* (RCM)). A MCC foi desenvolvida através de experiências adquiridas na indústria aeronáutica americana a partir dos anos 60. De acordo com Siqueira (2005), a história da manutenção pode ser classificada em três grandes gerações, associadas, respectivamente, aos conceitos de mecanização, industrialização

e automação. A Figura 2.1 ilustra a caracterização dessas gerações e o surgimento de novos conceitos de manutenção de acordo com cada geração (Siqueira 2005).




Figura 2.1: Evolução da manutenção.

Observa-se na Figura 2.1 que o conceito de manutenção preventiva teve início na segunda geração, motivado pelo crescimento do processo de industrialização, que exigia uma maior disponibilidade e vida útil de um equipamento. A manutenção baseada em confiabilidade é um desenvolvimento adicional do conceito de manutenção preventiva que procura informações de confiabilidade para preservar as capacidades funcionais de equipamentos e sistemas de operação (Moubray 1997).

Especificamente, procura atingir o conjunto de objetivos dados a seguir (Siqueira 2005):

- Preservar as funcionalidades dos equipamentos, com a segurança requerida;
- Restaurar a confiabilidade do equipamento após a deterioração;
- Otimizar a disponibilidade dos equipamentos;
- Minimizar o custo do ciclo de vida dos equipamentos;
- Atuar baseada nos modelos de falha dos equipamentos;
- Ser realizada somente quando necessária; e
- Agir em função dos efeitos e reduzir as consequências das falhas.

O objetivo de reduzir a consequência das falhas pode ser desdobrado em novos objetivos (Siqueira 2005):

- Preservar as funções dos sistemas;
- Identificar os tipos de falha que possam interromper as funções dos equipamentos;
- Priorizar as necessidades das funções operacionais dos equipamentos;
- Selecionar apenas as tarefas preventivas que sejam aplicáveis e efetivas;
- Determinar periodicidades ótimas para estas atividades.

Os objetivos descritos acima podem ser formalmente caracterizados por problemas matemáticos de otimização.

A próxima seção discute a formulação matemática do problema de otimização das ações de manutenção preventiva em sistemas de distribuição de energia elétrica.

2.3 Representação do Problema

Os sistemas de distribuição de energia elétrica são compostos por circuitos elétricos que transportam energia das subestações para os consumidores. Esses circuitos são compostos por equipamentos de manobras, equipamentos de proteção, equipamentos de correção, transformadores, condutores e infra-estruturas associadas, como postes, cruzetas, amarrações e cabos (Reis 2007).

O modelo matemático aqui discutido supõe a operação radial dos sistemas e com um único ponto de injeção de energia a partir da subestação. A operação radial é a realidade da grande maioria dos sistemas de distribuição. No entanto, é cada vez mais frequente a presença de geração distribuída nas redes, o que correspondem à injeção de energia elétrica em outros pontos além da subestação. Nesses casos, a hipótese de um único ponto de injeção caracteriza uma análise de pior caso.

Os equipamentos de proteção (disjuntores, chaves-fusíveis, religadores e chaves-faca) protegem a rede da propagação de falhas. Esses equipamentos são utilizados para caracterizar as fronteiras das seções, como sugerem Sittithumwat, Soudi & Tomsovic (2004) e Reis (2007). Se um equipamento de uma seção falha, o equipamento de proteção é acionado, causando, em redes radiais, a interrupção na transmissão da energia para as seções à jusante. Essa caracterização permite avaliar o impacto das ações de manutenção na confiabilidade de cada seção e da rede como um todo, levando em consideração o número de clientes que cada uma das seções abrange.

2.3.1 Redes de Distribuição Radial

Em redes de distribuição radial, as seções mais próximas dos alimentadores possuem importância maior para o cálculo de confiabilidade do sistema, pois se essas seções falham, um número maior de consumidores será atingido. Um exemplo de rede de distribuição radial é ilustrado pela Figura 2.2.




Figura 2.2: Representação de uma rede radial separada por seções.

A rede radial apresentada na Figura 2.2 é composta por sete seções, divididas por equipamentos de proteção que evitam a propagação da falha ao longo da rede. Algumas seções pertencem à rede primária do sistema e outras, identificadas pelos transformadores, pertencem às redes secundárias do sistema. Cada seção da rede de distribuição contém equipamentos que compõem o sistema. Os equipamentos estão sujeitos a um processo de deterioração ao longo dos anos. Esse processo de deterioração pode ser representado através de um modelo de taxa de falhas.

2.3.2 Modelo de Taxa de Falha

Este trabalho representa o problema de otimização de estratégias de manutenções preventivas em redes de distribuição radiais através do modelo de taxas de falhas adaptado Reis (2007). Este modelo procura estimar o processo de deterioração dos equipamentos ao longo dos anos em função de ações de manutenção. A relação entre confiabilidade e planos de manutenção,

estabelecida pelo modelo de taxa de falha, permite identificar as estratégias de manutenção com maior benefício para os sistemas.

As taxas de falha são calculadas para cada equipamento e, posteriormente, para cada seção da rede de distribuição. Supõe-se que elas são independentes e ocorrem sem superposição. As ações de manutenção levam a modificações nos multiplicadores de taxas de falha. Os multiplicadores de taxas de falha são parâmetros associados a cada tipo de equipamento. As taxas de falha para os equipamentos que compõem a rede de distribuição podem ser calculadas a partir da seguinte equação:

$$\lambda_e^t = \lambda_e^{(t-1)} \delta_e^t, \quad \delta_e^t \in \Delta_e \quad (2.1)$$

onde:

- λ_e^t é a taxa de falha do equipamento e no período t ;
- $\lambda_e^{(t-1)}$ é a taxa de falha do equipamento e no período anterior $(t - 1)$, sendo a taxa de falha inicial quando $t = 1$;
- δ_e^t é o multiplicador de taxa de falha do equipamento associado à ação de manutenção preventiva para o equipamento e no período t ;
- Δ_e é o conjunto de todas as ações de manutenção disponíveis.

As taxas de falha dos equipamentos permitem calcular as taxas de falha das seções. A taxa de falha de uma seção de rede radial é dada pela soma das taxas de falha associadas a cada equipamento que a compõe. Matematicamente,

$$\lambda_s^t = \lambda_s + \sum_{e \in E_s} \lambda_e^t, \quad (2.2)$$

onde:

- E_s é o conjunto de equipamentos na seção s ;
- λ_s^t é a taxa de falha da seção s no período t ;
- λ_s é a taxa de falha base da seção s , que representa a parcela da taxa de falha associada a fatores não incorporados no modelo (valor constante).

A partir do modelo de taxa de falha, pode-se quantificar a confiabilidade do sistema de distribuição.

2.3.3 Restrição de Confiabilidade

A confiabilidade de um sistema de distribuição de energia elétrica pode ser medida através de indicadores que representam a disponibilidade da energia para o consumidor. Os índices de confiabilidade mais usuais são o DEC e o FEC (Billinton & Billinton 1989), definidos a seguir:

- DEC: Duração Equivalente em Interrupção por Unidade Consumidora — mede a duração média de interrupções ocorridas no sistema de distribuição;
- FEC: Frequência Equivalente de Interrupção por Unidade Consumidora — mede a frequência média de interrupções ocorridas no sistema de distribuição.

O índice de confiabilidade adotado neste trabalho é o FEC, pois ações de manutenção procuram, em primeira instância, reduzir a frequência das falhas. O índice FEC pode ser calculado a partir das taxas de falhas das seções e do número de clientes que essa seção abrange em um determinado período (Billinton & Allan 1996). A equação seguinte representa esse cálculo:

$$FEC^t = \frac{\sum_{s \in S} \lambda_s^t N_s}{N}, \quad (2.3)$$

onde:

- S é o conjunto de todas as seções;
- N_s é o número de clientes contidos na seção s e nas seções à jusante;
- N é o número total de clientes da rede de distribuição radial.

As falhas causam interrupções no sistema e diminuem sua confiabilidade. Por isso, ações de manutenção devem ser aplicadas, reparando ou mesmo substituindo um equipamento (Endrenyi & Anders 2006). Essas ações de manutenção, sejam preventivas ou corretivas, possuem custos associados. Deste modo, o objetivo principal do problema de otimização é minimizar o custo operacional de aplicação das ações de manutenção ao sistema, respeitando valores determinados de confiabilidade expressos pelo índice FEC.

2.3.4 Formulação Matemática

A função objetivo do problema de manutenção de redes de distribuição deve avaliar os custos de manutenção corretiva (CMC) e os custos da manutenção preventiva (CMP). A Figura 2.3 ilustra as curvas dos custos em relação à confiabilidade da rede (Reis 2007). Uma estratégia




Figura 2.3: Custo x Confiabilidade.

ótima para o problema de manutenção procura encontrar o custo total mínimo, que corresponde à soma dos custos CMC e CMP.

Assim, define-se a função objetivo do problema de otimização como a soma dos custos de manutenções corretiva e preventiva. O índice de confiabilidade (FEC) caracteriza a principal restrição do problema.

As variáveis de decisão são dadas pelas ações de manutenção. Os níveis de manutenção escolhidos para cada equipamento determinam os valores de custo total da função objetivo e as taxas de falha dos equipamentos, que caracterizam a confiabilidade do sistema. O número de níveis de manutenção possíveis depende do tipo do sistema de distribuição que está sendo analisado. O mais usual é que o maior número considerado seja de três níveis de manutenção (IEEE Standard 493 1998, Brown 2002):

1. Não realizar manutenção preventiva;
2. Realizar manutenção preventiva mínima;
3. Realizar manutenção preventiva máxima.

Alguns trabalhos utilizaram outras funções objetivo para o problema de otimização de políticas de manutenção em sistemas de distribuição. Por exemplo, Sittithumwat et al. (2004) adotou como função objetivo o índice FEC, para maximizar a confiabilidade do sistema restrita à disponibilidade de recursos para a manutenção preventiva em um determinado período do horizonte de planejamento. Outra possibilidade para o estudo do problema consiste em adotar

uma abordagem multiobjetivo, buscando maximizar a confiabilidade do sistema e minimizar o custo operacional da manutenção (Usberti, Lyra, Cavellucci & González 2012).

O modelo de otimização adotado neste trabalho foi inspirado nos trabalhos de Reis (2007) e Sittithumwat et al. (2004). A função objetivo a ser minimizada, representa os custos de manutenção preventiva e corretiva. As restrições representam as metas pré-definidas de confiabilidade do sistema. Assim, o problema de otimização de manutenções preventivas em sistemas de distribuição de energia elétrica pode ser formulado como segue:

$$\min_{\delta_e^t} \quad \sum_{e \in E} \left[\sum_{t=1}^T (p_e(\delta_e^t) + \lambda_e^t c_e) \times \alpha_t \right] \quad (2.4)$$

$$s.a : \quad FEC^t \leq \overline{FEC} \quad \forall t = 1, \dots, T, \quad (2.5)$$

onde:

- E é o conjunto dos equipamentos sujeitos às ações programadas de manutenção;
- $\overline{FEC}$ é o valor máximo permitido para o FEC;
- $p_e(\delta_e^t)$ é o custo da aplicação da manutenção preventiva para o equipamento e associado ao multiplicador de taxa de falha δ_e^t ;
- c_e é o custo da manutenção corretiva para o equipamento e ;
- T é o número de anos do horizonte de planejamento;
- α_t é um parâmetro usado para colocar todos os custos para o “valor presente”.

$$\alpha_t = \left(\frac{1}{1+j} \right)^t, \quad (2.6)$$

onde t é o período do horizonte de planejamento e j é a taxa de juros.

O conjunto de variáveis de decisões x_{en}^t forma uma política de planejamento que determina o custo total de manutenção aplicado e os multiplicadores de taxa de falha para cada equipamento da rede de distribuição. Quanto maior é o custo gerado pelas ações de manutenção programadas, menor será o valor do FEC e maior será a confiabilidade do sistema.

A solução do problema caracterizado pelas equações definidas nesta seção é o tema dos próximos capítulos deste trabalho.

A próxima seção apresenta uma breve discussão da bibliografia da área.

2.4 Revisão Bibliográfica

A revisão bibliográfica é classificada de acordo com os conceitos abordados na caracterização do problema de otimização de manutenção e data de publicação, seguindo os temas: manutenção centrada em confiabilidade; problema de manutenção em sistemas de distribuição de energia elétrica; e métodos de solução para o problema de manutenção em sistemas de distribuição de energia elétrica.

2.4.1 Manutenção Centrada em Confiabilidade

Endrenyi, Aboresheid, Allan, Anders, Asgarpoor, Billinton, Chowdhury, Dialynas, Fipper, Fletcher, Grigg, McCalley, Meliopoulos, Mielnik, Nitu, Rau, Reppen, Salvaderi, Schneider & Singh (2001) realizam uma revisão das estratégias de manutenção mais utilizadas no estudo do impacto da confiabilidade nos sistemas de distribuição. Uma análise geral sobre as políticas de manutenção apontam as vantagens das estratégias presentes na literatura. O trabalho é evidenciado por apresentar definições de termos presentes na metodologia de manutenção.

Abordando a construção de um modelo de taxa de falha, Endrenyi, Anders & Leite da Silva (1998) desenvolvem um modelo de processo de deterioração para descrever o impacto da manutenção preventiva na confiabilidade do sistema. No mesmo contexto, o trabalho realizado por Sim & Endrenyi (1988) apresenta um estudo da indisponibilidade dos equipamentos, introduzindo novos aspectos para os modelos de falha, com a finalidade de tornar o problema de otimização mais realista.

Endrenyi & Anders (2006) elaboram um estudo que relaciona a otimização da manutenção com a confiabilidade do sistema, visando unificar as pesquisas apresentadas anteriormente. Além disso, uma análise de sensibilidade sobre os custos de manutenção é realizada.

O trabalho desenvolvido por Moon, Yoon, Lee, Kim, Lee & Park (2006) completa o conjunto de pesquisas referentes à metodologia de manutenção centrada em confiabilidade. Os autores estudam a relação entre os custos de manutenção e duração das interrupções das falhas no sistema, através de modelo de otimização que busca o melhor planejamento de manutenção com custos mínimos.

2.4.2 Problema de Manutenção em Sistemas de Distribuição de Energia Elétrica

As pesquisas referentes ao problema de otimização proposto envolvem o estudo dos índices de confiabilidade e construção das funções objetivo.

Billinton & Billinton (1989) definem os principais índices que medem a confiabilidade do sistema através de um estudo comparativo entre duas revisões bibliográficas previamente desenvolvidas. Esse trabalho é base para a definição do índice de confiabilidade usado no problema de otimização proposto aqui.

Sittithumwat et al. (2004) desenvolvem um modelo matemático que visa maximizar esse índice de confiabilidade, que mede a *Frequência Média de Interrupções por Unidade Consumidora* (FEC). Esse modelo serviu como inspiração para o desenvolvimento do modelo matemático proposto neste trabalho.

Soudi & Tomsovic (2001) propõem um algoritmo por programação de metas como estratégia de solução de um problema de otimização multiobjetivo. O problema de otimização tem como objetivo identificar e localizar equipamentos de proteção, de forma a minimizar os índices de confiabilidade do sistema. O estudo de casos explora um exemplo de rede de distribuição radial, referência para os testes computacionais de pequeno porte realizados durante o desenvolvimento dos algoritmos aqui propostos.

2.4.3 Métodos de Solução para o Problema de Manutenção em Sistemas de Distribuição de Energia Elétrica

O problema de otimização da manutenção é um problema combinatorial de difícil solução. Para sua solução, a maioria dos trabalhos já publicados propõem a aplicação de técnicas heurísticas, mesmo em situações onde os problemas tratados são de pequeno porte.

Métodos Heurísticos como Estratégia de Solução para o Problema de Manutenção em Sistemas de Distribuição de Energia Elétrica

A maioria dos trabalhos publicados utiliza meta-heurísticas como estratégia para a obtenção da solução do problema. Por exemplo, o trabalho realizado por Kuntz, Christie & Venkata (2002) apresenta três métodos heurísticos para abordar o problema de planejamento de manutenção ótimo: algoritmo genético, *simulated annealing* e busca tabu. A técnica de busca local, *hill-climbing*, também é aplicada em conjunto com cada um dos três métodos. Os métodos propostos são aplicados a um modelo de otimização para o planejamento referente à infraestrutura do sistema, através de uma rede de distribuição composta por 10 componentes, para um horizonte de planejamento de seis anos. A infraestrutura do sistema refere-se à poda de vegetação, sendo considerada um componente da rede de distribuição.

O trabalho de Reis (2007) é destacado por elaborar duas meta-heurísticas: uma abordagem por método GRASP (*greedy randomized adaptive search procedure*); e uma abordagem por

algoritmo genético híbrido. Os estudos de casos mostram que a abordagem por algoritmo genético híbrido obtém bons resultados junto a problemas de escala real. Cabe ressaltar que o modelo utilizado é a base do modelo de otimização proposto neste trabalho.

Dahal & Chakpitak (2007) apresentam duas meta-heurísticas que combinam a técnica de algoritmo genético e *simulated annealing* para o problema de manutenção de geradores em sistemas de distribuição. Nos estudos de casos elaborados, as meta-heurísticas são aplicadas a um problema de pequeno porte, composto por um sistema de 21 geradores.

Bertling, Miranda, Matos & Hilber (2007) desenvolvem uma meta-heurística baseada na técnica de Enxame de Partículas, do inglês *Particle Swarm*, aplicando-a ao sistema de distribuição urbana de Estocolmo, na Suécia, que é uma rede de distribuição real, porém composta por apenas 57 componentes. Em outra pesquisa que aborda o enxame de partículas, Pereira, Lapa, Mol & da Luz (2010) propõem uma abordagem para encontrar o melhor planejamento de manutenção para geradores nucleares. Como em outros estudos, a abordagem também é aplicada a um sistema de pequeno porte, constituído por sete componentes.

Abordando um problema de otimização multiobjetivo, Moghaddam & Usher (2011a) apresentam dois métodos heurísticos por algoritmo genético e *simulated annealing*. O objetivo do modelo é procurar um planejamento de ações que minimize o custo total e maximize a confiabilidade do sistema ao longo do horizonte de planejamento. O trabalho discute a construção dos métodos e elabora testes a partir de um exemplo reduzido composto por 10 componentes e um horizonte de planejamento de 36 períodos.

Arya, Choube & Arya (2011) propõem uma técnica de otimização chamada Evolução Diferencial como estratégia para minimizar as taxas de falha e o tempo de reparo para os componentes de uma rede de distribuição. O trabalho busca provar a eficiência do método, e para isso conduz um estudo comparativo de desempenho entre Evolução Diferencial e uma abordagem por Enxame de Partículas. Os testes são realizados para uma rede radial pequena, composta por apenas sete componentes.

A técnica otimização ordinal, do inglês *Ordinal Optimization*, é proposta por Park & Yoon (2012) para a solução de um modelo de otimização que explora a confiabilidade de sistemas de distribuição. O trabalho também realiza um estudo comparativo entre a técnica desenvolvida e o método de Programação Dinâmica. Embora o exemplo numérico simulado aponte para o bom desempenho da técnica de otimização ordinal, os testes são realizados considerando a inserção de apenas quatro equipamentos para o processo de otimização.

É possível observar que a maioria dos trabalhos citados apresenta estudos computacionais limitados a problemas de pequeno porte. Essa dificuldade pode ser evidenciada através de

um estudo de complexidade, como mostram Usberti et al. (2012). Os autores demonstram a complexidade do problema de otimização da manutenção, classificando-o como NP-difícil. Além disso, realizam um estudo de casos sobre a abordagem por algoritmo genético híbrido desenvolvida por Reis (2007), aplicando a um grupo de três redes de distribuição de escala real.

Programação Dinâmica como Estratégia de Solução para o Problema de Manutenção em Sistemas de Distribuição de Energia Elétrica

Devido à dificuldade de solução do problema de otimização da manutenção, pode-se notar que os métodos de programação dinâmica estudados são abordados através de aproximações, que buscam reduzir a complexidade do método.

Zurn & Quintana (1975) apresentam uma abordagem por programação dinâmica com aproximações sucessivas como estratégia para solucionar o problema de planejamento da manutenção de geradores. Por se tratar de estudo mais antigo, as ideias envolvidas precedem o conceito de manutenção centrada em confiabilidade. A abordagem é testada para um exemplo pequeno, composto por 20 geradores e apenas 12 intervalos de tempo. Essa dificuldade em aplicar uma abordagem por programação dinâmica a problemas de grande porte pode ser evidenciada também nas pesquisas seguintes.

Um outro estudo que aborda programação dinâmica com aproximações sucessivas é proposto por Yamayee, Sidenblad & Yoshimura (1983). Nesse estudo, a ideia de confiabilidade é inserida, dando importância ao impacto da aplicação da manutenção. Todavia, os estudos de casos também são elaborados com base em sistemas pequenos. Nesse caso, o sistema possui 21 componentes para um período de horizonte de planejamento discretizado em 52 semanas.

Janjic & Popovic (2007) apresentam uma abordagem por programação dinâmica que utilizada uma heurística de priorização. De forma análoga aos estudos anteriores, o estudo de casos também é realizado através de redes de distribuição de pequeno porte. Contudo, o trabalho é relacionado por abordar um problema de otimização semelhante ao problema de otimização proposto nesta tese.

Um trabalho recente que envolve o método de programação dinâmica é desenvolvido por Moghaddam & Usher (2011b). Os autores propõem uma abordagem híbrida que explora o uso da programação dinâmica combinada com o método de *branch-and-bound* para encontrar soluções para o problema de manutenção preventiva restritos à confiabilidade do sistema. O trabalho apresenta um estudo computacional direcionado a um sistema composto por apenas dez componentes.

Todas as pesquisas citadas apresentam estudos computacionais restritos a sistemas de pe-

queno porte, mesmo que direcionados por aproximações ou hibridizações. Esse fato, em conjunto com a complexidade do problema de otimização da manutenção definida como NP-difícil, torna a aplicação do método de programação dinâmica ao problema de otimização de manutenção em redes de distribuição de escala real uma tarefa inviável de ser implementada.

Para viabilizar a aplicação, é proposta neste trabalho uma nova abordagem sobre o método de programação dinâmica, denominada Programação Dinâmica com Reduções de Espaço de Estados (PDREE). A abordagem proposta combina uma Técnica de Redução de Soluções Dominadas (TRSD), desenvolvida por Bacalhau, Usberti & Lyra (2013), e o método de Programação Dinâmica Diferencial Discreta (PDDD), inicialmente proposto por Heidari et al. (1971). Além dessa abordagem, são desenvolvidas duas abordagens híbridas que combinam a PDREE e uma abordagem por algoritmo genético híbrido previamente desenvolvida por Reis (2007).

2.5 Considerações Finais

O capítulo apresentou os principais aspectos da manutenção preventiva com foco no problema de otimização aplicado ao sistema de distribuição de energia elétrica e na formulação matemática do modelo de otimização. Além disso, pesquisas relacionadas à área foram discutidas através da elaboração de uma revisão bibliográfica.

No próximo capítulo, são apresentadas a estrutura do método por algoritmo genético e a abordagem por algoritmo genético híbrido (AGH) desenvolvido por Reis (2007), definida como objeto de estudo para este trabalho.

Algoritmo Genético Híbrido Aplicado ao Problema de Otimização de Manutenção Preventiva

3.1 Introdução

O capítulo apresenta os principais conceitos que representam os passos relacionados à estrutura básica dos algoritmos genéticos e à estrutura do algoritmo genético híbrido.

A abordagem por Algoritmo Genético Híbrido (AGH) desenvolvida por Reis (2007) é resumida em tópicos e os algoritmos de busca local que definem a hibridização do algoritmo são apresentados. Por fim, são destacados comentários gerais sobre o capítulo.

3.2 Algoritmos Genéticos

Os algoritmos genéticos (AG) são métodos de otimização que procuram emular computacionalmente os fenômenos de reprodução, evolução e adaptação, na busca por soluções ótimas de um problema de otimização. Foram introduzidos por Holland através da publicação do livro *Adaptation in Natural and Artificial Systems* em (1975), e tem como estratégia tratar possíveis soluções de um problema como *indivíduos* de uma *população* que *evoluem* ao longo de gerações (Goldberg 1989). Esse processo pode ser formalizado em um método de otimização, resumido nos passos ilustrados na Figura 3.1, e detalhados no Pseudocódigo 3.1.




Figura 3.1: Estrutura do algoritmo gen tico.

O algoritmo gen tico detalhado pelo Pseudoc digo 3.1 mant m uma popula  o de indiv duos $P(t)$ para cada itera  o t do algoritmo. A fun  o de avalia  o operada a cada itera  o   denominada fun  o *fitness* e define os indiv duos da popula  o que s o considerados mais adaptados para o problema, para serem selecionados para a aplica  o dos operadores gen ticos. Para representar o processo de avalia  o de aptid o e os operadores gen ticos, s o definidos alguns termos referentes ao algoritmo.

- **Cromossomo:** O cromossomo   uma cadeia de atributos associados ao problema, chamados genes. Os genes possuem uma localiza  o definida, chamada *locus*, e um valor associado chamado alelo (Goldberg 1989). A Figura 3.2 exemplifica a estrutura de um cromossomo representada por uma cadeia de atributos, onde cada atributo corresponde a um d gito real no intervalo $[0 \ 1]$;
- **Espa o Genot pico:**   o espa o que cont m a popula  o de indiv duos caracterizados


Algoritmo Genético

```

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:   realizar cruzamentos entre os indivíduos selecionados de  $P(t)$ 
8:   realizar mutações em indivíduos de  $P(t)$ 
9:   avaliar  $P(t)$ 
10: fim enquanto

```

Pseudocódigo 3.1: Algoritmo Genético

Figura 3.2: Cromossomo de comprimento $L = 10$

por uma codificação, ou seja, um cromossomo que representa uma solução potencial do problema;

- **Espaço Fenotípico:** É o espaço que contém a população de indivíduos caracterizados pela interpretação do genótipo. Cada indivíduo corresponde a uma proposta de solução que é avaliada pela função de aptidão (*fitness*).

A Figura 3.3 ilustra o processo iterativo entre os dois espaços definidos no algoritmo genético. A passagem $g_1 \rightarrow f_1$ representa a decodificação da população inicial definida no espaço genotípico para o espaço fenotípico, $f_1 \rightarrow f_2$ representa o processo de seleção através da função de aptidão dos elementos da população inicial no espaço fenotípico, $f_2 \rightarrow g_1$ representa codificação da população selecionada pela função de aptidão do problema no espaço fenotípico para o espaço genotípico, $g_2 \rightarrow g'_1$ representa a população selecionada passando pelo processo de recombinação e mutação no espaço genotípico. Esse processo de recombinação e mutação leva a uma nova geração da população.

Os principais passos que definem a estrutura do algoritmo genético, em conjunto com a abordagem desenvolvida por Reis (2007), são resumidos nas seções seguintes.




Figura 3.3: Interação entre os espaços genotípico e fenotípico (Atmar 1994).

3.3 Especialização do AG para o Problema de Manutenção Preventiva em Sistemas de Distribuição de Energia Elétrica

3.3.1 Codificação dos Indivíduos

Os cromossomos da população podem ser codificados por números binários, reais e inteiros, além da representação por caracteres (Bäck, Fogel & Michalewicz 2000). A codificação de um indivíduo é uma etapa fundamental em um algoritmo evolutivo (Michalewicz 1996). Em alguns estudos, o tipo de representação é determinante para os operadores genéticos desenvolvidos, como apresenta a abordagem proposta por Reis (2007). Os indivíduos são codificados como um vetor de números reais. Cada equipamento da rede de distribuição será uma posição neste vetor e indicará o valor do investimento destinado à manutenção preventiva desse equipamento. Os valores de investimentos são normalizados e definidos no intervalo $[0, 1]$, o que caracteriza os alelos. A Figura 3.4 ilustra um exemplo da codificação realizada, apresentando o investimento destinado a cada equipamento.




Figura 3.4: Codificação do indivíduo para a abordagem

Um processo de decodificação sugerido por Reis (2007), prevê o tratamento de indivíduos

infectíveis, dadas as restrições do problema de otimização de manutenção proposto. O processo é composto por duas fases, que representam a busca programada pelas ações de manutenção para os elementos em função do investimento alocado. Detalhes adicionais sobre o processo de decodificação podem ser vistos em Reis (2007).

O nível de manutenção de um elemento selecionado aumenta a cada iteração, de acordo com a prioridade calculada através da seguinte equação:

$$P_e = inv_e - invJaAlocado_e, \quad (3.1)$$

onde:

- P_e é a prioridade calculada para o equipamento e ;
- inv_e é o investimento destinado ao equipamento e ;
- $invJaAlocado_e$ é o investimento já alocado para o equipamento e .

3.3.2 População Inicial

Uma população é um conjunto de cromossomos em que cada um representa uma solução candidata para o problema (Michalewicz 1996). Usualmente, uma população inicial é gerada aleatoriamente e codificada em um conjunto de cromossomos de comprimento finito.

Pode-se gerar uma solução aleatoriamente para determinar os indivíduos da população. Porém, com conhecimento prévio do problema e informações sobre cada equipamento que compõe a rede de distribuição, é mais vantajoso determinar um processo baseado nessas características. O processo buscará reduzir o tempo de criação e manter a diversidade da população para evitar uma convergência prematura do algoritmo genético.

Na abordagem desenvolvida por Reis (2007), a população é criada a partir de uma heurística construtiva composta de função de avaliação, que aumentando ou diminuindo o nível de manutenção determina a relação custo-benefício nos equipamentos da rede.

$$FG(e) = \frac{custo_{e,max} - custo_{e,atual}}{contFEC_{e,atual} - contFEC_{e,min}}, \quad (3.2)$$

onde:

- $contFEC_{e,atual}$ é a contribuição atual do elemento e para o FEC total do sistema;
- $contFEC_{e,min}$ é o valor da contribuição desse elemento para o FEC no maior nível de confiabilidade;

- $custo_{e,max}$ é o custo do maior nível de manutenção;
- $custo_{e,atual}$ é o custo do nível atual de manutenção.

A estratégia da heurística construtiva consiste em selecionar aleatoriamente um elemento na população e definir uma ação de manutenção programada fazendo uso da Equação 3.2 de custo-benefício. O processo se repete até que toda a população atinja a factibilidade. O objetivo é gerar boas soluções iniciais para o algoritmo genético e aumentar a diversidade e o espaço de busca por novas soluções.

3.3.3 Avaliação

A avaliação é dada por uma função de aptidão denominada *fitness*, que está associada à função objetivo do problema de otimização. Essa função é aplicada ao indivíduo e mede o desempenho (qualidade) dessa representação em relação ao problema especificado.

A função de aptidão é aplicada depois de um processo de decodificação, e parte de características fenotípicas a valores que representam o desempenho citado. A Equação 3.3 ilustra o cálculo da função *fitness* associada ao modelo.

$$\frac{1}{F(soluc\ao)} \quad , \quad (3.3)$$

onde:

- $F(soluc\ao)$ é o valor associado à Equação 2.4 definida no Capítulo 2.3.

A partir desse cálculo, o próximo processo do algoritmo genético é criar um mecanismo de seleção para a aplicação dos operadores genéticos.

3.3.4 Seleção

A seleção também é realizada no espaço fenotípico, e tem como principal objetivo escolher indivíduos dentro de uma população com probabilidade proporcional ao *fitness*, funcionando como uma espécie de filtro (Michalewicz & Fogel 2000). Os métodos de seleção mais comuns são (Goldberg 1989):

- Elitismo: O elitismo pode ser aplicado em conjunto com outros métodos, e garante que o algoritmo genético mantenha um determinado número de indivíduos melhor adaptados a cada geração. O método impede que os operadores genéticos eliminem os indivíduos selecionados para o cruzamento;

- **Método da Roleta:** É um método probabilístico baseado no jogo da roleta. A medida de aptidão determina a proporção que cada indivíduo irá ocupar na roleta. Esse método proporciona diversidade para a população, dado que os indivíduos com maiores valores de aptidão nem sempre são escolhidos;
- **Método do Torneio:** Escolhe-se aleatoriamente uma determinada quantidade de indivíduos na população inicial. O número de indivíduos escolhidos é definido por um parâmetro previamente fixado, que define a pressão seletiva. Dentre os indivíduos selecionados é realizado um torneio, onde o indivíduo que apresentar o maior valor de aptidão é selecionado para a geração seguinte. Faz-se tantos torneios quanto o número de indivíduos que devem ser selecionados.

O processo de seleção dos indivíduos para a aplicação dos operadores genéticos, dado por Reis (2007), usa a seleção por torneio binário, onde apenas dois indivíduos participam. O processo segue os três passos seguintes:

1. Selecionam-se aleatoriamente na população dois indivíduos;
2. Calcula-se a função de aptidão para cada indivíduo selecionado;
3. Realiza-se o torneio entre os dois indivíduos e o mais apto é selecionado.

3.3.5 Operadores Genéticos

Os operadores mais utilizados são os operadores de recombinação e mutação. Esses operadores são aplicados após o processo de seleção dentro do espaço genotípico. Operam sobre os indivíduos buscando novas características para a nova geração de indivíduos.

- **Recombinação:**

Selecionados dois ou mais indivíduos, definidos como progenitores, o operador genético busca misturar as características desses indivíduos produzindo novos indivíduos (descendentes).

Pode ser aplicado em um único ponto ou multi-pontos a partir desses pontos de referência, ou pode também ser aplicado de forma uniforme baseado em uma probabilidade atribuída a cada gene. A Figura 3.5 ilustra o operador de recombinação para um ponto único.

- **Mutação:**




Figura 3.5: Recombinação em cromossomos de comprimento $L = 10$.

O operador de mutação gera uma perturbação das informações dos genes e altera o código genético gerando um novo indivíduo. O parâmetro taxa de mutação se refere à probabilidade de um gene sofrer alteração. O intuito do operador é aumentar a diversidade de indivíduos na população e permitir que novas características sejam exploradas para a solução do problema. A Figura 3.6 ilustra um exemplo de operador de mutação aplicado a um indivíduo.




Figura 3.6: Mutação em cromossomos de comprimento $L = 10$.

A abordagem AGH proposta por Reis (2007) utiliza o operador genético de recombinação do tipo aritmético. A codificação é dada por um vetor de números reais (Michalewicz 1996) e o processo gera um novo indivíduo, definido como I' , através de uma combinação linear dos indivíduos *progenitores*, usando um vetor auxiliar $\beta_i \in [0, 1]$.

O operador de mutação gera um novo indivíduo I' através de uma perturbação em cada posição e do indivíduo (progenitor) selecionado, conforme ilustra a seguinte equação:

$$I_e = \begin{cases} I_e^i + \cup(-\Delta, \Delta) & \text{se } \tau \leq \rho \\ I_e^i & \text{caso contrário} \end{cases} \quad \forall e \in E, \quad (3.4)$$

onde:

- τ é um número aleatório no intervalo $[0, 1)$;
- ρ é a taxa de mutação;
- Δ define a variação máxima permitida;
- E é o conjunto de elementos sujeitos à manutenção no problema;
- $\cup(-\Delta, \Delta)$ um valor aleatório uniformemente distribuído no intervalo $[-\Delta, \Delta]$

Ao longo das gerações do algoritmo genético, o intervalo que define os valores de investimento para cada equipamento vai diminuindo, conforme os indivíduos vão evoluindo na população. O operador de mutação é aplicado para aumentar o intervalo e garantir uma maior diversidade para a população.

3.3.6 Atualização da População

Reis (2007) aplica a estratégia *steady-state* para atualização da população. Um ou dois indivíduos são gerados a cada iteração e concorrem com seus *progenitores* para serem incluídos na população e, assim, pode-se evitar que indivíduos considerados bons para o problema sejam descartados. Contudo, existe o risco dessa população perder diversidade rapidamente. Para diminuir esse risco, impede-se que indivíduos duplicados sejam inseridos na população.

3.3.7 Critérios de Parada

Alguns problemas de otimização são difíceis de serem tratados, o que gera um procedimento computacional custoso. Deste modo, são inseridos no algoritmo genético critérios de parada que determinam o término do processo. Podem ser definidos de várias formas, tais como o critério de convergência da população, o qual é determinado pelo nível de diversidade dessa população, e por um número pré-definido de gerações do algoritmo.

Na abordagem desenvolvida por Reis (2007), os critérios de parada são os principais já mencionados: o número de gerações; e a convergência da população. Se algum dos critérios for atingido, a busca é interrompida.

3.3.8 Parâmetros de Controle

Para que a evolução da população de indivíduos seja eficiente, a definição dos parâmetros do algoritmo genético é uma etapa importante da construção do algoritmo.

Alguns parâmetros, como número de iterações, taxa de mutação, tamanho da população, e taxa de recombinação, afetam diretamente o desempenho do algoritmo genético para a obtenção de uma boa solução final, com um tempo de processamento satisfatório.

No algoritmo proposto por Reis (2007), os parâmetros são determinados empiricamente para os cenários explorados nos estudos de casos. Os parâmetros a serem determinados são: o tamanho da população; a taxa de mutação; e o número máximo de iterações. Além disso, também é necessário determinar um parâmetro que mede o progresso da busca, determinando a convergência da população.

3.4 Hibridização do Algoritmo Genético

São incorporados ao algoritmo genético procedimentos que definem a formalização do processo de hibridização. Buscas locais são implementadas com conhecimento no domínio do problema de otimização. A abordagem desenvolvida por Reis (2007) utiliza uma busca específica para a exploração local do espaço de soluções. O Pseudocódigo 3.2 mostra a incorporação da busca local ao algoritmo genético e formaliza a abordagem Algoritmo Genético Híbrido (AGH).

Algoritmo Genético Híbrido $AGH(tampop)$

```

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:    realizar cruzamentos entre os indivíduos selecionados de  $P(t)$ ;
8:    realizar mutações em indivíduos de  $P(t)$ ;
9:     $P(t) \leftarrow BL(P(t))$ ;
10:   avaliar  $P(t)$ ;
11: fim enquanto
Retorna: (melhor indivíduo)
```

Pseudocódigo 3.2: Algoritmo Genético Híbrido

A busca local (BL) desenvolvida é aplicada de forma parcial no espaço de soluções através da limitação do número de iterações do processo, pois a busca eleva consideravelmente o tempo

computacional. São realizadas as realocações de investimentos apenas em elementos que apresentam um desvio caracterizado entre os investimentos alocados dos progenitores selecionados para a recombinação, reduzindo o tamanho do espaço de solução da busca local parcial e diminuindo o número de pares de elementos testados. O número de pares será dado por $|E'| * |E'|$, sendo que E' é um subconjunto do conjunto E que contém todos os elementos disponíveis. O subconjunto E' é formado pelos elementos $e \in E$ tais que, $I_e^1 \neq I_e^2$, sendo I_e^1 o investimento alocado ao elemento e para o progenitor 1 e I_e^2 o investimento alocados ao elemento e para o progenitor 2.

As principais características da busca local proposta são apresentadas no Pseudocódigo 3.2. O objetivo é reduzir os custos de manutenção programada das soluções realocando o investimento entre pares de equipamentos e buscar ações de manutenção programadas mais efetivas que aumentam a confiabilidade do sistema. Os passos da busca local parcial são apresentados pelos Pseudocódigos 3.3 e 3.4.

Busca Local Parcial $BL(solucao)$

```

1:  inicializar  $E'$ ;
2:  para  $\forall e \in E'$  faça
3:    para  $\forall f \in E'$  faça
4:       $mov \leftarrow buscarMelhorMovimento(e, f)$  (Pseudocódigo 4, a seguir);
5:      se  $mov$  melhora a solução  $solucao$  então
6:         $solucao \leftarrow executarMovimento(solucao, mov)$ ;
7:         $melhorou \leftarrow true$ ;
8:      fim se
9:    fim para
10: fim para
Retorna:  $solucao$ 

```

Pseudocódigo 3.3: Busca Local Parcial

Determinado o subconjunto E' , aplica-se um procedimento que determina os melhores movimentos que podem ser executados, dados dois indivíduos selecionados nesse subconjunto. Se os movimentos realizados melhoram a solução, ela é então modificada e outros indivíduos são selecionados, até que todos sejam analisados.

3.5 Comentários Finais

Este capítulo apresentou os principais conceitos de um algoritmo genético e resumiu a abordagem por algoritmo genético híbrido previamente desenvolvida por Reis (2007). Foi apresentada também a estrutura do algoritmo genético e do algoritmo genético híbrido, com ênfase nos

Busca do Melhor Movimento *buscarMelhorMovimento(e, f)*

```
1: para  $ano \leftarrow 1$  até  $T$  faça
2:    $N \leftarrow$  conjunto de níveis de manutenção inferiores ao nível atual do elemento  $e$ ;
3:    $M \leftarrow$  conjunto de níveis de manutenção igual ou superiores ao nível atual do
   elemento  $f$ ;
4:   para  $\forall n \in N$  e  $\forall m \in M$  faça
5:      $mov \leftarrow testaMovimento(n, m)$ ;
6:      $atualizarMelhorMovimento(mov, melhorMov)$ ;
7:   fim para
8: fim para
Retorna:  $melhorMov$ 
```

Pseudocódigo 3.4: Busca do Melhor Movimento

algoritmos de busca local.

Como mencionado no capítulo anterior, a abordagem por algoritmo genético híbrido (AGH) foi escolhida como objeto de estudo comparativo nesta tese.

Programação Dinâmica Aplicada ao Problema de Otimização de Manutenção Preventiva

4.1 Introdução

O método de Programação Dinâmica (PD) consiste em resolver um problema de otimização através de uma sequência de decisões que buscam soluções para subproblemas interligados de forma recursiva. Aplicado ao problema de manutenção preventiva proposto, o método procura encontrar o melhor planejamento de manutenções preventivas em sistemas de distribuição de energia elétrica.

Sendo assim, o capítulo apresenta os conceitos do método de programação dinâmica e a aplicação do método de programação dinâmica ao problema de manutenção preventiva em sistemas de distribuição de energia elétrica. Na última seção, são apresentados comentários finais sobre o capítulo e as ideias iniciais do capítulo seguinte.

4.2 Programação Dinâmica

Desenvolvida por Bellman (1957), a programação dinâmica é uma técnica de programação matemática utilizada para resolver problemas de otimização. A estratégia do método busca solucionar uma série de subproblemas do problema original, interligados recursivamente. Divide

o problema original em partes menores, encontra as soluções para as partes, e então as combina a fim de obter uma solução global.

Como mencionado, o método se aplica a problemas de otimização (Cormen, Leiserson, Rivest & Stein 2001). Sendo assim, toma-se o seguinte problema de otimização descrito através do método de programação dinâmica:

$$\text{Min}_{u_1, \dots, u_K} \left\{ \sum_{k=1}^K \varphi_k(x_k, u_k) \right\} \quad (4.1)$$

s.a:

$$\begin{aligned} x_{k+1} &= h_{k+1}(x_k, u_{k+1}) \\ \underline{x} &\leq x_k \leq \bar{x}, \quad \forall k \in \{1, \dots, K\} \\ \underline{u} &\leq u_k \leq \bar{u}, \quad \forall k \in \{1, \dots, K\} \end{aligned} \quad (4.2)$$

onde:

- $\varphi_k(x_k, u_k)$ é a função recursiva para o estágio k ;
- x_k é o vetor de estado n -dimensional para o estágio k ;
- u_k é o vetor de controle q -dimensional para o estágio k ;
- h é a função de transição de estado que determina o próximo estado x_{k+1} dado o estado x_k e o controle u_{k+1} .

O estágio k corresponde a uma etapa do processo de decisões sequenciais do método de programação dinâmica. A programação dinâmica estrutura os problemas de otimização em múltiplos estágios, nos quais as decisões são avaliadas a cada intervalo de tempo, caracterizando a estrutura sequencial de abordagem do problema.

A variável de estado descreve a condição em que se encontra um dado estágio do processo. O estado do sistema é definido como um vetor x_k composto por n variáveis de estado (Larson 1968).

$$x_k = \begin{bmatrix} x_k^1 \\ x_k^2 \\ \vdots \\ x_k^n \end{bmatrix} \quad (4.3)$$

A cada estágio, são descritas as opções que causam uma transição de um determinado estado para outro. Essas opções, também chamadas de decisões, representam as variáveis de controle. Assim, pode-se definir um vetor de controle u_k , composto por q variáveis de controle, que afetam

diretamente as variáveis de estado (Kirk & Kreider 1970).

$$u_k = \begin{bmatrix} u_k^1 \\ u_k^2 \\ \vdots \\ u_k^q \end{bmatrix} \quad (4.4)$$

A sequência de decisões dadas pelos vetores de controle caracteriza uma política de decisões. Assim, pode-se obter uma sequência de vetores de estado associados à essa política de decisões e definir uma trajetória para o sistema. Para determinar essa sequência, um processo de otimização é construído, onde uma solução para um problema de otimização com K -estágios é obtida. Esse processo consiste em resolver um estágio a cada intervalo de tempo, e buscar um vetor de controle ótimo e um vetor de estado ótimo, através de uma função de recursão. O princípio que suporta e garante que a solução ótima seja encontrada é o ‘princípio de otimalidade de *Bellman*’. O princípio diz que, independente do estado e da decisão tomada para o estágio corrente, os estados restantes a partir deste estágio também constituirão uma trajetória ótima.

Uma vez que o método de programação dinâmica resolve um problema de otimização, pode-se definir uma função de custo ótimo acumulado $F(x_k)$, que associa a condição do vetor de estado x_k , para o estágio k , e retorna a cada iteração calculada um valor que representa essa condição. A Equação (4.5), descrita a seguir, descreve o princípio de otimalidade de *Bellman*.

$$F_{k+1}(x_{k+1}) = \min_{u_1, u_2, \dots, u_{k+1}} \left\{ \sum_{j=1}^{k+1} \varphi_j(x_j, u_j) \right\} \quad (4.5)$$

Deste modo, mostra-se que a Equação (4.6) define a equação recursiva de otimalidade (Larson 1968).

$$F_{k+1}(x_{k+1}) = \min_{u_{k+1} \in U_{k+1}} \{ \varphi_{k+1}(u_{k+1}) + F_k(x_k) \} \quad (4.6)$$

Assim, pode-se ilustrar o processo de otimização para decisões multiestágios pela Figura 4.1.

O processo de otimização pode ser concebido em duas vias, no sentido normal (*forward*), ou no sentido inverso (*backward*). A relação recursiva, presente na estratégia, pode ser vista identificando um estado x_{k+1} , para o estágio $k+1$, dado o estado x_k disponível. Dada a equação recursiva de otimalidade, o processo de otimização pode ser realizado pela estratégia *forward*.

A Figura 4.2 ilustra um exemplo unidimensional de processo de otimização do método de programação dinâmica pela estratégia *forward* (Gonzalez 2005).

O processo de otimização termina quando $F_K(x_K)$ é calculado para todos os valores factíveis




Figura 4.1: Processo de otimização de decisão multiestágio - Função de custo ótimo




Figura 4.2: Diagrama de estados

de x_K e o valor de função objetivo ótimo é determinado. A partir disso, é iniciado um outro processo para a recuperação da trajetória ótima. São percorridos novamente todos os estágios do processo de otimização, onde uma trajetória ótima é obtida através da equação de transição de estados definida na Equação (4.2), dos vetores de controle ótimo e dos vetores de estado ótimo obtidos ao longo do processo de otimização.

A recuperação é dada a partir do último vetor de estado ótimo calculado x_K^* , até o primeiro

vetor de estado ótimo x_0^* , como mostram as seguintes equações:

$$\left\{ \begin{array}{l} x_{K-1}^* = x_K^* - f_K(u_K^*) \\ x_{K-2}^* = x_{K-1}^* - f_{K-1}(u_{K-1}^*) \\ \vdots \\ x_1^* = x_2^* - f_2(u_2^*) \\ \vdots \\ x_0^* = x_1^* - f_1(u_1^*) \end{array} \right. \quad (4.7)$$

Sendo assim, o método de programação dinâmica pode ser representada pelo Pseudocódigo 4.1.

Programação Dinâmica
1: Para $k = 0, \dots, K$ faça
2: Determine $x_k(u_k)$
3: Calcule $F_k(x_k)$
4: Fim Para
5: Determine $F_K(x_K)$
6: Para $k = K - 1, \dots, 0$ faça
7: Calcule $x_k^* = x_{k+1}^* - f_{k+1}(u_{k+1}^*)$
8: Fim Para

Pseudocódigo 4.1: Programação Dinâmica

4.3 Programação Dinâmica Aplicada ao Problema de Otimização da Manutenção Preventiva em Sistemas de Distribuição de Energia Elétrica

Inicialmente, o problema de manutenção preventiva em redes de distribuição de energia elétrica foi explorado como um problema da mochila multidimensional ((Bacalhau, Usberti, Filho & Cavellucci 2012);(Bacalhau, Usberti & Filho 2012)). Esse estudo foi utilizado para identificar os principais conceitos para a adaptação do problema visando a aplicação do método de programação dinâmica.

Como o problema de manutenção preventiva proposto é um problema de otimização, ele poderá ser resolvido pelo método de programação dinâmica.

O conceito de estágio k é associado aos equipamentos e que compõem a rede de distribuição. Cada equipamento corresponde a um subproblema do problema original, que é o planejamento

da manutenção do sistema de distribuição. A partir disso, representa-se um vetor de estado x_k pela Equação (4.8).

$$x_k = \begin{bmatrix} x_k^1 \\ \vdots \\ x_k^t \\ \vdots \\ x_k^T \end{bmatrix}, \quad x_k^t \in X_k. \quad (4.8)$$

onde:

- x_k^t é a variável de estado associada ao equipamento k e período de horizonte de planejamento t ;
- X_k é o conjunto de vetores de estado x_k correspondentes ao estágio k , com $X_k \subset [0, \overline{FEC}]$.

O vetor de estado x_k representa a expectativa de falha por período acumulada para os equipamentos de $1, \dots, k$. A expectativa de falha por período é dada pelo índice de confiabilidade calculado para cada horizonte de planejamento, conforme o modelo de otimização proposto.

Desta forma, o vetor de controle representa as ações de manutenção preventiva disponíveis, como mostra a Equação (4.9).

$$u_k = \begin{bmatrix} u_k^1 \\ \vdots \\ u_k^t \\ \vdots \\ u_k^T \end{bmatrix}, \quad u_k^t \in U_k. \quad (4.9)$$


onde:

- u_k^t é a variável de controle associada às ações de manutenção disponíveis para o equipamento k no período de horizonte de planejamento t ;
- U_k é o conjunto de todas as ações de manutenção disponíveis para o equipamento k .

Nota-se que, u_k^t está relacionada diretamente à variável δ_e^t , sendo U_k o mesmo conjunto Δ_e definido na Equação (2.1) da Subseção 2.3.2.


As Figuras 4.3(a), 4.3(b) e 4.3(c) ilustram os vetores de estado x_k possíveis, considerando um, dois e três horizontes de planejamento, respectivamente.

No modelo adotado para a otimização de estratégias de manutenções preventivas em sistemas de distribuição, a topologia da rede não interfere na ordem em que os equipamentos são inseridos



(a) Para um ano de horizonte de planejamento

(b) Para dois anos de horizonte de planejamento



(c) Para três anos de horizonte de planejamento

Figura 4.3: Vetores de estados possíveis

em cada estágio do processo de otimização do método de programação dinâmica. A topologia da rede de distribuição é usada apenas para avaliar o número de consumidores afetados pelas falhas.

O processo de otimização do método de programação dinâmica pode ser resolvido através da estratégia *forward*. Sendo assim, define-se a equação de transição de estados a partir da Equação (4.2).

$$x_{k+1} = x_k + f_{k+1}(u_{k+1}), \quad (4.10)$$

onde:

- f_{k+1} é um vetor que contém os valores de confiabilidade calculados para o equipamento $k + 1$ para todos os períodos de horizonte de planejamento, como mostram as Equações (4.11-4.13).

$$f_k = \begin{bmatrix} f_k^1(u_k) \\ \vdots \\ f_k^t(u_k) \\ \vdots \\ f_k^T(u_k) \end{bmatrix} \quad (4.11)$$

$$f_k^t(u_k) = \frac{\lambda_k^t N_s}{N} \quad (4.12)$$

$$\lambda_k^t = \lambda_k^{(t-1)} u_k^t, \quad u_k^t \in U_k \quad (4.13)$$

onde:

- f_k^t é o cálculo da confiabilidade do equipamento k para o período de horizonte de planejamento t ;
- $\lambda_k^{(t-1)}$ é a taxa de falha do equipamento k para o período de horizonte de planejamento do ano anterior, sendo definido como taxa de falha inicial quando $t = 1$;
- λ_k^t é a taxa de falha para o equipamento k e período de horizonte de planejamento t ;
- N_s é o número de clientes da seção s e das seções à jusante, onde se encontra o equipamento k ;
- N é o número total de clientes que a rede de distribuição atende.

Além disso, é possível notar que f_k^t é obtido a partir do cálculo do FEC^t para o equipamento k , definido na Equação (2.3) da Subseção 2.3.3.

A seguir, é apresentado na Figura 4.4 um exemplo didático para ilustrar o cálculo dos vetores de estado definidos.

A rede fictícia apresentada na Figura 4.4 é composta por três transformadores A, B e C, distribuídos em três seções distintas, as quais abrangem 100, 200 e 300 consumidores respectivamente. As seções são delimitadas pelo equipamento de proteção e o número total de consumidores é dado pela soma dos consumidores presentes em cada seção. Os outros valores necessários para o cálculo, tais como os multiplicadores de taxa de falha associados à ação de manutenção de não realizar manutenção preventiva (δ_s), os multiplicadores de taxa de falha associados à ação de manutenção de realizar manutenção preventiva (δ_c), e as taxas de falha iniciais, podem ser vistos na Tabela 4.2.




Figura 4.4: Exemplo Simples

Rede Exemplo			
Transformador	Taxa de Falha Inicial	δ_c	δ_s
A	0.05	0.90	1.50
B	0.04	0.95	1.20
C	0.07	0.85	1.30

Tabela 4.2: Transformadores - Rede de Distribuição Fictícia

O objetivo do exemplo é demonstrar o cálculo dos vetores de estado para a rede de distribuição fictícia, dados alguns cenários simulados. Esses cenários exploram diferentes períodos de horizonte de planejamento e diferentes planejamentos de manutenção preventiva.

- Cenário 1: Para um ano de horizonte de planejamento sem manutenção preventiva programada.

Como a topologia da rede não influencia a ordem de inserção dos equipamentos, o processo de otimização do método de programação dinâmica pode ser efetuada de forma arbitrária. Nesse cenário, a sequência dos transformadores foi determinada A, C e B.

O processo é iniciado pelo estágio inicial dado $x_0 = 0$, que caracteriza a ausência de equipamentos analisados.

$$x_0 = 0;$$

O primeiro estágio representa o transformador A, calculado conforme as Equações (4.10)-(4.13) definidas.

$$x_1 = x_0 + f_1(u_1) = x_0 + (f_1^1(u_1));$$

$$f_1^1(u_1) = \frac{(\lambda_1^{(0)} u_1^1) N_1}{N} = \frac{(0.05 \cdot 1.5) \cdot 100}{600} = 0.0125;$$

O segundo estágio representa o transformador C. De acordo com a definição do vetor de estados, a confiabilidade calculada para o estágio anterior é acumulada.

$$x_2 = x_1 + f_2(u_2) = 0.0125 + (f_2^1(u_2));$$

$$f_2^1(u_2) = \frac{(\lambda_2^{(0)} u_2^1) N_2}{N} = \frac{(0.07 \cdot 1.3) \cdot 300}{600} = 0.0455;$$

De forma análoga, é calculado o último estágio, o qual representa o transformador B.

$$x_3 = x_2 + f_3(u_3) = (0.0125 + 0.0455) + (f_3^1(u_3));$$

$$f_3^1(u_3) = \frac{(\lambda_3^{(0)} u_3^1) N_3}{N} = \frac{(0.04 \cdot 1.2) \cdot 200}{600} = 0.016;$$

$$x^* = x_3 = (0.0125 + 0.0455 + 0.016) = 0.074;$$

Assim, obtêm-se o resultado final $x^* = 0.074$, que é a soma de todos os índices de confiabilidade calculados para cada transformador. Esse valor diz que o planejamento de manutenção obtido terá uma probabilidade de 7.4% de falhar ao longo do horizonte de planejamento determinado.

- Cenário 2: Para horizonte de planejamento de dois anos, com manutenção preventiva programada para o transformador A no primeiro ano de horizonte de planejamento e com manutenção preventiva programada para o transformador C no segundo ano de horizonte de planejamento.

Nesse cenário, o objetivo é demonstrar o cálculo dos vetores de estado para múltiplos períodos de horizonte de planejamento.

$$x_0 = (0, 0);$$

O primeiro estágio refere-se ao transformador A, com manutenção preventiva programada para o primeiro ano de horizonte de planejamento.

$$\begin{aligned} x_1 &= x_0 + f_1(u_1) = (0, 0) + (f_1^1(u_1), f_1^2(u_1)); \\ f_1^1(u_1) &= \frac{(\lambda_1^{(0)} u_1^1) N_1}{N} = \frac{(0.05 \cdot 0.9) \cdot 100}{600} = 0.0075; \\ f_1^2(u_1) &= \frac{(\lambda_1^{(1)} u_1^2) N_1}{N} = \frac{(\lambda_1^{(0)} u_1^1 u_1^2) N_1}{N} = \frac{(0.05 \cdot 0.9 \cdot 1.5) \cdot 100}{600} = 0.01125; \end{aligned}$$

O segundo estágio calculado se refere ao transformador C com manutenção preventiva programada para o segundo ano de horizonte de planejamento.

$$\begin{aligned} x_2 &= x_1 + f_2(u_2) = (0.0075, 0.01125) + (f_2^1(u_2), f_2^2(u_2)); \\ f_2^1(u_2) &= \frac{(\lambda_2^{(0)} u_2^1) N_2}{N} = \frac{(0.07 \cdot 1.3) \cdot 300}{600} = 0.0455; \\ f_2^2(u_2) &= \frac{(\lambda_2^{(1)} u_2^2) N_2}{N} = \frac{(\lambda_2^{(0)} u_2^1 u_2^2) N_2}{N} = \frac{(0.07 \cdot 1.3 \cdot 0.85) \cdot 300}{600} = 0.0387; \end{aligned}$$

O último estágio calculado se refere ao transformador B e determina o valor final para o cálculo do vetor de estados para o cenário estudado.

$$\begin{aligned} x_3 &= x_2 + f_3(u_3) = (0.0075 + 0.0455, 0.01125 + 0.0387) + (f_3^1(u_3), f_3^2(u_3)); \\ f_3^1(u_3) &= \frac{(\lambda_3^{(0)} u_3^1) N_3}{N} = \frac{(0.04 \cdot 1.2) \cdot 200}{600} = 0.016; \\ f_3^2(u_3) &= \frac{(\lambda_3^{(1)} u_3^2) N_3}{N} = \frac{(\lambda_3^{(0)} u_3^1 u_3^2) N_3}{N} = \frac{(0.04 \cdot 1.2 \cdot 1.2) \cdot 200}{600} = 0.0192; \\ x^* &= x_3 = (0.0075 + 0.0455 + 0.016, 0.01125 + 0.0387 + 0.0192) = (0.069, 0.06915); \end{aligned}$$

Seguindo a representação da aplicação do método de programação dinâmica, define-se a função de custo elementar $\varphi_k(u_k)$, levando em consideração a função objetivo do problema proposto definida pela Equação (2.4) na Subseção 2.3.4.

$$\varphi_k(u_k) = \sum_{t=1}^T \frac{1}{(1+r)^t} (p_k(u_k^t) + \lambda_k^t c_k), \quad (4.14)$$

onde:

- $p_k(u_k^t)$ é o custo de manutenção preventiva associado ao multiplicador de taxa de falha u_k^t para o equipamento k e período de horizonte de planejamento t ;
- c_k é o custo de manutenção corretiva para o equipamento k ;
- r é a taxa de juros.

Seguindo a estratégia *forward* para o processo de otimização do método de programação dinâmica, a função de custo ótimo acumulado é calculada para cada estado, a cada estágio, como define a seguinte equação:

$$F_{k+1}(x_{k+1}) = \min_{u_1, \dots, u_{k+1}} \left\{ \sum_{j=1}^{k+1} \varphi_j(u_j) \right\}, \quad (4.15)$$

Desta forma, verifica-se que a função de custo ótimo acumulada pode ser descrita através das Equações (4.16) e (4.17).

$$F_{k+1}(x_{k+1}) = \min_{u_{k+1} \in U_{k+1}} \{ \varphi_{k+1}(u_{k+1}) + F_k(x_k) \} \quad (4.16)$$

$$x_k = x_{k+1} - f_{k+1}(u_{k+1}), \quad (4.17)$$

O processo de otimização do método de programação dinâmica termina quando $F_K(x_K)$ é calculado para todos os valores factíveis de x_K . O valor ótimo para a função objetivo descrito na Equação (4.1), $F(x_K^*)$, é obtido através de um processo simples de otimização sobre o último estágio K calculado, como mostra a seguinte equação:

$$F_K(x_K^*) = \min_{x_K} \{ F_K(x_K) \} \quad (4.18)$$

A estratégia de otimização *forward* também é dotada de um processo para identificar o conjunto de ações de manutenção ótimo, $u_k^o(x_k)$, que é utilizado para determinar o planejamento de manutenção ótimo para o problema. Esse processo recursivo para recuperar a política de decisão ótima u^* é iniciado a partir do último estágio K calculado e termina quando o conjunto ótimo de estratégias de manutenção preventiva esteja completo $\{u_k^*, \forall k\}$, como definem as Equações (4.19), (4.20) e (4.21).

$$u_K^* = u_K^o(x_K^*) \quad (4.19)$$

$$x_k^* = x_{k+1}^* - f_{k+1}(u_{k+1}^*) \quad (4.20)$$

$$u_k^* = u_k^o(x_k^*) \quad (4.21)$$

O Pseudocódigo 4.3 descreve o método de programação dinâmica adaptado ao problema de otimização de manutenção preventiva proposto.

Programação Dinâmica PD	
1:	Para $k = 0, \dots, K$ faça
2:	Calcula $x_{k+1} = x_k + f_{k+1}(u_{k+1})$;
3:	Se $(x_{k+1} \leq FEC)$ então
4:	Calcula $F_{k+1}(x_{k+1})$;
5:	Fim Se
6:	Fim Para
7:	Determina $F_K(x_K^*) = \min_{x_K} \{F_K(x_K)\}$;
8:	Para $k = K, \dots, 0$ faça
9:	Calcula $u_k^* = u_k^o(x_k^*)$;
10:	Calcula $x_k^* = x_{k+1}^* - f_{k+1}(u_{k+1}^*)$;
11:	Fim Para
Retorna: $F_K(x_K^*), u_k^*$	

Pseudocódigo 4.3: Programação Dinâmica para o Problema de Manutenção Preventiva

4.4 Comentários Finais

Essencialmente, este capítulo apresentou os principais conceitos do método de programação dinâmica e da aplicação do método de programação dinâmica ao problema de otimização de manutenção preventiva em redes de distribuição de energia elétrica.

Algumas etapas da aplicação do método foram exemplificadas através de um estudo numérico e suas principais características foram comentadas, dentre elas, as estratégias de otimização e as características da formulação matemática do problema de otimização da manutenção.

No capítulo seguinte, é apresentado um estudo de complexidade do método de programação dinâmica em conjunto com a aplicação do problema de manutenção preventiva e o desenvolvimento de uma técnica de redução do espaço de soluções.

Estudo de Complexidade e Técnica de Redução de Soluções Dominadas

5.1 Introdução

Esse capítulo apresenta um estudo de complexidade do método de programação dinâmica aplicado ao problema de otimização da manutenção proposto e uma técnica de redução de soluções dominadas aplicada ao processo de otimização do método de programação dinâmica.

São apresentados também dois exemplos didáticos que ilustram a aplicação do método de programação dinâmica e a técnica de redução de soluções dominadas. Os resultados dos exemplos são analisados de forma sucinta, destacando alternativas de desdobramentos para o método de programação dinâmica.

5.2 Estudo de Complexidade do Método de Programação Dinâmica

Um estudo de complexidade é desenvolvido a partir da aplicação do método de programação dinâmica para o problema de manutenção preventiva em sistemas de distribuição de energia elétrica, apresentado no capítulo anterior.

O problema de otimização de manutenção preventiva foi demonstrado pertencer à classe

NP-difícil (Usberti et al. 2012). Deste modo, a aplicação do método de programação dinâmica a problemas de escala real conduz a um aumento do esforço computacional. Essa dificuldade foi usualmente mencionada como a “maldição da dimensionalidade”(do inglês, “*curse of dimensionality*”) (Bellman 1957).

A proposição a seguir caracteriza a complexidade do método de programação dinâmica aplicado ao problema de otimização de manutenção.

Proposição 5.2.1.

A complexidade do algoritmo de programação dinâmica aplicado ao problema de manutenção preventiva em redes de distribuição de energia elétrica é da ordem de:

$$\Theta(\gamma^{T \cdot K}),$$

onde:

- γ é o número de ações de manutenção preventiva para o problema proposto;
- T é o horizonte de planejamento para o problema proposto;
- K é o número de equipamentos que compõem a rede de distribuição.

Demonstração. Uma representação da complexidade de um algoritmo pode ser dada pelo número de soluções que ele explora ao longo de sua execução. Desta forma, são construídas três tabelas que apresentam uma estimativa para o número de vezes que o cálculo de vetores de estado são executados a cada estágio do processo de otimização do método de programação dinâmica para múltiplos anos de horizonte de planejamento.

T = 1					
Estágio	1	2	3	...	K
N ^o de Estados	2	4	8	...	2 ^K

Tabela 5.1: Número de vetores de estado calculados a cada estágio para um ano de horizonte de planejamento.

Conforme mencionado nos capítulos anteriores, considera-se para o problema de otimização proposto apenas dois tipos de ação de manutenção preventiva (realizar e não realizar manutenção preventiva). Isso caracteriza a base da potência que descreve a estimativa para o número de

vetores de estados, 2^K , para o horizonte de planejamento de um ano. De forma análoga são apresentadas as próximas tabelas referentes aos múltiplos anos de horizonte de planejamento.

T = 2					
Estágio	1	2	3	...	K
Nº de Estados	4	8	64	...	4^K

Tabela 5.2: Número de vetores de estado calculados a cada estágio para dois anos de horizonte de planejamento.

T = 3					
Estágio	1	2	3	...	n
Nº de Estados	8	64	512	...	8^K

Tabela 5.3: Número de vetores de estado calculados a cada estágio para três anos de horizonte de planejamento.

Pode-se notar, nas Tabelas 5.2 e 5.3, que a estimativa cresce exponencialmente de acordo com o aumento do número de anos de horizonte de planejamento. Generalizando, o número de vetores de estado calculados pode ser representado pela fórmula:

$$2^{T*K}$$

Todavia, a fórmula geral que descreve a estimativa de vetores de estado calculados pelo método de programação dinâmica, aplicado ao problema de manutenção preventiva em redes de distribuição de energia elétrica, pode ser escrita da seguinte forma:

$$\gamma^{T*K},$$

onde γ corresponde ao número de ações de manutenção preventiva disponíveis.

Portando, o lema está demonstrado.

□

Esse estudo de complexidade revela que o método de programação dinâmica aplicado ao problema de manutenção é limitado quanto ao estudo de redes de distribuição de escala real.

Por exemplo, para o problema proposto aplicado a uma rede de distribuição composta por 100 equipamentos e otimizada para um planejamento de três anos, a estimativa para o número de vetores de estados calculados pelo método de programação dinâmica é de $2^{3 \cdot 100} = 2^{300}$. Trata-se de um número considerado excessivamente grande, seja qual for a performance do processador. Com base nessa análise de complexidade, um exemplo didático para a aplicação do método de programação dinâmica ao problema de manutenção é elaborado, com a finalidade de ilustrar o aumento exponencial do número de vetores de estados calculados.

5.3 Aplicação do Método de Programação Dinâmica

Nesta seção, é apresentado um exemplo ilustrativo da aplicação do método de programação dinâmica em uma rede de distribuição de energia elétrica fictícia.

Nesse exemplo, estão disponíveis apenas quatro equipamentos caracterizados em seções. A topologia da rede, os valores referentes aos multiplicadores de taxa de falha dos equipamentos e o número de clientes atendidos por cada seção, são definidos a seguir.




Figura 5.1: Rede de referência

Sejam os atributos relacionados às redes de distribuição radial, a topologia representada na Figura 5.1 mostra que a rede de distribuição fictícia atenderá ao total de 100 consumidores. Todos os equipamentos são distintos, sendo que os valores referentes ao custo de manutenção preventiva (CMP), custo de manutenção corretiva (CMC), multiplicadores de taxa de falha referentes a realizar manutenção preventiva (δ_c) e não realizar manutenção preventiva (δ_s), e taxa de falha inicial, estão dispostos na Tabela 5.4.

Descritos os dados referentes à rede de distribuição, o método de programação dinâmica para determinar o planejamento ótimo da manutenção preventiva para o horizonte de planejamento de um ano é aplicado, com respeito à restrição de índice de confiabilidade máximo de 14,9% de probabilidade de falha por ano.

Pelo estudo de complexidade realizado, observa-se que serão $\Theta(2^k)$ vetores de estados calculados a cada estágio k . Como a rede é composta por quatro equipamentos, o número final será

Tipo	CMC*	CMP*	δ_c	δ_s	Taxa de Falha Inicial
Equipamento 1	3.45	2.5	0.9	1.15	0.05
Equipamento 2	4	3	0.8	1.2	0.05
Equipamento 3	2	1.3	0.95	1.05	0.05
Equipamento 4	2.5	1.7	0.85	1.25	0.05
* R\$×1000,00					

Tabela 5.4: Equipamentos - Rede de distribuição fictícia

$2^4 = 16$ vetores de estados calculados.

Todos os valores referentes aos cálculos realizados são apresentados na Figura 5.2. Nota-se através da figura que, a confiabilidade é $FEC = 0.1482$ falha por ano e o custo de manutenção ótimo de R\$ 13.993, 20.

Nesse exemplo, os equipamentos estão casualmente dispostos conforme a topologia da rede de distribuição elaborada. Porém, como já foi mencionado, a topologia da rede de distribuição não possui influência na escolha da ordem de otimização dos equipamentos que compõem o processo de otimização, ou no resultado final obtido.

5.4 Técnica de Redução de Soluções Dominadas

A estratégia da técnica desenvolvida envolve identificar e eliminar soluções consideradas não-promissoras, denominadas soluções dominadas. A técnica, aplicada ao método de programação dinâmica, é inserida no processo de otimização, sendo executada a cada estágio. Assim, procura eliminar estados dominados de acordo com duas regras de avaliação dos valores dos vetores de estados e da função de custo ótimo associada.

Dado um estágio k do processo de otimização do método de programação dinâmica, os vetores de estado x_k e da função de custo ótimo $F_k(x_k)$ são comparados um a um, através de duas regras de avaliação desenvolvidas com base no conhecimento prévio do problema (Bacalhau, Usberti & Lyra 2013).

A primeira regra avalia se os valores de custo de manutenção e índice de confiabilidade do sistema para o estado x'_k são inferiores em relação ao estado x''_k .




Figura 5.2: Diagrama de estados - Trajetória Ótima

- **Regra 1:** Diz-se que x'_k é um estado dominado se existe algum x''_k tal que:

$$F_k(x'_k) > F_k(x''_k) \text{ e} \quad (5.1)$$

$$x'^t_k > x''^t_k, \forall t$$

A partir das características do problema de otimização proposto, onde muitas soluções possuem confiabilidade similares, é formulada a segunda regra. Essa regra avalia se o valor de custo de manutenção é inferior e se os valores dos índices de confiabilidade do sistema são próximos,

dado um parâmetro ρ .

- **Regra 2:** Diz-se que x'_k é um estado dominado se existe algum x''_k tal que:

$$F_k(x'_k) > F_k(x''_k) \text{ e} \quad (5.2)$$

$$\|x'_k - x''_k\| < \rho,$$

onde:

- ρ é o parâmetro usado para caracterizar índices de confiabilidade muito próximos;
- $\|x'_k - x''_k\|$ é a norma quadrática da diferença entre os vetores x'_k e x''_k .

Se o estado é considerado não-promissor para o problema, ele é retirado do processo de otimização do método de programação dinâmica. Desta forma, a técnica pode ser representada através do Pseudocódigo 5.5.

Técnica de Redução de Soluções Dominadas $TRSD(x'_k, x''_k)$

- 1: **Se** ($F_k(x'_k) > F_k(x''_k)$) **então**
 - 2: **Se** ($x'^t_k > x''^t_k, \forall t$) **então**
 - 3: elimina x'_k ;
 - 4: **Senão Se** $\|x'_k - x''_k\| < \rho$ **então**
 - 5: elimina x'_k ;
 - 6: **Fim Se**
 - 7: **Fim Se**
 - 8: **Fim Se**
-
-

Pseudocódigo 5.5: Técnica de Redução de Soluções Dominadas

A inserção da técnica de redução no método de programação dinâmica determina um novo algoritmo, denominado neste trabalho como Programação Dinâmica Modificada (PDmod). Esse novo procedimento é representado pelo Pseudocódigo 5.6.

5.5 Aplicação do Método de Programação Dinâmica Modificado

A aplicação da técnica de redução de soluções ao método de programação dinâmica leva o método de programação dinâmica a perder a garantia de otimalidade da solução final obtida.

Programação Dinâmica Modificada PDmod

- 1: **Para** $k = 0, \dots, K$ **faça**
 - 2: Determine $x_k(u_k)$;
 - 3: Calcule $F_k(x_k)$;
 - 4: $TRSD(x'_k, x''_k) \forall x'_k$;
 - 5: **Fim Para**
 - 6: Determine $F_K(x_K^*)$;
 - 7: **Para** $k = K - 1, \dots, 0$ **faça**
 - 8: Calcule $x_k^* = x_{k+1}^* - f_{k+1}(u_{k+1}^*)$;
 - 9: **Fim Para**
-
-

Pseudocódigo 5.6: Programação Dinâmica Modificada

Essa afirmação é específica para o problema de otimização proposto: uma solução dominada em um estágio pode se tornar, ao longo do processo de otimização do método de programação dinâmica, uma candidata à solução final. Além disso, a afirmação pode ser formalizada matematicamente:

- *Sejam A e B duas soluções. Se A é dita uma solução dominada por B em um estágio k , pode-se afirmar que não é possível garantir que a solução A ainda seja dominada por B no estágio final K .*

Sejam as soluções A e B compostas pela soma dos fatores a_i e b_i , respectivamente, com $i = 1, \dots, k, \dots, K$, onde esses fatores representam os valores iniciais de taxa de falha de cada equipamento. Sejam também δ_s o multiplicador de taxas de falhas associado à ação de manutenção não-programada e δ_c o multiplicador de taxas de falhas associado à ação de manutenção programada.

Supõe-se o seguinte caso especial:

$$\sum_{i=1}^K a_i < \sum_{i=1}^K b_i \text{ dado que,}$$

$$\sum_{i=1}^k a_i < \sum_{i=1}^k b_i \text{ e}$$

$$\sum_{i=k+1}^K a_i > \sum_{i=k+1}^K b_i.$$

Desta forma, multiplicando-se as inequações pelos multiplicadores de taxas de falha, tem-se:

$$\delta_c \left(\sum_{i=1}^k a_i \right) < \delta_c \left(\sum_{i=1}^k b_i \right) \text{ e}$$

$$\delta_s \left(\sum_{i=k+1}^K a_i \right) > \delta_s \left(\sum_{i=k+1}^K b_i \right)$$

É suficiente mostrar que a inequação seguinte é válida para algum caso específico.

$$\delta_c \left(\sum_{i=1}^k a_i \right) + \delta_s \left(\sum_{i=k+1}^K a_i \right) > \delta_c \left(\sum_{i=1}^k b_i \right) + \delta_s \left(\sum_{i=k+1}^K b_i \right)$$

Rearranjando a inequação, tem-se que

$$\delta_c \left(\sum_{i=1}^k (a_i - b_i) \right) + \delta_s \left(\sum_{i=k+1}^K (a_i - b_i) \right) > 0 \text{ e}$$

$$\delta_s \left(\sum_{i=k+1}^K (a_i - b_i) \right) > \delta_c \left(\sum_{i=1}^k (b_i - a_i) \right).$$

Dadas as informação descritas no caso especial, é possível afirmar que

$$\sum_{i=k+1}^K (a_i - b_i) > 0 \text{ e } \sum_{i=1}^k (b_i - a_i) > 0$$

e ainda que,

$$\sum_{i=k+1}^K (a_i - b_i) < \sum_{i=1}^k (b_i - a_i).$$

Portanto, através da inequação seguinte, o lema é demonstrado.

$$\frac{\sum_{i=k+1}^K (a_i - b_i)}{\sum_{i=1}^k (b_i - a_i)} > \frac{\delta_c}{\delta_s},$$

Como $\delta_s \in [1, 2]$ e $\delta_c \in [0, 1]$, dada as características dos multiplicadores de taxa de falha, o fator à direita da inequação será um número positivo menor do que 1. De forma análoga, como $\sum_{i=k+1}^K (a_i - b_i) < \sum_{i=1}^k (b_i - a_i)$ o fator à esquerda da inequação também

será um número positivo menor do que 1. Por esta razão, conclui-se que é possível afirmar que existirá um caso específico em que a inequação final é válida, o que caracteriza um exemplo concreto para a perda de otimalidade da aplicação da técnica de redução de soluções dominadas ao método de programação dinâmica.

A partir disso, um exemplo de aplicação da técnica de redução de soluções dominadas no método de programação dinâmica é elaborado. Esse exemplo busca representar o caso especial descrito na demonstração.

Exemplo Prático

Para o problema de otimização de manutenção preventiva, é aplicado o método de programação dinâmica modificado na mesma rede de distribuição fictícia utilizada no exemplo ilustrativo elaborado na Seção 5.3. Porém, a estratégia da técnica proposta exige que um novo parâmetro $\rho = 0.004$ seja indicado.

A Figura 5.3 mostra a solução final obtida após a aplicação do método de programação dinâmica modificado, com o valor de custo calculado em R\$ 14.481,80. Essa solução é sub-ótima, dado que a solução ótima global foi eliminada pela técnica de redução de soluções dominadas.

Apesar da solução não ser o ótimo global, o número de soluções calculadas pelo método foi muito reduzido, o que auxilia a aplicação do problema de otimização de manutenção preventiva a redes de distribuição de escala real, com múltiplos horizontes de planejamento.

Através do estudo publicado em Bacalhau, Usberti & Lyra (2013), verificou-se que a técnica de reduções de soluções dominadas aplicada ao método de programação dinâmica mostrou bom desempenho em relação ao custo de manutenção para um estudo com redes fictícias de médio porte. Porém, os tempos computacionais obtidos foram elevados, o que levou à investigação de novas alternativas de hibridizações e aproximações para o método de programação dinâmica – quase sempre as aplicações de programação dinâmica em problemas reais requerem alternativas de aproximações (Heidari et al. 1971, Sniedovich 2011, Powell 2011).

5.6 Comentários Finais

O capítulo apresentou um estudo de complexidade do método de programação dinâmica e um exemplo ilustrativo da aplicação do método ao problema de manutenção preventiva em redes de distribuição de energia elétrica. Baseado no estudo de complexidade discutido, uma técnica de redução de soluções dominadas é proposta e aplicada ao mesmo exemplo ilustrativo elaborado.




Figura 5.3: Diagrama de estados - Trajetória Final

Uma análise resumida dos exemplos práticos destacou a redução do número de soluções e os benefícios da aplicação da técnica de redução de soluções dominadas ao problema de otimização da manutenção. Pesquisas previamente desenvolvidas e perspectivas de desdobramentos para a aplicação do problema de otimização foram mencionadas. As alternativas de aproximações para o método de programação dinâmica podem ser vistas no desenvolvimento do método de Programação Dinâmica com Reduções de Espaço de Estados, apresentado no próximo capítulo.

Programação Dinâmica com Reduções de Espaço de Estados

6.1 Introdução

O capítulo apresenta a metodologia de Programação Dinâmica com Reduções de Espaço de Estados (PDREE), que consiste na combinação de duas técnicas de redução de espaço de estados. A Técnica de Redução de Soluções Dominadas, apresentada no capítulo anterior, e a técnica que envolve o conceito de Programação Dinâmica Diferencial Discreta (PDDD).

A metodologia de PDREE é aplicada ao problema de otimização de manutenção em sistemas de distribuição de energia elétrica e discutida nas seções seguintes. São apresentados os conceitos da metodologia e um resumo sobre os passos que definem a abordagem por PDREE e, em seguida, comentários sobre o desenvolvimento dos algoritmos.

6.2 Programação Dinâmica com Reduções de Espaço de Estados

A metodologia de Programação Dinâmica com Reduções de Espaço de Estados (PDREE) utiliza de forma coordenada duas técnicas de reduções de espaço de estados. Uma descreve o conceito do método de Programação Dinâmica Diferencial Discreta (PDDD), inicialmente

proposto por Heidari et al. (1971). A outra é a Técnica de Redução de Soluções Dominadas (TRSD), apresentada no capítulo anterior.

6.2.1 Programação Dinâmica Diferencial Discreta

A estratégia PDDD realiza um processo de otimização por programação dinâmica em torno de uma região de busca composta por boas trajetórias de referência caracterizadas pela função objetivo determinada, que se movem iterativamente nos espaços de estados. Alguns trabalhos recentes referenciam o método por outra denominação, tal como “Método do Corredor” (Sniedovich 2011). Neste trabalho, o “corredor” será denominado “túnel”.

Para a definição dos conceitos, admite-se que a função recursiva de otimalidade em conjunto com a equação de transição de estados, definidas no método de programação dinâmica, são também definidas para o processo de otimização do método PDDD.

Trajetória de Referência

Para a construção de uma trajetória de referência, define-se uma sequência de vetores de controle, $\hat{u}_k$ com $k = 1, \dots, K$, designada como uma política de referência, que satisfaz as condições de factibilidade do problema. A sequência determina a trajetória de referência, $\hat{x}_k$, com $k = 1, \dots, K$. Para sistemas inversíveis, é possível determinar uma política de referência $\hat{u}_k$, a partir de uma trajetória de referência $\hat{x}_k$, como mostra a seguinte equação:

$$u_k = f^{-1}(x_k, x_{k+1}) \quad (6.1)$$

A partir da trajetória de referência, pode-se determinar o valor da função de custo ótimo pelo cálculo da função recursiva de otimalidade. A Equação 6.2 mostra a função recursiva de otimalidade para o método PDDD.

$$F_k(\hat{x}_k) = \min_{\hat{u}_k} \{ \varphi_k(\hat{x}_k, \hat{u}_k) + F_{k+1}(\hat{x}_{k+1}) \}, \quad (6.2)$$

$F_k(\hat{x}_k)$ retorna o valor de custo ótimo para o vetor de estado $\hat{x}_k$ do estágio k da trajetória de referência assumida.

Construção do Túnel

Após tomar uma trajetória de referência, é necessário definir um conjunto de incrementos $\Omega(x_k)$ para vetores de estado $\hat{x}_k$ calculados para o vetor de controle $\hat{u}_k$. Esses valores envolvem a criação de um espaço de busca para a aplicação do processo de otimização do método de

programação dinâmica. Esse espaço caracteriza a ideia de construção de uma espécie de túnel em torno da trajetória de referência (Lyra & Ferreira 1995). Os valores são definidos da seguinte forma:

$$\Omega_i(x_k) = \begin{bmatrix} \omega_i(x_k^1) \\ \omega_i(x_k^2) \\ \vdots \\ \omega_i(x_k^j) \\ \vdots \\ \omega_i(x_k^m) \end{bmatrix}, \quad \begin{matrix} k = 1, \dots, K \\ i = 1, \dots, N^m \end{matrix} \quad (6.3)$$

Sendo que, a j -ésima componente $\omega_i(x_k^j)$, $j = 1, \dots, m$, assume um valor σ_l , $l = 1, \dots, N$, definido como um conjunto de valores incrementais que podem ser adicionados aos vetores de estado. Deste modo, o número total de vetores $\Omega_i(x_k)$ para cada estágio k é N^m .

Representa-se o túnel em torno da trajetória de referência, onde a largura será dada pela soma dos componentes incrementais aos valores de estados $\hat{x}_k$, como mostra a Equação 6.4.

$$\hat{x}_k + \Omega_i(x_k), \quad i = 1, \dots, N^m \quad (6.4)$$

Uma vez somados os valores incrementais, obtém-se um novo subdomínio denominado D_k :

$$D_k = \overline{D} \cap X \quad (6.5)$$

onde:

- $\overline{D} = \hat{x}_k + \Omega_i(x_k)$, $i = 1, \dots, N^m$;
- X é o conjunto de todos os estados possíveis.

A Figura 6.1 ilustra um subdomínio D_k no estágio k , com $m = 2$, $N = 4$ e vetor de estados bi-dimensional $x_k = \{x_k^1, x_k^2\}$.

O subdomínio D_k é composto por 16 pontos na vizinhança de $\hat{x}_k$, onde $\sigma_1 = 2$, $\sigma_2 = 1$, $\sigma_3 = 0$ e $\sigma_4 = -1$.

O túnel C pode ser definido como a união de todos os subdomínios D_k , com $k = 1, \dots, K$. A Figura 6.2 exemplifica a construção do túnel em torno da trajetória de referência calculada para um sistema com vetor de estado x_k unidimensional, $m = 1$, $N = 3$ e $K = 6$ (Heidari et al. 1971).




Figura 6.1: Exemplo de subdomínio no estágio k .




Figura 6.2: Diagrama de estados para a metodologia de PDREE

Processo de Otimização do Método PDDD

O método de programação dinâmica procura uma nova trajetória, denominada trajetória nominal, dentro dos limites determinados pelos valores de largura do túnel. Se o valor de função de custo ótimo da trajetória nominal for melhor do que o valor da função de custo ótimo dada pela trajetória de referência, a trajetória nominal é definida como a trajetória de referência para

a próxima iteração. O processo de otimização do método PDDD, pode ser formalizado nos seguintes passos:

1. Define-se a trajetória de referência $\hat{x}_k$;
2. Constrói-se o túnel C ;
3. Usa-se a função recursiva de otimalidade (6.2) para minimizar a função de custo ótimo restrito aos limites do túnel;
4. Compara-se o valor da função de custo ótimo da trajetória nominal $F'_K(\hat{x}'_K)$, com o valor da função de custo ótimo da trajetória de referência $F_K(\hat{x}_K)$ da iteração anterior. Se $F'_K(\hat{x}'_K) < F_K(\hat{x}_K)$, então

$$\hat{x}_k \leftarrow \hat{x}'_k,$$

$$F_K(\hat{x}_K) \leftarrow F'_K(\hat{x}'_K)$$

e volta-se ao passo 2, caso contrário, termina-se o processo de otimização.

A largura definida para o túnel pode variar ao longo do processo de otimização do método. Podem ser escolhidos diferentes valores de $[\sigma_l]_{it}$, $l = 1, \dots, N$ no passo 2, como mostram os exemplos ilustrados anteriormente.

6.2.2 Caracterização da Metodologia de PDREE

A metodologia de PDREE é composta por duas estratégias de redução do espaço de busca. A estratégia que define a estrutura da metodologia, o método de PDDD e a técnica TRSD. A técnica é aplicada ao método de programação dinâmica, caracterizado pelo desenvolvimento do algoritmo de Programação Dinâmica Modificado (PDmod) representado pelo Pseudocódigo 5.6 do capítulo anterior. Desta forma, a metodologia de PDREE pode ser representada pelo Pseudocódigo 6.1.

6.3 Abordagem por PDREE Aplicado ao Problema de Otimização de Manutenção Preventiva em Sistemas de Distribuição de Energia Elétrica

A aplicação da metodologia de PDREE ao problema de otimização de manutenção preventiva em sistemas de distribuição de energia elétrica, uma das principais contribuições deste trabalho, pode ser formalizada nas seções seguintes.

PDREE

- 1: Determina-se a $\hat{x}_k$;
 - 2: **Repita**
 - 3: Constrói-se o túnel C ;
 - 4: $\hat{x}'_k \leftarrow \text{PDmod}$;
 - 5: **Se** ($F'_K(\hat{x}'_K) < F_K(\hat{x}_K)$) **então**
 - 6: $\hat{x}_k \leftarrow \hat{x}'_k \forall k$;
 - 7: **Fim Se**
 - 8: **Até que** (nenhuma trajetória nominal melhor seja obtida)
-
-

Pseudocódigo 6.1: Metodologia de PDREE

6.3.1 Construção da Trajetória de Referência

A abordagem por PDREE é dotada de Heurística Construtiva (HC) que procura de forma gulosa determinar uma boa trajetória de referência, $\hat{x}_k$ com $k = 1, \dots, K$ para a aplicação do método PDDD. A heurística consiste em criar uma lista de medidas de investimentos através dos multiplicadores de taxas de falha $u_k^t \in U_k$ referente a todos os equipamentos k e períodos t que compõe a rede de distribuição, baseado em uma função de custo-benefício dada pela equação:

$$CB(u_k^t) = \frac{\lambda_k^{t-1}(\dot{u}_k^t - u_k^t)N_s}{p_k(u_k^t)\exp(t)}, \quad (6.6)$$

onde:

- λ_k^{t-1} é a taxa de falha para o período anterior $t-1$ para o equipamento k , sendo denominado taxa de falha inicial quando $t = 1$;
- $\dot{u}_k^t$ é o multiplicador de taxa de falha para o equipamento k para o período de horizonte de planejamento t associado à ação de não realizar manutenção preventiva. Nota-se que esse será o maior valor dentre os multiplicadores;
- u_k^t é o multiplicador de taxa de falha para o equipamento k para o período de horizonte de planejamento t ;
- N_s é o número de consumidores que o equipamento k atende, referente à seção s e as seções à jusante de s ;

- $p_k(u_k^t)$ é o custo da manutenção preventiva associado ao multiplicador de taxa de falha para o equipamento k no período de horizonte de planejamento t ;
- $exp(t)$ é um valor determinado empiricamente, o qual se refere ao período de horizonte de planejamento t .

Os valores de medidas de investimentos calculados são ordenados e uma solução é construída conforme uma heurística construtiva descrita no Pseudocódigo 6.2 (Bacalhau, Filho & Cavellucci 2009):

Heurística Construtiva HC

- 1: Calcula-se e ordena-se $CB(u_k^t)$;
- 2: Constrói-se $\hat{x}_k$ associado ao $\max\{CB(u_k^t)\}$;
- 3: **Enquanto** $\hat{x}_k$ não é factível **faça**
- 4: $\max\{CB(u_k^t)\} \leftarrow []$;
- 5: Constrói-se $\hat{x}_k$ associado ao novo $\max\{CB(u_k^t)\}$;
- 6: **Fim Enquanto**

Retorna: $\hat{x}_k$

Pseudocódigo 6.2: Heurística construtiva

No primeiro passo, são calculadas todas as medidas de investimento $CB(u_k^t)$ e ordenadas. No segundo passo, determina-se uma trajetória de referência ($\hat{x}_k$) baseada no máximo investimento escolhido $\max\{CB(u_k^t)\}$: o equipamento k de período t é associado ao multiplicador de taxa de falha (u_k^t), enquanto todos os outros equipamentos que compõem a rede de distribuição são associados à ação de manutenção programada (u_k^t). No terceiro até o sexto passo, testa-se a factibilidade de ($\hat{x}_k$). Se ($\hat{x}_k$) não é factível, a segunda maior medida de investimento associada a um outro equipamento k no período t é selecionada, sendo determinada uma nova trajetória de referência $\hat{x}_k$, associando aos equipamentos já analisados a ação de manutenção (u_k^t). A heurística construtiva continua até que uma trajetória de referência factível seja encontrada.

6.3.2 PDDD Aplicada ao Problema de Otimização de Manutenção Preventiva em sistemas de Distribuição de Energia Elétrica

Construção do Túnel

Uma vez encontrada uma trajetória de referência $\{\hat{x}_k, k = 0, \dots, K\}$, o túnel que caracteriza a região do espaço de busca para o processo de otimização do método de programação dinâmica é

construído. A largura do túnel é dada pela intersecção dos valores incrementais com os possíveis valores de estados $\Omega(\hat{x}_k) \cap X_k$, como mostrou a Equação (6.5). A Equação 6.7 formaliza o cálculo dos valores incrementais para a aplicação da metodologia de PDREE ao problema de otimização de manutenção preventiva.

$$\Omega(\hat{x}_k) = \begin{pmatrix} \hat{x}_k^1 + \sigma_k^1 \\ \hat{x}_k^2 + \sigma_k^2 \\ \vdots \\ \hat{x}_k^t + \sigma_k^t \\ \vdots \\ \hat{x}_k^T + \sigma_k^T \end{pmatrix} \quad (6.7)$$

onde σ_k^t é um valor de incremento positivo ou negativo com limitantes superiores $\overline{\sigma}_k$ e inferiores $\underline{\sigma}_k$,

$$\underline{\sigma}_k \leq \sigma_k^t \leq \overline{\sigma}_k, \forall t \quad (6.8)$$

E pode assumir valores associados ao cálculo do índice de confiabilidade FEC, como mostra a Equação 6.9.

$$\sigma_k^t = \begin{cases} 0 & \text{se ultrapassa os limitantes superiores ou inferiores} \\ f_k^t(u_k) & \text{caso contrário.} \end{cases} \quad (6.9)$$

Os valores incrementais são acumulados ao longo dos estágios calculados. Por isso, um novo parâmetro β é inserido a partir de estudos empíricos, cuja função é controlar o excesso de abertura do túnel.

$$\hat{x}_k + (\Omega(\hat{x}_k) \times \beta),$$

onde:

- $\beta \in [0, 1]$.

Sendo assim, a construção do túnel pode ser representada pelo Pseudocódigo 6.3.

Construção do Túnel *Tunnel*

```

1: Para  $k = 0, \dots, K$  faça
2:   Determina-se  $\Omega(\hat{x}_k)$ ;
3:   Calcula-se  $C \leftarrow \hat{x}_k + (\Omega(\hat{x}_k) \times \beta)$ ;
4: Fim Para
Retorna:  $C$ 

```

Pseudocódigo 6.3: Construção do túnel

6.3.3 Caracterização da Abordagem por PDREE

O processo de otimização da abordagem por PDREE é constituído por uma nova leitura do processo de otimização do método de PDDD em conjunto com a técnica de redução de soluções dominadas, proposta no capítulo anterior (Bacalhau, Usberti & Lyra 2013).

O processo de otimização da abordagem por PDREE pode ser resumido nos seguintes passos:

1. Obtém-se uma boa trajetória de referência $\hat{x}_k$ através do algoritmo representado no Pseudocódigo 6.2;
2. Determina-se o parâmetro β ;
3. Constrói-se o túnel $\hat{x}_k + (\Omega(\hat{x}_k) \times \beta)$, o qual representa a região do espaço de busca $\Omega(\hat{x}_k) \cap X_k$ para o processo de otimização do método de programação dinâmica, através do algoritmo representado no Pseudocódigo 6.3;
4. Usa-se a função recursiva de otimalidade (6.2) para minimizar a função de custo ótimo restrito aos limites do túnel;
5. Executa-se o processo de otimização do método de programação dinâmica modificado, para a obtenção da trajetória nominal $(\hat{x}'_k)$, através do algoritmo representado no Pseudocódigo 5.6.
6. Compara-se o valor da função de custo ótimo da trajetória nominal $F'_K(\hat{x}'_K)$, com o valor da função de custo ótimo da trajetória de referência $F_K(\hat{x}_K)$ da iteração anterior. Se $F'_K(\hat{x}'_K) < F_K(\hat{x}_K)$,

$$\hat{x}_k \leftarrow \hat{x}'_k, \forall k,$$

$$F(\hat{x}_K^*) \leftarrow F_K(\hat{x}_K),$$

o túnel sofre um estreitamento, com o decréscimo do parâmetro β ,

$$\beta \leftarrow \beta \cdot \tau,$$

$$0 < \tau < 1,$$

e volta-se ao passo 3. Caso contrário, termina-se o processo de otimização.

O processo de otimização da abordagem por PDREE é também representado pelo Pseudo-código 6.4.

PDREE

- 1: $\hat{x}_k \leftarrow HC$;
 - 2: Determina-se β ;
 - 3: **Repita**
 - 4: $\hat{x}_k + (\Omega(\hat{x}_k) \times \beta) \leftarrow Tunnel$;
 - 5: $\hat{x}_k \leftarrow PDmod$;
 - 6: **Se** $(F'_K(\hat{x}'_K) < F_K(\hat{x}_K))$ **então**
 - 7: $\hat{x}_k \leftarrow \hat{x}'_k \forall k$;
 - 8: **Fim Se**
 - 9: **Até que** (nenhuma trajetória nominal melhor seja obtida)
-
-

Pseudocódigo 6.4: Abordagem por PDREE

6.3.4 Comentários sobre a Abordagem por PDREE

A heurística construtiva desenvolvida tem como objetivo obter uma boa trajetória de referência de tal forma que o processo do método possa convergir para uma boa solução final.

O afunilamento do túnel, dado pelo parâmetro τ , se faz necessário uma vez que a função que define os valores de vetor de estados é suave quando se aproxima de um ótimo local, e assim existirão poucas soluções promissoras no espaço de soluções. A estratégia reduz o número de trajetórias, tornando a busca mais rápida ao longo das iterações.

Com base em alguns resultados preliminares (Bacalhau, Usberti & Cavellucci 2013), os processos de heurística construtiva e construção do túnel possuem um papel fundamental na obtenção de boas soluções para o problema de otimização de manutenção proposto. Por isso, novas ideias de investigações para a obtenção da trajetória de referência e construção do túnel são exploradas. Uma delas é a utilização da abordagem por algoritmo genético híbrido (AGH)

desenvolvida por Reis (2007) como alternativa para a determinação da trajetória de referência da abordagem por PDREE. Assim, duas novas abordagens híbridas, compostas pela combinação dessa abordagem por algoritmo genético híbrido e pela abordagem por PDREE, são propostas.

6.4 Comentários Finais

Este capítulo apresentou uma nova metodologia sobre as ideias do método de programação dinâmica, denominada Programação Dinâmica com Reduções de Espaço de Estados (PDREE). O desenvolvimento dessa metodologia teve como objetivo reduzir o espaço de busca por soluções para viabilizar a aplicação do problema de otimização da manutenção a redes de distribuição de escala real.

A metodologia de PDREE aplicada ao problema de otimização de manutenção preventiva em redes de distribuição de energia elétrica através do desenvolvimento da abordagem por PDREE também é apresentada. No desenvolvimento da abordagem por PDREE, foram destacados a heurística construtiva para obtenção de uma trajetória de referência e o processo de construção do túnel.

Comentários adicionais sobre a abordagem desenvolvida foram discutidos, apontando para aspectos da estratégia envolvida e para as investigações complementares que inspiraram o desenvolvimento de duas novas abordagens híbridas apresentadas no próximo capítulo.

Abordagens Híbridas Aplicadas ao Problema de Manutenção Preventiva em Redes de Distribuição

7.1 Introdução

O capítulo apresenta duas abordagens híbridas que exploram a combinação da abordagem por programação dinâmica com reduções de espaço de estados (PDREE) apresentado no capítulo anterior, com uma abordagem por algoritmo genético híbrido (AGH) desenvolvido por Reis (2007), apresentado no Capítulo 3.

Nas seções seguintes, são apresentadas a estrutura dos algoritmos híbridos e uma análise das principais ideias que envolvem a construção dos algoritmos. Além disso, pseudocódigos e fluxogramas são construídos com a finalidade de facilitar a compreensão dos conceitos.

7.2 Abordagem Híbrida 1

O Algoritmo Genético Híbrido (AGH) desenvolvido por Reis (2007) é aplicado à abordagem por Programação Dinâmica com Reduções de Espaço de Estados proposta neste trabalho. A estratégia de abordagem híbrida 1 (AH1) consiste em executar a abordagem por AGH como a heurística construtiva para a obtenção de boas trajetórias de referência, que serão posteriormente otimizadas na abordagem por PDREE.

O objetivo dessa nova abordagem é determinar boas políticas iniciais para a aplicação do processo de otimização da abordagem por PDREE, buscando melhorar os resultados finais obtidos. O processo de otimização do algoritmo genético híbrido por muitas vezes requer um processo custoso, produzindo um aumento considerável no tempo computacional requerido pela abordagem híbrida. Para evitar o aumento excessivo do tempo computacional, são redefinidos os critérios de parada para o algoritmo genético híbrido. Dentre esses critérios, são reduzidos o número máximo de iterações (gerações) e o número de indivíduos na população inicial de soluções.

O algoritmo que formaliza a estrutura da AH1 pode ser ilustrado pelo Pseudocódigo 7.1.

AH1

```

1:  $\hat{x}_k \leftarrow AGH$ ;
2: Determina-se  $\beta$ ;
3: Repita
4:    $C \leftarrow Tunnel$ ;
5:    $\hat{x}_k \leftarrow PDmod$ ;
6:   Se ( $F'_K(\hat{x}'_K) < F_K(\hat{x}_K)$ ) então
7:      $\hat{x}_k \leftarrow \hat{x}'_k \forall k$ ;
8:   Fim Se
9: Até que (nenhuma trajetória nominal melhor seja obtida)

```

Pseudocódigo 7.1: Abordagem Híbrida 1

O pseudocódigo pouco difere do algoritmo da abordagem por PDREE já apresentada. A diferença é a aplicação do AGH para gerar a trajetória de referência $\hat{x}_k$, que será utilizada para o processo de construção do túnel e, posteriormente, no processo de otimização do método de programação dinâmica modificado. Além do pseudocódigo, também é apresentado o Fluxograma 7.1 ilustrando a estrutura do algoritmo.

7.3 Comentários sobre a Abordagem AH1

A estratégia desenvolvida para a abordagem AH1 tem o intuito de buscar uma solução final com melhor qualidade de valor de custo de manutenção. O procedimento aleatório presente no algoritmo genético híbrido é vantajoso no sentido de diversificação do espaço de busca dado pela trajetória de referência obtida.

O aumento do recurso computacional requerido é uma das desvantagens apresentadas pela




Figura 7.1: Fluxograma da Abordagem Híbrida 1

abordagem desenvolvida. Porém, é possível ajustar os parâmetros do algoritmo genético para atenuar essa dificuldade.

7.4 Abordagem Híbrida 2

A abordagem híbrida 2 (AH2) explora a aplicação da abordagem por PDREE como uma espécie de busca local para aperfeiçoar alguns indivíduos que compõem a população inicial do AGH. A estratégia consiste em utilizar o processo de otimização da abordagem por PDREE para melhorar (evoluir) indivíduos da população, determinando uma rápida convergência para melhores soluções finais encontradas pelo AGH.

Nota-se que o risco da população do AGH perder diversidade é muito grande, conduzindo o algoritmo a uma solução sub-ótima. Por isso, são definidas algumas medidas de controle para a

aplicação da abordagem por PDREE. A primeira medida consiste em aplicar a abordagem por PDREE apenas em uma pequena parte da população inicial. A outra medida é a redefinição dos parâmetros que compõem a abordagem por PDREE. Os parâmetros β e τ que controlam a largura do túnel e o afunilamento do túnel, respectivamente, serão mais rígidos, determinando um espaço de busca por soluções reduzido. A finalidade dessas medidas de controle é diminuir o tempo de execução da abordagem AH2 e evitar a convergência prematura.

O Pseudocódigo 7.2 ilustra a estratégia da abordagem desenvolvida.

AH2

```

1:   $t \leftarrow 0$ ;
2:  inicializa-se  $P(t)$ ;
3:  avalia-se  $P(t)$ ;
3:   $P \leftarrow PDREEmod \forall P_s$ ;
4:  enquanto não atingir a condição de parada faça
5:     $t \leftarrow t + 1$ ;
6:    seleciona-se  $P(t)$  de  $P(t - 1)$ ;
7:    realiza-se cruzamentos entre os indivíduos selecionados de  $P(t)$ ;
8:    realiza-se mutações em indivíduos de  $P(t)$ ;
9:     $P(t) \leftarrow BL(P(t))$ ;
10:   avaliar  $P(t)$ ;
11:  fim enquanto
Retorna: (melhor indivíduo)

```

Pseudocódigo 7.2: Abordagem Híbrida 2

A abordagem por PDREE presente no Pseudocódigo 7.2, denominada PDREEmod, possui diferenças quanto à estrutura de processamento apresentado pelo Pseudocódigo 6.4 do capítulo anterior. O algoritmo PDREEmod não precisa de uma heurística construtiva para a obtenção da trajetória de referência, uma vez que ela é determinada pelos indivíduos que compõem o conjunto de indivíduos selecionados, P_s , para participar do processo de otimização da abordagem por PDREE, que retorna um novo indivíduo P potencialmente aperfeiçoado. O algoritmo modificado é ilustrado pelo Pseudocódigo 7.3.

O Fluxograma 7.2 define os passos descritos nos Pseudocódigos 7.2 e 7.3.

PDREEmod

- 1: Determina-se β ;
 - 2: **Repita**
 - 3: $C \leftarrow Tunnel$;
 - 4: $P \leftarrow PDmod$;
 - 5: **Se** ($F'_K(P') < F_K(P)$) **então**
 - 6: $P \leftarrow P'$;
 - 7: **Fim Se**
 - 8: **Até que** (nenhuma trajetória nominal melhor seja obtida)
-
-

Pseudocódigo 7.3: Abordagem por PDREE modificado

7.5 Comentários sobre a Abordagem AH2

O número de indivíduos que passarão pelo processo de otimização da abordagem por PDREE está diretamente relacionado com o tempo computacional requerido. Quanto maior o conjunto P_s , maior será o tempo computacional final.

Os novos parâmetros definidos para a abordagem por PDREEmod são determinantes para a qualidade das soluções finais. Para um melhor desempenho da abordagem, tornam-se necessários estudos empíricos para cada cenário estudado.

7.6 Comentários Finais

O capítulo apresentou o desenvolvimento de duas abordagens híbridas que combinam a abordagem por programação dinâmica com reduções de espaço de estados e uma abordagem por algoritmo genético híbrido previamente desenvolvida.

As abordagens híbridas foram representadas via pseudocódigos e fluxogramas. Além disso, comentários adicionais sobre as abordagens foram discutidos, destacando as vantagens e desvantagens de cada uma.

O próximo capítulo apresenta um estudo de casos envolvendo a abordagem por PDREE, as abordagens híbridas, AH1 e AH2, e a abordagem por AGH, para diversos cenários simulados em redes de distribuição de escala real.




Figura 7.2: Fluxograma da Abordagem Híbrida 2

Estudo de Casos

8.1 Introdução

Este capítulo apresenta um estudo comparativo de desempenhos entre as abordagens desenvolvidas, PDREE, AH1 e AH2, e a abordagem por algoritmo genético híbrido desenvolvido por Reis (2007). As abordagens são aplicadas ao problema de manutenção preventiva em redes de distribuição de energia elétrica de escala real.

O estudo de casos é dividido em três experimentos distintos, que simulam as abordagens desenvolvidas para vários cenários de restrição de confiabilidade do sistema e múltiplos anos de horizonte de planejamento. O estudo de casos com o método de programação dinâmica tradicional não é realizado devido à explosão combinatorial que inviabiliza a solução de problemas de porte real.

São apresentados também os parâmetros definidos para cada uma das abordagens discutidas e os valores referentes a topologia e equipamentos que compõem cada uma das redes de distribuição. Os resultados obtidos são ilustrados em tabelas e gráficos, sendo que análises comparativas são conduzidas para discutir os cenários simulados.

8.2 Redes de Distribuição Radial

Três simulações computacionais redes de distribuição de energia elétrica são exploradas nesse estudo de casos. São compostas por números de equipamentos, consumidores e topologia diferentes, representando três municípios do estado de São Paulo, Brasil.

A topologia segue os princípios apresentados na Seção 2.3.1. Ou seja, existem equipamentos de proteção, chave-fusíveis e religadores, que determinam as fronteiras das seções da rede de distribuição radial. Existem também as seções de redes primárias e as seções de redes secundárias, distinguidas pelos transformadores. As seções aqui são representadas como um componente sujeito à manutenção, mais especificamente, refere-se às podas de vegetação das áreas que as seções abrangem (Radmer, Kuntz, Christie, Venkata & Fletcher 2002).

As três redes de distribuição simuladas apresentam as seguintes características:

- **Rede de distribuição 1**

A rede de distribuição 1 abrange uma população de aproximadamente 41.000 habitantes. Representa a menor instância explorada e é composta por:

- 782 equipamentos;
- 18268 consumidores;
- Quatro tipos de equipamentos: chave-fusível, transformador, religador e seção (poda de árvores).

- **Rede de distribuição 2**

A rede de distribuição abrange uma população de aproximadamente 33.000 habitantes. É considerada a instância de porte médio e é composta por:

- 1855 equipamentos;
- 14178 consumidores;
- Quatro tipos de equipamentos: chave-fusível, transformador, religador e seção (poda de árvores).

- **Rede de distribuição 3**

A rede de distribuição uma população aproximada de 288.401 habitantes. É considerada a rede de grande porte do estudo e é composta por:

- 1976 equipamentos;
- 66266 consumidores;

- Quatro tipos de equipamentos: chave-fusível, transformador, religador e seção (poda de árvores).

Cabe ressaltar que as topologias das redes de distribuição citadas e o número de clientes que cada seção abrange não são apresentados, dada a extensão das redes de distribuição.

8.3 Dados dos Equipamentos

Para as redes de distribuição 1, 2 e 3, os valores referentes aos custos de manutenção preventiva (CMP), custo de manutenção corretiva (CMC), multiplicadores de taxa de falha associados à ação de não realizar manutenção preventiva (δ_c), multiplicadores de taxa de falha associados à ação de não realizar manutenção preventiva (δ_s) e a quantidade de cada tipo de equipamento (Qtde), são apresentados nas Tabelas 8.1, 8.2 e 8.3, respectivamente.

Rede de distribuição 1						
Tipo	CMC*	CMP*	δ_c	δ_s	Qtde	
Seção	2.05	1.025	0.95	1.51	151	
Chave Fusível	3.7	1.2	0.91	1.28	146	
Religador	1.2	0.6	0.91	1.28	4	
Transformador	1.692	0.846	0.95	1.51	481	
* em Reais (R\$ $\times$ 1000)						

Tabela 8.1: Equipamentos

A Rede de distribuição 1 e a Rede de distribuição 2 são compostas por quatro tipos de equipamentos, com os mesmos valores descritos nas tabelas, sendo diferenciadas pelo número de equipamentos que as compõem.

A Rede de distribuição 3 apresenta valores distintos para os custos de manutenção preventiva e corretiva para o equipamento do tipo seção, e para o número de equipamentos.

8.4 Experimentos

O objetivo dos experimentos é produzir uma discussão sobre o desempenho das abordagens propostas aplicadas ao problema de manutenção de redes de distribuição de energia elétrica de escala real.

Rede de distribuição 2						
Tipo	CMC	CMP	δ_c	δ_s	Qtde	
Seção	2.05	1.025	0.95	1.51	481	
Chave Fusível	3.7	1.2	0.91	1.28	473	
Religador	1.2	0.6	0.91	1.28	7	
Transformador	1.692	0.846	0.95	1.51	894	

Tabela 8.2: Equipamentos

Rede de distribuição 3						
Tipo	CMC	CMP	δ_c	δ_s	Qtde	
Seção	1.05	0.525	0.95	1.51	265	
Chave Fusível	3.7	1.2	0.91	1.28	258	
Religador	1.2	0.6	0.91	1.28	6	
Transformador	1.692	0.846	0.95	1.51	1447	

Tabela 8.3: Equipamentos

Os experimentos simulam diferentes cenários de confiabilidade para múltiplos períodos de horizonte do planejamento.

8.4.1 Restrições de Confiabilidade

As restrições de confiabilidade $\overline{FEC}$ para os cenários propostos são calculadas a partir dos limites de confiabilidade para cada uma das redes apresentadas. São determinados cinco valores de restrição de confiabilidade distribuídos entre o valor de confiabilidade máxima (FEC_{min}), obtido a partir da realização de manutenção preventiva em todos os equipamentos, o valor de confiabilidade mínima (FEC_{max}), obtido a partir da não-realização de manutenção preventiva em todos os equipamentos.

Sendo assim, os valores de $\overline{FEC}$ para cada rede de distribuição obedecem a estratégia de escolher valores referentes a uma porcentagem definida entre o máximo e mínimo de confiabilidade

mencionados. São calculados pela seguinte equação:

$$\overline{FEC} = FEC_{min} + (FEC_{max} - FEC_{min}) \times p, \quad (8.1)$$

onde:

- p é uma porcentagem definida.

Os valores calculados pela Equação (8.1) para as redes de distribuição 1, 2 e 3, são apresentados nas Tabelas 8.4, 8.5 e 8.6, respectivamente.

Rede de distribuição 1			
Horizonte de Planejamento 1		Horizonte Planejamento 2	Horizonte Planejamento 3
$FEC_{min} = 0.2894$		$FEC_{min} = 0.2894$	$FEC_{min} = 0.2894$
$FEC_{max} = 0.4260$		$FEC_{max} = 0.5831$	$FEC_{max} = 0.8034$
$\overline{FEC}$		$\overline{FEC}$	$\overline{FEC}$
10%	0.3030	0.3188	0.3408
30%	0.3303	0.3775	0.4436
50%	0.3577	0.4362	0.5464
70%	0.3850	0.4919	0.6492
90%	0.4123	0.5536	0.7520

Tabela 8.4: Restrições de confiabilidade

8.4.2 Parâmetros

Os parâmetros são definidos para cada uma das abordagens estudadas, a partir de testes realizados à priori. Os testes envolvem conhecimento prévio do problema de otimização da manutenção e dos cenários simulados, e procuram um equilíbrio entre os valores de custo de manutenção e o tempo computacional.

Algoritmo Genético Híbrido

Para a abordagem proposta por Reis (2007), os parâmetros definidos foram:

- Número de indivíduos na população – $tampop = 200$;
- Número de iterações – $num_it = 500$;

Rede de distribuição 2			
Horizonte de Planejamento 1		Horizonte Planejamento 2	Horizonte Planejamento 3
$FEC_{min} = 0.3240$		$FEC_{min} = 0.3240$	$FEC_{min} = 0.3240$
$FEC_{max} = 0.4867$		$FEC_{max} = 0.6850$	$FEC_{max} = 0.9704$
$\overline{FEC}$		$\overline{FEC}$	$\overline{FEC}$
10%	0.3403	0.3601	0.3886
30%	0.3728	0.4323	0.5179
50%	0.4053	0.5045	0.6472
70%	0.4379	0.5767	0.7765
90%	0.4704	0.6489	0.9058

Tabela 8.5: Restrições de confiabilidade

Rede de distribuição 3			
Horizonte de Planejamento 1		Horizonte Planejamento 2	Horizonte Planejamento 3
$FEC_{min} = 0.9543$		$FEC_{min} = 0.9543$	$FEC_{min} = 0.9543$
$FEC_{max} = 1.4463$		$FEC_{max} = 2.0591$	$FEC_{max} = 2.9495$
$\overline{FEC}$		$\overline{FEC}$	$\overline{FEC}$
10%	1.0035	1.0648	1.1538
30%	1.1019	1.2857	1.5529
50%	1.2003	1.5067	1.9519
70%	1.2987	1.7277	2.3509
90%	1.3971	1.9485	2.7500

Tabela 8.6: Restrições de confiabilidade

- Taxa de mutação – $tx_mutacao = 0.5$;
- Taxa de recombinação – $tx_recombinacao = 0.5$.

Abordagem por PDREE

Para a abordagem por PDREE desenvolvida, os parâmetros definidos foram:

- Abertura do túnel – $\beta = 0.999$;
- Afunilamento do túnel – $\tau = 0.98$;

- Taxa de redução de soluções – $\rho = 0.001$.

A largura do túnel será diminuída 0.1% a cada estágio e 2% a cada iteração do processo de otimização do método de programação dinâmica.

Abordagem Híbrida 1

A seguir são definidos os parâmetros para as abordagens AGH e PDREE presentes na abordagem AH1.

- Número de indivíduos na população – $tampop = 50$;
- Número de iterações – $num_it = 100$;
- Taxa de mutação – $tx_mutacao = 0.5$;
- Taxa de recombinação – $tx_recombinacao = 0.5$.
- Abertura do túnel – $\beta = 0.995$;
- Afunilamento do túnel – $\tau = 0.98$;
- Taxa de redução de soluções – $\rho = 0.001$.

Para a abordagem AH1 os parâmetros relacionados à abordagem AGH sofreram alterações. O tamanho da população, o número de iterações foram reduzidos. Em relação à abordagem por PDREE, o parâmetro β foi alterado, reduzindo a largura do túnel em 0.5% a cada estágio.

Abordagem Híbrida 2

A abordagem AH2 leva em consideração um novo parâmetro que define a porcentagem da população inicial que passará pelo processo de PDREE:

- Taxa de indivíduos selecionados – $tx_ind = 10\%$;
- Abertura do túnel – $\beta = 0.95$;
- Afunilamento do túnel – $\tau = 0.95$;
- Taxa de redução de soluções – $\rho = 0,00005$.
- Número de indivíduos na população – $tampop = 100$;
- Número de iterações – $num_it = 500$;

- Taxa de mutação – $tx_mutacao = 0.5$;
- Taxa de recombinação – $tx_recombinacao = 0.5$.

Para a abordagem AH2 o tamanho da população inicial da abordagem AGH foi reduzido. Em relação à abordagem por PDREE, o parâmetro que define a largura do túnel e o afunilamento foram alterados, cotados em 5%. A taxa de redução de soluções será $\rho = 5 \times 10^{-4}$, admitindo uma redução de soluções dominadas menos rigorosa.

8.5 Experimento I

As três redes de distribuição propostas, Rede 1, Rede 2 e Rede 3 são executadas para até três anos de horizonte de planejamento, com juros de 15%. As abordagens estudadas são aplicadas às três instâncias e executadas apenas uma vez, determinando a solução final composta pelo valor final de custo de manutenção e tempo computacional.

8.5.1 Resultados para a Rede de Distribuição 1

Os resultados obtidos para a rede de distribuição 1, são mostrados nas Tabelas 8.7, 8.8 e 8.9. Referem-se aos custos de manutenção e aos tempos computacionais obtidos para as restrições de confiabilidade definidas.

Os melhores valores de custo de manutenção e tempo computacional são destacados em negrito, sendo os custos definidos em Reais (R\$ $\times$ 1000) e os tempos computacionais em segundos (s).

8.5.2 Análise dos Resultados para a Rede de Distribuição 1

Nota-se que todas as abordagens analisadas obtiveram resultados semelhantes quando executados para um horizonte de planejamento de um ano. Em apenas dois casos o AGH obteve um custo maior para as manutenções, porém a diferença é irrelevante do ponto de vista percentual. Quanto aos custos computacionais requeridos, todas as abordagens obtiveram bons resultados.

Para os horizontes de planejamento de dois e três anos, as abordagens híbridas AH1 e AH2 obtiveram os melhores resultados. O ganho percentual chegou a quase 5% para o custos de manutenção obtidos pela AGH. Em relação à restrição de confiabilidade, observa-se que para restrições menos rigorosas, todas as abordagens obtiveram bons resultados quanto a custo e tempo computacional.

Horizonte de Planejamento - 1 ano								
$\overline{FEC}$	AH1		AH2		PDREE		AGH	
	Custo*	Tempo**	Custo	Tempo	Custo	Tempo	Custo	Tempo
0.3030	154.42	3	154.42	2	154.42	1	154.42	3
0.3303	84.79	2	84.79	2	84.79	1	84.79	4
0.3577	51.31	2	51.31	3	51.31	1	51.79	3
0.3850	29.41	2	29.41	2	29.41	1	29.43	2
0.4123	14.49	1	14.49	1	14.49	1	14.49	1

* em Reais (R\$ $\times$ 1000)

** em segundos (s)

Tabela 8.7: Resultados - Rede 1

Horizonte de Planejamento - 2 anos								
$\overline{FEC}$	AH1		AH2		PDREE		AGH	
	Custo	Tempo	Custo	Tempo	Custo	Tempo	Custo	Tempo
0.3188	264.12	3	260.48	5	264.32	5	261.73	4
0.3775	153.11	3	153.83	6	153.80	7	159.65	4
0.4362	97.41	4	97.41	5	97.41	5	99.12	3
0.4919	59.28	14	59.28	5	59.28	3	59.28	3
0.5536	34.27	1	34.27	2	34.27	3	34.27	2

Tabela 8.8: Resultados - Rede 1

8.5.3 Resultados para a Rede de Distribuição 2

As abordagens estudadas são aplicadas a rede de distribuição 2 e executadas para um, dois e três anos de horizonte de planejamento. Os resultados obtidos para o custo de manutenção e tempo computacional são apresentados nas Tabelas 8.10, 8.11 e 8.12.

8.5.4 Análise dos Resultados para a Rede de Distribuição 2

Os resultados obtidos por todas as abordagens são semelhantes, apresentando nos casos mais extremos, uma variação percentual inferior a %1 para o custos de manutenção.

Horizonte de Planejamento - 3 anos								
$\overline{FEC}$	AH1		AH2		PDREE		AGH	
	Custo	Tempo	Custo	Tempo	Custo	Tempo	Custo	Tempo
0.3408	388.49	8	387.82	12	388.72	17	390.60	7
0.4436	253.43	13	251.92	23	252.93	21	253.43	6
0.5464	153.66	9	153.66	15	153.66	11	157.71	5
0.6492	93.77	6	93.77	11	93.77	6	94.51	3
0.7520	62.40	10	62.40	2	62.40	1	62.40	2

Tabela 8.9: Resultados - Rede 1

Horizonte de Planejamento - 1 ano								
$\overline{FEC}$	AH1		AH2		PDREE		AGH	
	Custo	Tempo	Custo	Tempo	Custo	Tempo	Custo	Tempo
0.3403	642.90	11	642.90	17	641.49	3	644.90	20
0.3728	364.66	8	364.66	11	365.09	6	366.13	12
0.4053	284.59	10	284.59	13	284.67	3	286.60	8
0.4379	241.05	5	241.05	7	241.05	2	241.64	5
0.4704	216.05	3	216.05	5	216.05	1	216.05	5

Tabela 8.10: Resultados - Rede 2

É possível observar que todas as abordagens desenvolvidas apresentaram um bom desempenho em relação aos tempos computacionais apresentados pela abordagem AGH, com exceção para o cenário com horizonte de planejamento de três anos, onde a AGH se sobressaiu. Porém, esse ganho computacional não é significativo, uma vez que o problema de otimização da manutenção possui impacto a longo prazo.

8.5.5 Resultados para a Rede de Distribuição 3

Os resultados obtidos para a execução das abordagens estudadas na rede de distribuição 3, com horizonte de planejamento variando entre um, dois e três anos, são apresentados nas Tabelas 8.13, 8.14 e 8.15.

Horizonte de Planejamento - 2 anos								
$\overline{FEC}$	AH1		AH2		PDREE		AGH	
	Custo	Tempo	Custo	Tempo	Custo	Tempo	Custo	Tempo
0.3601	1110.62	13	1109.57	17	1118.34	16	1111.92	26
0.4323	782.07	14	781.78	18	782.07	26	782.38	15
0.5045	656.44	16	657.52	28	658.94	29	658.94	10
0.5767	573.47	17	573.23	18	573.65	17	574.20	8
0.6489	534.64	7	534.64	5	534.64	3	534.64	4

Tabela 8.11: Resultados - Rede 2

Horizonte de Planejamento - 3 anos								
$\overline{FEC}$	AH1		AH2		PDREE		AGH	
	Custo	Tempo	Custo	Tempo	Custo	Tempo	Custo	Tempo
0.3886	1803.68	23	1784.35	31	1800.62	32	1800.62	42
0.5179	1352.71	41	1353.52	50	1358.54	64	1360.23	22
0.6472	1174.67	54	1174.65	67	1177.40	121	1175.16	21
0.7765	1053.87	37	1054.09	61	1054.02	150	1056.23	12
0.9058	1008.41	9	1008.41	9	1008.41	5	1008.41	6

Tabela 8.12: Resultados - Rede 2

Horizonte de Planejamento - 1 ano								
$\overline{FEC}$	AH1		AH2		PDREE		AGH	
	Custo	Tempo	Custo	Tempo	Custo	Tempo	Custo	Tempo
1.0035	687.76	14	687.76	20	687.76	17	688.96	22
1.1019	496.94	22	496.94	37	496.94	24	503.99	54
1.2003	324.87	24	324.93	42	324.58	25	330.73	61
1.2987	181.73	14	183.22	23	181.60	19	186.68	22
1.3971	72.47	4	72.47	6	72.47	2	72.47	3

Tabela 8.13: Resultados - Rede 3

Horizonte de Planejamento - 2 anos								
$\overline{FEC}$	AH1		AH2		PDREE		AGH	
	Custo	Tempo	Custo	Tempo	Custo	Tempo	Custo	Tempo
1.0648	1279.28	27	1276.62	40	1278.73	27	1280.74	41
1.2857	908.29	36	901.42	58	901.22	55	914.75	71
1.5067	613.98	38	613.78	58	613.77	109	622.86	52
1.7277	363.35	38	363.99	54	363.24	141	368.96	29
1.9485	177.22	7	177.22	8	177.22	7	177.22	3

Tabela 8.14: Resultados - Rede 3

Horizonte de Planejamento - 3 anos								
$\overline{FEC}$	AH1		AH2		PDREE		AGH	
	Custo	Tempo	Custo	Tempo	Custo	Tempo	Custo	Tempo
1.1538	1880.84	58	1876.78	91	1876.97	133	1882.30	92
1.5529	1307.44	101	1305.75	115	1307.33	245	1322.16	165
1.9519	890.34	140	890.21	135	892.76	133	900.30	142
2.3509	564,14	129	566.25	136	570.02	190	572.48	52
2.7500	333.79	15	333.79	15	333.79	10	333.79	7

Tabela 8.15: Resultados - Rede 3

8.5.6 Análise dos Resultados - Rede de Distribuição 3

A abordagem por PDREE apresenta bom desempenho em relação ao valor de custo obtido pela abordagem AGH para o cenário com horizonte de planejamento de um e dois anos, chegando a obter um ganho percentual de aproximadamente %3. O desempenho da AH2 também é destacado nos casos de restrição de qualidade mais rigorosa, obtendo bons resultados quanto aos tempos computacionais obtidos.

O cenário simulado para o horizonte de planejamento de três anos apresenta o ganho mais significativo obtido pelas abordagens desenvolvidas quanto aos custos de manutenção. Elas obtiveram um ganho total de aproximadamente R\$40.000,00 em relação ao AGH e com tempos computacionais menores.

Os ganhos totais obtidos pela abordagem por PDREE para os custos de manutenção em

relação ao AGH para todos os cenários simulados nessa rede de distribuição ultrapassa o valor de R\$80.000,00, sendo na grande parte com tempos computacionais menores.

Analisando a AH2, os ganhos totais para os custos de manutenção é ainda maior em relação ao AGH, chegando a aproximadamente R\$90.000,00. O desempenho da AH2 em relação aos tempos computacionais obtidos também são bons em comparação com os obtidos pela abordagem AGH, exceto nos cenários com restrições de qualidade menos rigorosas.

A AH1 também obteve melhores resultados do que a AGH, porém com desempenho mais modesto. Destaca-se em relação aos tempos computacionais obtidos quando a restrição de confiabilidade é mais rigorosa.

8.5.7 Análise Geral do Experimento

As três abordagens propostas apresentaram bom desempenho, sendo na maioria dos casos superiores à AGH. Contudo, a abordagem AGH contribui fortemente para o bom desempenho das abordagens híbridas.

A análise comparativa entre as duas abordagens híbridas mostrou resultados distintos em alguns cenários simulados. Esse fato conduz ao próximo experimento, que busca analisar o desempenho dessas duas abordagens híbridas em conjunto.

8.6 Experimento II

As abordagens AH1 e AH2 alternavam os bons resultados em alguns caso observados. Assim, é desenvolvida uma nova abordagem, denominada AH3, combinando as abordagens mencionadas.

São explorados os casos para horizonte de planejamento de três anos para cada uma das redes de distribuição estudadas e os resultados são apresentados em tabelas que ilustram os custos de manutenção e os tempos computacionais requeridos.

Os resultados são discutidos em uma análise de resultados, apontando para os benefícios do desenvolvimento desse conjunto de ideias.

8.6.1 Resultados para o Experimento II

Os parâmetros adotados para as abordagens são os mesmos definidos para o Experimento 1, e os algoritmos são executados uma vez. Os resultados finais são apresentado nas Tabelas 8.1, 8.2 e 8.3 e destacados em negrito os melhores ou iguais aos resultados obtidos nos mesmos casos explorados no Experimento I.

Rede de Distribuição 1		
AH3		
$\overline{FEC}$	Custo	Tempo
0.3408	387.82	17
0.4436	251.92	28
0.5464	153.66	20
0.6492	93.77	15
0.7520	62.40	8

Tabela 8.1: Resultados - Rede 1

Rede de Distribuição 2		
AH3		
$\overline{FEC}$	Custo	Tempo
0.3886	1784.35	50
0.5179	1353.52	81
0.6472	1174.59	116
0.7765	1053.87	87
0.9058	1008.41	27

Tabela 8.2: Resultados - Rede 2

Rede de Distribuição 3		
AH3		
$\overline{FEC}$	Custo	Tempo
1.1538	1876.45	95
1.5529	1304.95	205
1.9519	890.17	301
2.3509	564.12	305
2.7500	333.79	33

Tabela 8.3: Resultados - Rede 3

8.6.2 Análise dos Resultados do Experimento II

Na rede de distribuição 1, a abordagem AH3 manteve os bons resultados obtidos pela AH2, ou seja, nenhuma melhoria foi obtida, dados os tempos computacionais mais elevados.

Para a rede de distribuição 2, a abordagem AH3 não conseguiu bons resultados em relação aos custos de manutenção. Em um dos cenários, o resultado final em relação aos custos de manutenção foi pior do que o obtido pela AH2. Os pequenos ganhos obtidos nos demais cenários foram considerados insignificantes.

Todavia, para a rede de distribuição 3, a abordagem AH3 obteve melhores resultados em relação aos custos de manutenção em todos os cenários. Comparando-se com as outras abordagens, o desempenho da AH3 é considerado bom, com tempos computacionais aceitáveis.

8.7 Experimento III

O terceiro experimento utiliza as estratégias de construção de gráficos probabilísticos chamados *Time-to-Target Plots* (TTTPlot) (Aiex, Resende & Ribeiro 2007).

Esses gráficos são utilizados para comparar o desempenho de heurísticas através dos tempos computacionais obtidos. Os gráficos são gerados a partir de uma série de execuções realizadas para as heurísticas, onde é medido o tempo mínimo requerido para que os algoritmos analisados atinjam uma solução alvo. O objetivo é analisar a probabilidade que cada algoritmo possui para atingir essas soluções alvo em função do tempo computacional.

Para a construção desses gráficos, são realizados três passos:

- **Determina-se uma solução alvo:**

Cada gráfico gerado corresponde a uma solução alvo. Usualmente, escolhe-se um valor que representa uma boa solução para o problema estudado.

- **Mede-se o tempo computacional requerido:**

Os algoritmos analisados são executados n -vezes e cada execução o tempo computacional necessário para que a solução alvo seja alcançada é preservado;

- **Calcula-se a probabilidade p :**

A probabilidade é calculada a partir da seguinte equação:

$$p(y) = \frac{(y - \frac{1}{2})}{n_e}, \quad (8.2)$$

onde $y = 1, \dots, n_e$ e n_e é o número de execuções realizadas.

8.7.1 Dados para o Experimento III

São comparados os desempenhos das abordagens híbridas, AH1 e AH2, e do algoritmo genético híbrido AGH. As abordagens são executadas 100 vezes, e a solução alvo é determinada conforme os valores de custos de manutenção obtidos no Experimento I. São construídos três gráficos TTTplots, referenciando cada uma das redes de distribuição estudadas.

Dado que o número de execuções, alguns parâmetro foram redefinidos para as abordagens. Para a abordagem AGH, a população foi composta por 100 indivíduos. Para a abordagem AH1, a abertura do túnel, o afunilamento, o número de indivíduos da população e o número de iterações do algoritmo genético foram modificados. Foram redefinidos $\beta = 0.95$, $\tau = 0.95$,

$num_{it} = 50$ e $tampop = 50$. Para a abordagem AH2, foram redefinidos os parâmetros de abertura do túnel, $\beta = 0.80$, e do afunilamento do túnel, $\tau = 0.80$.

Uma outra análise foi elaborada através da construção gráficos de distribuição de probabilidade. Os gráficos construídos são chamados de *quantil-quantil plot*, ou *Q-Q plot* (WILK & GNANADESIKAN 1968). Esses gráficos verificam se os tempos computacionais obtidos se ajustam a uma curva de distribuição cumulativa de probabilidade.

8.7.2 Resultados para o Experimento III

Rede de Distribuição 1

A rede de distribuição 1 foi abordada para o cenário de três anos de horizonte de planejamento. Os algoritmos foram executados 100 vezes, com restrição de confiabilidade, $\overline{FEC} = 0.5464$ e solução alvo proposta de R\$ 158.000,00 de custo de manutenção. A Figura 8.4 ilustra o gráfico TTTplot de distribuição cumulativa de probabilidade para as abordagens executadas.




Figura 8.4: Gráfico de distribuição cumulativa de probabilidade - Rede 1.

As Figuras 8.5, 8.6 e 8.7 apresentam os gráficos *Q-Q plot* para os dados obtidos pelas abordagens em relação à distribuição cumulativa de probabilidade.




Figura 8.5: AGH - Rede 1.




Figura 8.6: AH1 - Rede 1.

Rede de Distribuição 2

A rede de distribuição 2 é abordada para o cenário de dois anos de horizonte de planejamento. Os algoritmos foram executados 100 vezes, com restrição de confiabilidade, $\overline{FEC} = 0.5045$, e




Figura 8.7: AH2 - Rede 1.

a solução alvo proposta R\$ 659.000,00 para o custo de manutenção. A Figura 8.8 apresenta o gráfico TTTplot obtido.




Figura 8.8: Gráfico de distribuição cumulativa de probabilidade - Rede 2.

Assim como no resultado anterior, o gráfico Q-Q plot é construído. As Figuras 8.9, 8.10 e

8.11 apresentam os gráficos para cada uma das abordagens.




Figura 8.9: AGH - Rede 2.




Figura 8.10: AH1 - Rede 2.




Figura 8.11: AH2 - Rede 2.

Rede de Distribuição 3

A rede de distribuição 3 é abordada para o cenário de um ano de horizonte de planejamento. O gráfico TTTplot é construído executando 100 vezes cada uma das abordagens estudadas, com restrição de confiabilidade, $\overline{FEC} = 1.2003$, e a solução alvo proposta de R\$ 335.000,00 de custo de manutenção. O gráfico TTTplot pode ser visto na Figura 8.12.

O gráfico Q-Q plot também é construído para os resultados obtidos para a rede de distribuição 3. As Figuras 8.13, 8.14 e 8.15 apresentam os gráficos para as abordagens estudadas.

A partir desses resultados, algumas conclusões podem ser apresentadas sobre o desempenho das abordagens exploradas.

8.7.3 Análise dos Resultados do Experimento III

Gráficos TTTplots

O gráfico da Figura 8.4 mostra o melhor desempenho computacional obtido pela abordagem AH2 para a rede de distribuição 1. A AH2 tem 80% de chance de atingir a solução alvo em até 1.5 segundos, enquanto as abordagens AH1 e AGH conseguiram a mesma probabilidade de alcançar o alvo em aproximadamente 2 e 2.55 segundos, respectivamente. Nota-se que a probabilidade da abordagem AGH atingir o alvo em menos tempo que a abordagem AH2 é muito pequena,




Figura 8.12: Gráfico de distribuição cumulativa de probabilidade - Rede 3.




Figura 8.13: AGH - Rede 3.

menos de 4% de chance. A abordagem AH1 também apresenta um bom desempenho, possuindo quase 99% de chances de atingir o objetivo em menos de 2.1 segundos.

O gráfico da Figura 8.8 mostra um resultado similar para a rede de distribuição 2. A abordagem AH2 obteve o melhor desempenho, atingindo o alvo com quase 98% de probabilidade




Figura 8.14: AH1 - Rede 3.




Figura 8.15: AH2 - Rede 3.

em aproximadamente 4 segundos. As outras abordagens AH1 e AGH, tiveram a mesma probabilidade de atingir o alvo em 5.10 e 8.4 segundos, respectivamente. Os desempenhos da AH1 e da AH2 são muito superiores ao desempenho da AGH. A probabilidade da abordagem AGH

atingir o alvo com tempo computacional inferior é menor do que 2%.

O gráfico da Figura 8.12, referente à rede de distribuição 3, mostra que abordagem AH1 obteve um desempenho muito superior, dado que a probabilidade das abordagens AH2 e AGH atingirem o alvo com tempo computacional inferior é zero. A abordagem AH2 também obteve um bom desempenho, porém com a probabilidade de quase 30% de chances da abordagem AGH atingir o alvo em um menor tempo computacional.

Gráficos Q-Q Plots

Os gráficos Q-Q plots avaliam se os dados obtidos pelas abordagens seguem uma distribuição normal. São constituídos por quantis teóricos de uma distribuição contrastando com os quantis do conjunto de dados.

Em relação ao desempenho dos algoritmos explorados, pode-se afirmar que quanto mais o tempo medido se aproxima dos quantis teóricos, mais robustos são os algoritmos desenvolvidos. Uma porcentagem muito alta de pontos do conjunto de dados distantes da distribuição normal atribui ao algoritmo uma aleatoriedade indesejada quanto à obtenção de uma boa solução final. Supondo um caso real, em que existem muitas redes de distribuição distintas para muitos cenários simulados, o estudo empírico dos parâmetros para os algoritmos torna-se um trabalho demorado.

Para os Q-Q plots construídos a partir dos resultados da rede de distribuição 1, nota-se um desempenho superior das abordagens AH1 e AH2 em relação à abordagem AGH. Apesar da abordagem AH2 ter um desempenho melhor para o gráfico TTTplot, a abordagem AH1 apresentou um conjunto de dados mais próximo dos quantis teóricos.

Para a rede de distribuição 2, os Q-Q plots mostram que a abordagem AH2 apresentou um conjunto de dados mais próximos dos quantis teóricos. As abordagens AH1 e AGH obtiveram um desempenho um pouco semelhante diante dessa análise do conjunto de dados apresentados.

O conjunto de dados obtidos pelas abordagens para a rede de distribuição 3 mostram essencialmente que a abordagem AGH não se adaptou à topologia da rede de distribuição. Os gráficos Q-Q plots mostram uma porcentagem muito grande de pontos do conjunto de dados, da abordagem AGH, distantes da distribuição normal. Quanto às abordagens AH1 e AH2, é correto afirmar que ambas obtiveram um desempenho muito bom, considerando a complexidade da topologia da rede.

Através de uma análise geral dos gráficos Q-Q plots, pode-se afirmar que as abordagens AH1 e AH2 desenvolvidas são mais robustas para o problema de otimização de manutenção abordado.

8.8 Comentários Finais

O capítulo apresentou um estudo comparativo de desempenho entre as abordagens desenvolvidas neste trabalho e uma abordagem por algoritmo genético desenvolvida por Reis (2007), aplicadas ao problema de otimização de manutenção em redes de distribuição de energia elétrica de escala real.

O estudo foi composto por três experimentos, explorando diversos cenários de restrição de confiabilidade do sistema de distribuição e múltiplos anos de horizonte de planejamento.

Os resultados obtidos foram discutidos a partir das análises de desempenho realizadas. Através dessa discussão, é possível confirmar que as abordagens desenvolvidas neste trabalho tiveram desempenho superiores para a aplicação do problema de otimização de manutenção proposto.

Conclusões e Perspectivas

O trabalho abordou o problema de otimização de políticas de planejamento para alocação ótima de recursos de manutenção preventiva em redes de distribuição de energia elétrica.

Os aspectos da metodologia de manutenção e o problema de otimização de manutenção preventiva aplicada em sistemas de distribuição de energia elétrica foram apresentados. O modelo de otimização para o problema, um aperfeiçoamento do modelo proposto por Reis (2007), teve como objetivo encontrar o melhor orçamento para o planejamentos de políticas de manutenção preventiva sob restrições de níveis mínimos de confiabilidade do sistema, ao longo de um horizonte de planejamento.

A maioria dos trabalhos propostos para políticas de manutenção em sistemas de distribuição de energia elétrica utiliza meta-heurísticas como estratégia de solução. Dentre essas meta-heurísticas, destacou-se a abordagem por Algoritmo Genético Híbrido (AGH) proposta por Reis (2007), pois tratou o problema de otimização para sistemas de distribuição de energia elétrica em escala real. As principais ideias da abordagem AGH foram apresentadas e adotadas como referência para os estudos de casos realizados neste trabalho.

A principal contribuição da tese foi o desenvolvimento de uma metodologia, baseada em programação dinâmica, para o problema de otimização proposto. A metodologia, denominada Programação Dinâmica com Reduções de Espaços de Estados (PDREE), utiliza de forma coordenada duas técnicas de reduções de espaço de estados: a primeira técnica procurou eliminar regiões pouco promissoras do espaço de estados, usando o conceito de soluções dominadas; a

segunda técnica explorou o conceito de Programação Dinâmica Diferencial Discreta, realizando a otimização por programação dinâmica em torno de uma vizinhança de boas trajetórias de referência obtidas por um método de otimização guloso.

Foram desenvolvidas também duas abordagens híbridas que combinam a abordagem por PDREE e a abordagem por AGH mencionada. A primeira abordagem híbrida, denominada AH1, utilizou a abordagem AGH para a obtenção de planos de manutenção iniciais, posteriormente otimizados pela abordagem por PDREE. A segunda abordagem híbrida, denominada AH2, utilizou a abordagem PDREE como um procedimento de otimização para gerar boas populações de soluções iniciais, posteriormente otimizadas pela abordagem AGH.

Os estudos de casos realizaram aplicações em redes reais, com análises comparativas de desempenho entre a abordagem por PDREE, as abordagens híbridas, AH1 e AH2, e o algoritmo genético híbrido proposto por Reis (2007). O primeiro experimento propôs uma análise dos resultados referentes aos custos de manutenção e aos tempos computacionais para diversos cenários simulados. O segundo experimento, testou para alguns casos explorados no primeiro experimento, o desenvolvimento de uma terceira abordagem híbrida, denominada AH3, que combinava as duas abordagens híbridas, AH1 e AH2. O terceiro experimento discutiu o desempenho dos algoritmos referentes às abordagens híbridas e à abordagem AGH.

Os resultados mostraram que em quase todos os cenários as abordagens desenvolvidas neste trabalho obtiveram melhores desempenhos, destacando alguns casos onde o desempenho da AGH foi superior. Nos primeiros dois experimentos, as abordagens obtiveram os melhores resultados em relação aos custos de manutenção, com destaque para abordagens híbridas, AH1 e AH2, que também obtiveram bons resultados em relação ao tempo computacional. No terceiro experimento, os gráficos probabilísticos mostraram que as abordagens AH1 e AH2 foram mais robustas em relação à obtenção de soluções alvo.

Em resumo, os estudos de casos realizados permitem afirmar que as abordagens desenvolvidas neste trabalho estendem o “estado-da-arte” sobre a otimização de políticas de manutenção de sistemas de distribuição de energia elétrica.

O bom desempenho das abordagens híbridas sugerem a exploração de outras alternativas de cooperação entre meta-heurísticas e os conceitos de programação dinâmica aqui desenvolvidos. Por exemplo, a metodologia de PDREE pode ser usada em otimizações locais, ao longo do processo iterativo de algoritmos genéticos híbridos.

Numa perspectiva mais ampla, um campo possível de investigação é a aplicação da metodologia para redes de distribuição não-radiais, redes de transmissão ou outros componentes dos sistemas de energia elétrica. No entanto, deve-se ressaltar que as abordagens por programação

dinâmica exigem a presença de características que permitam a decomposição de processos de decisões em estágios e que, frequentemente, precisam de ser associados a estratégias de redução dos espaços de buscas.

Referências Bibliográficas

- Aiex, R. M., Resende, M. G. & Ribeiro, C. C. (2007). TTT plots: a perl program to create time-to-target plots, *Optimization Letters* **1**(4): 355–366.
- Arya, L., Choube, S. & Arya, R. (2011). Differential evolution applied for reliability optimization of radial distribution systems, *International Journal of Electrical Power & Energy Systems* **33**(2): 271 – 277.
- Atmar, W. (1994). Notes on the simulation of evolution, *IEEE Transactions on Neural Networks* **5**(1): 130–147.
- Bacalhau, E. T., Filho, C. L. & Cavellucci, C. (2009). Buscas em espaços de estados para alocação Ótima de recursos de manutenção em redes de distribuição de energia elétrica, *Simpósio Brasileiro de Pesquisa Operacional (SBPO), Porto Seguro, BA* **1**: 1917–1928.
- Bacalhau, E. T., Usberti, F. L. & Cavellucci, C. (2013). Programação dinâmica diferencial aplicada ao planejamento de recursos de manutenção preventiva em redes de distribuição de energia elétrica, *Simpósio Brasileiro de Pesquisa Operacional (SBPO), Natal, RN* **1**: 1112–1123.
- Bacalhau, E. T., Usberti, F. L. & Filho, C. L. (2012). Programação dinâmica aplicada ao problema da mochila para a alocação Ótima de recursos de manutenção em redes de energia elétrica, *Congresso Brasileiro de Automática (CBA), Campina Grande, PB* **1**: 2134–2139.
- Bacalhau, E. T., Usberti, F. L., Filho, C. L. & Cavellucci, C. (2012). A knapsack problem approach for optimal allocation of maintenance resources on electric power distribution networks., in C. J. Luz & F. Valente (eds), *ICORES*, SciTePress, pp. 462–466.

- Bacalhau, E. T., Usberti, F. L. & Lyra, C. (2013). A dynamic programming approach for optimal allocation of maintenance resources on power distribution networks, *Power and Energy Society General Meeting (PES), 2013 IEEE*, pp. 1–5.
- Bellman, R. (1957). *Dynamic Programming*, Dover Publications.
- Bertling, L., Miranda, V., Matos, M. A. & Hilber, P. (2007). Multiobjective optimization applied to maintenance policy for electrical networks, *IEEE Transactions on Power Systems* **22**(4): 1675 – 1682.
- Billinton, R. & Allan, R. N. (1996). *Reliability evaluation of power systems*, Plenum Press, New York.
- Billinton, R. & Billinton, J. (1989). Distribution system reliability indices, *IEEE Transactions on Power Delivery* **4**(1): 561–568.
- Brown, R. E. (2002). *Electric Power Distribution Reliability*, CRC Press, New York.
- Bäck, T., Fogel, D. B. & Michalewicz, T. (2000). *Evolutionary Computation 1*, Taylor & Francis Group, New York, NY, U.S.A.
- Cormen, T. H., Leiserson, C. E., Rivest, R. L. & Stein, C. (2001). *Introduction to Algorithms*, MIT Press.
- Dahal, K. P. & Chakpitak, N. (2007). Generator maintenance scheduling in power systems using metaheuristic-based hybrid approaches, *Electric Power Systems Research* **77**(7): 771 – 779.
- Endrenyi, J., Aboresheid, S., Allan, R., Anders, G., Asgarpour, S., Billinton, R., Chowdhury, N., Dialynas, E., Fipper, M., Fletcher, R., Grigg, C., McCalley, J., Meliopoulos, S., Mielnik, T., Nitu, P., Rau, N., Reppen, N., Salvaderi, L., Schneider, A. & 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. (2006). Aging, maintenance and reliability, *IEEE power & energy magazine* pp. 59–67.
- Endrenyi, J., Anders, G. & Leite da Silva, A. (1998). Probabilistic evaluation of the effect of maintenance on reliability. an application, *IEEE Transactions on Power Systems* **13**(2): 576–583.

- Goldberg, D. E. (1989). *Genetic Algorithms in Search, Optimization, and Machine Learning*, Addison-Wesley.
- Gonzalez, J. F. V. (2005). *Redução de perdas em redes primarias de distribuição de energia elétrica por instalação e controle de capacitores.*, Mestrado, Faculdade de Engenharia Elétrica e de Computação - Universidade Estadual de Campinas, Campinas - SP - Brazil.
- Heidari, M., Chow, V. T., Kokotovic, P. V. & Meredith, D. D. (1971). Discrete differential dynamic programming approach to water resources systems optimization, *Water Resources Research* **7**(2): 273–282.
- Holland, J. (1975). *Adaptation in Natural and Artificial Systems*, The University of Michigan Press.
- IEEE Standard 493 (1998). IEEE recommended practice for the design of reliable industrial and commercial power systems, *IEEE Gold Book*.
- Janjic, A. & Popovic, D. (2007). Selective maintenance schedule of distribution networks based on risk management approach, *IEEE Transactions on Power Systems* **22**(2): 597–604.
- Kirk, D. & Kreider, D. (1970). *Optimal Control Theory: An Introduction*, Prentice-Hall electrical engineering series, Prentice-Hall.
- Kuntz, P., Christie, R. & Venkata, S. (2002). Optimal vegetation maintenance scheduling of overhead electric power distribution systems, *IEEE Transactions on Power Delivery* **17**(4): 1164–1169.
- Larson, R. E. (1968). *State Increment Dynamic Programming*, American Elsevier Pub. Co.
- Lyra, C. & Ferreira, L. (1995). A multiobjective approach to the short-term scheduling of a hydroelectric power system, *Power Systems, IEEE Transactions on* **10**(4): 1750–1755.
- Michalewicz, Z. (1996). *Genetic Algorithms + Data Structures = Evolution Programs*, Springer, New York.
- Michalewicz, Z. & Fogel, D. B. (2000). *How to Solve it*, Spring-Verlag, New York.
- Moghaddam, K. S. & Usher, J. S. (2011a). A new multi-objective optimization model for preventive maintenance and replacement scheduling of multi-component systems, *Engineering Optimization* **43**(7): 701–719.

- Moghaddam, K. S. & Usher, J. S. (2011b). Preventive maintenance and replacement scheduling for repairable and maintainable systems using dynamic programming, *Computers & Industrial Engineering* **60**(4): 654–665.
- Moon, J.-F., Yoon, Y.-T., Lee, S.-S., Kim, J.-C., Lee, H.-T. & Park, G.-P. (2006). Reliability-centered maintenance model to managing power distribution system equipment, *Power Engineering Society General Meeting, 2006. IEEE*, pp. 6 pp.–.
- Moubray, J. (1997). *Reliability-Centered Maintenance*, second edition edn, Industrial Press Inc., New York, NY, U.S.A.
- Park, G. P. & Yoon, Y. T. (2012). Application of ordinal optimization on reliability centered maintenance of distribution system, *European Transactions on Electrical Power* **22**(3): 391–401.
- Pereira, C. M., Lapa, C. M., Mol, A. C. & da Luz, A. F. (2010). A particle swarm optimization (psa) approach for non-periodic preventive maintenance scheduling programming, *Progress in Nuclear Energy* **52**(8): 710 – 714.
- Powell, W. B. (2011). *Approximate Dynamic Programming: Solving the Curses of Dimensionality*, Wiley Series in Probability and Statistics, Wiley.
- Radmer, D., Kuntz, P., Christie, R., Venkata, S. & Fletcher, R. (2002). Predicting vegetation-related failure rates for overhead distribution feeders, *IEEE Transactions on Power Delivery* **17**(4): 1170–1175.
- Reis, P. A. (2007). *Otimização baseada em confiabilidade de planos de manutenção de sistemas de distribuição de energia elétrica*, Mestrado, Faculdade de Engenharia Elétrica e de Computação - Universidade Estadual de Campinas, Campinas - SP - Brazil.
- Sim, S. H. & Endrenyi, J. (1988). Optimal preventive maintenance with repair, *IEEE Transactions on Reliability - TR* **37**(1): 92–96.
- Siqueira, I. P. (2005). *Manutenção Centrada na Confiabilidade: Manual de Implementação*, Qualitymark Editora LTDA., Rio de Janeiro, RJ, Brasil.
- Sittithumwat, A., Soudi, F. & Tomsovic, K. (2004). Optimal allocation of distribution maintenance resources with limited information, *Electric Power Systems Research* **68**: 208 – 220.

- Sniedovich, M. (2011). *Dynamic Programming: Foundations and Principles, Second Edition*, CRC Press, Taylor & Francis Group.
- Soudi, F. & Tomsovic, K. (2001). Optimal trade-offs in distribution protection design, *IEEE Transactions on Power Delivery* **16**(2): 292–296.
- Usberti, F. L., Lyra, C., Cavellucci, C. & González, J. F. V. (2012). Hierarchical multiple criteria optimization of maintenance activities on power distribution networks, *Annals of Operations Research* pp. 1–22.
- WILK, M. B. & GNANADESIKAN, R. (1968). Probability plotting methods for the analysis for the analysis of data, *Biometrika* **55**(1): 1–17.
- Yamayee, Z., Sidenblad, K. & Yoshimura, M. (1983). A computationally efficient optimal maintenance scheduling method, *Power Apparatus and Systems, IEEE Transactions on PAS-102*(2): 330 –338.
- Zurn, H. H. & Quintana, V. (1975). Generator maintenance scheduling via successive approximations dynamic programming, *Power Apparatus and Systems, IEEE Transactions on* **94**(2): 665–671.