

TESE DE DOUTORADO Nº 189

**PLANEJAMENTO INTEGRADO DE SISTEMAS DE DISTRIBUIÇÃO DE ENERGIA
ELÉTRICA ROBUSTOS COM GERAÇÃO DISTRIBUÍDA**

Cristiane Geralda Taroco

DATA DA DEFESA: 04/08/2014

Universidade Federal de Minas Gerais

Escola de Engenharia

Programa de Pós-Graduação em Engenharia Elétrica

**PLANEJAMENTO INTEGRADO DE SISTEMAS DE
DISTRIBUIÇÃO DE ENERGIA ELÉTRICA ROBUSTOS COM
GERAÇÃO DISTRIBUÍDA**

Cristiane Geralda Taroco

Tese de Doutorado submetida à Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação em Engenharia Elétrica da Escola de Engenharia da Universidade Federal de Minas Gerais, como requisito para obtenção do Título de Doutor em Engenharia Elétrica.

Orientador: Prof. Eduardo Gontijo Carrano

Belo Horizonte - MG

Agosto de 2014

T191p

Tarôco, Cristiane Geralda.

Planejamento integrado de sistemas de distribuição de energia elétrica robustos com geração distribuída [manuscrito] / Cristiane Geralda Tarôco. – 2014.

xi, 115 f., enc.: il.

Orientador: Eduardo Gontijo Carrano.

Tese (doutorado) - Universidade Federal de Minas Gerais,
Escola de Engenharia.

Bibliografia: f.109-115.

1. Engenharia elétrica – Teses. 2. Energia elétrica - Distribuição – Teses.
I.Carrano, Eduardo Gontijo. II. Universidade Federal de Minas Gerais.
Escola de Engenharia. III. Título.

CDU: 621.3(043)

"Planejamento Integrado de Sistemas de Distribuição de Energia Elétrica Robustos com Geração Distribuída"

Cristiane Geralda Taroco

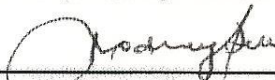
Tese de Doutorado submetida à Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação em Engenharia Elétrica da Escola de Engenharia da Universidade Federal de Minas Gerais, como requisito para obtenção do grau de Doutor em Engenharia Elétrica.

Aprovada em 04 de agosto de 2014.

Por:



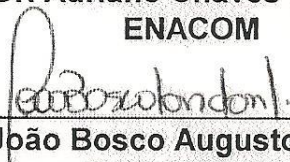
Prof. Dr. Eduardo Gontijo Carrano
DEE (UFMG) - Orientador



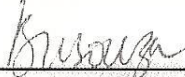
Prof. Dr. Rodney Rezende Saldanha
DEE (UFMG)



Dr. Adriano Chaves Lisboa
ENACOM



Prof. Dr. João Bosco Augusto London Junior
DEE (USP SC)



Prof. Dr. Benemar Alencar de Souza
DEE (UFCG)

UNIVERSIDADE FEDERAL DE MINAS GERAIS
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA
CENTRO DE PESQUISA E DESENVOLVIMENTO EM ENGENHARIA ELÉTRICA

Planejamento Integrado de Sistemas de Distribuição de Energia Elétrica Robustos com Geração Distribuída

Cristiane Geralda Tarôco

Orientador: Prof. Eduardo Gontijo Carrano

Belo Horizonte, Agosto de 2014

Resumo

Neste trabalho foi desenvolvida uma ferramenta de planejamento de sistemas de distribuição de energia elétrica capaz de obter redes robustas, confiáveis e menos onerosas. Essa ferramenta é capaz de realizar as seguintes operações: *(i)* planejamento da nova estrutura (topologia) da rede; *(ii)* atribuição dos tipos de condutores utilizados na rede; *(iii)* posicionamento de novas unidades de geração e subestações; *(iv)* análise da robustez das redes após a inserção de novas unidades de geração. Para compor esta ferramenta foram desenvolvidos um procedimento de busca local determinística que deve ser aplicado às soluções encontradas pelo algoritmo de otimização e um mecanismo para alocação de novas unidades de geração. O procedimento de busca local é composto por três operadores: *i)* operador de aprimoramento dos custos, *ii)* operador de aprimoramento da robustez e *iii)* operador de aprimoramento da confiabilidade. No planejamento do sistema são consideradas variáveis de projeto incertas (módulo das cargas, preço da energia e potência entregue pela turbina eólica), necessárias para a modelagem da evolução do sistema a médio e longo prazo. O algoritmo de projeto proposto tem por intuito encontrar conjuntos de soluções que apresentem um bom compromisso entre custo, confiabilidade e robustez. São consideradas versões mono (custo) e multi-objetivo (custo e confiabilidade) do problema de planejamento de redes de distribuição de energia elétrica. Foram consideradas como unidades de geração turbinas eólicas. Os resultados obtidos mostram que a ferramenta é adequada para o planejamento de sistemas de distribuição, já que possibilita a obtenção de redes robustas, confiáveis e menos onerosas.

Abstract

In this work it is developed a tool dedicated to plan electric power distribution systems able to find networks that are robust, reliable and have lower monetary cost. This tool is able to perform the following operations: *(i)* to plan the new network topology; *(ii)* to assign the conductor capacities and types; *(iii)* to locate new generation units and substations; *(iv)* to analyse the network robustness after the allocation of new generation units. To form this tool they were developed a local search deterministic procedure that must be applied to the solutions found by the optimization algorithm and a procedure to locate new generation units. The local search deterministic procedure is composed of three operators: *i)* cost improvement operator, *ii)* robustness improvement operator and *iii)* reliability improvement procedure. Some uncertain variables are considered (evolution of the load, the energy price at each node and variation of the power produced by the wind turbine), since they are required to model the system evolution at medium and long term. The main purpose of the proposed algorithm is to find a set of solutions that show a favorable trade-off with regard to cost, reliability and robustness. Mono (cost) and multiobjective (cost and reliability) statements of the problem are considered. Wind turbines were considered as the generation units to be allocated. The results show that the proposed tool is adequate for planning distribution systems as the networks obtained are robust, reliable and have lower monetary cost.

Agradecimentos

Agradeço a Deus por ter me guiado nesta importante etapa da minha vida e por tudo que Ele tem me proporcionado.

Agradeço ao meu marido Leandro pela compreensão, carinho e apoio.

Aos meus pais e minha irmã pelo apoio e por terem acreditado que eu pudesse aqui chegar.

Ao Professor Eduardo Carrano pela orientação, disponibilidade e por todo o conhecimento adquirido.

Ao Professor Oriane Magela Neto (em memória) que participou da minha formação acadêmica desde a graduação na UFSJ e me incentivou a seguir a carreira acadêmica. Obrigada pelo apoio, incentivo e orientação.

Aos professores que aceitaram participar da banca da minha defesa de tese.

A todas as pessoas que de alguma forma contribuíram para a realização deste trabalho.

Agradeço ao CNPq pelo apoio financeiro.

Sumário

Lista de Figuras	vii
Lista de Tabelas	ix
Lista de Acrônimos	x
1 Projeto de Redes de Distribuição de Energia	1
1.1 Introdução	1
1.2 Revisão Bibliográfica	7
1.2.1 Aplicação de Algoritmos Evolucionários ao Problema de Redes de Energia Elétrica	7
1.2.2 Planejamento Robusto de Sistemas de Energia	11
1.2.3 Objetivos	14
2 Geração Distribuída	16
2.1 Introdução	16
2.2 Geração Distribuída no Brasil	18
2.2.1 Oportunidades	18
2.2.2 Barreiras	20
3 Formulação do Problema de Redes de Distribuição de Energia Elétrica	21
3.1 Representação das variáveis	21
3.1.1 Grafos	21
3.1.2 Árvores	23
3.1.3 Representação das Variáveis	24
3.1.4 Representação das Subestações / Unidades de Geração	24
3.2 Formulação dos Problemas Mono e Multiobjetivo de Redes de Distribuição de Energia Elétrica	25
3.2.1 Formulação Geral do Problema Mono-objetivo	25
3.2.2 Formulação Geral do Problema Multiobjetivo	28
4 Otimização e Computação Evolucionária	31
4.1 Conceitos Relevantes ao Trabalho	31

4.2	Algoritmos Evolucionários	36
4.2.1	Algoritmos Genéticos	37
5	Algoritmo Proposto para o Projeto de Redes de Distribuição de Energia Elétrica	51
5.1	Modelos para Descrição das Variáveis Incertas	51
5.1.1	Modelo de Crescimento da Carga	51
5.1.2	Modelo de Variação do Preço da Energia	52
5.1.3	Distribuição de Probabilidade Conjunta das Variáveis Incertas	53
5.1.4	Modelo de Variação da Potência Produzida pela Unidade de Geração de Energia Eólica	54
5.1.5	Simulação de Monte Carlo	55
5.2	Algoritmos Propostos	55
5.2.1	AG Mono-objetivo	55
5.2.2	AG Multiobjetivo	56
5.3	Operadores Específicos Propostos	57
5.3.1	Operador de Atribuição da Capacidade de Condutores	58
5.3.2	Operador de Aprimoramento dos Custos	60
5.3.3	Operador de Aprimoramento da Robustez	61
5.3.4	Operador de Aprimoramento da Confiabilidade	64
5.4	Operador para Posicionamento de Unidades de Geração	66
5.5	Ferramenta de Planejamento de Sistemas de Distribuição	74
6	Resultados e Discussão	76
6.1	Planejamento Multiobjetivo de Redes Confiáveis e Robustas	77
6.1.1	Sistema de 21 nós	77
6.1.2	Sistema de 100 nós	83
6.1.3	Sistema de 300 nós	84
6.2	Ajuste da resolução r e definição do método de posicionamento de subestação/unidade de geração a ser adotado	89
6.2.1	Ajuste da Resolução r	90
6.2.2	Definição do método de posicionamento de subestação/unidade de geração a ser adotado	92
6.3	Comparação de resultados obtidos pelo método proposto com resultados obtidos na literatura	97
6.4	Aplicação da Ferramenta de Planejamento de Sistemas de Distribuição de Energia Elétrica no Projeto Multiobjetivo de Redes Considerando o Posicionamento de Novas Unidades de Geração de Energia Eólica	99
6.4.1	Sistema de 49 nós de carga	101
6.4.2	Análise de Resultados	104

7	Conclusões e Propostas de Continuidade	106
7.1	Conclusões	106
7.2	Propostas de Continuidade	108
	Referências Bibliográficas	109

Lista de Figuras

1.1	Estrutura da oferta interna de eletricidade no Brasil - 2012. Fonte: Adaptado de Balanço Energético Nacional 2013 (Ministério de Minas e Energia, 2013).	2
3.1	Exemplo de grafo.	22
3.2	Grafo completo para o grafo da Figura 3.1	22
3.3	Exemplo de árvore.	23
4.1	Cálculo da <i>crowding distance</i> . Os pontos marcados por círculos cheios pertencem ao mesmo <i>front</i>	49
5.1	Operador de atribuição da capacidade de condutores.	60
5.2	Operador de aprimoramento dos custos.	62
5.3	Operador de aprimoramento da robustez.	64
5.4	Operador de aprimoramento da confiabilidade.	66
5.5	Três regiões factíveis disjuntas e suas posições candidatas.	73
5.6	Escolhendo a posição candidata mais próxima para posicionar a unidade de geração.	73
5.7	Exemplo de possíveis regiões para localização de unidade de geração quando existem acidentes geográficos.	74
6.1	Sistema de 20 nós de carga.	78
6.2	Sistema de 21 nós – Conjuntos de soluções finais obtidos para o sistema de 21 nós.	80
6.3	Sistema de 21 nós – Exemplo de soluções da Tabela 6.4.	82
6.4	Sistema de 100 nós – Conjuntos de soluções finais obtidos para o sistema de 100 nós.	84
6.5	Sistema de 100 nós – Exemplo de soluções da Tabela 6.5.	85
6.6	Sistema de 300 nós – Conjuntos de soluções finais obtidos para o sistema de 300 nós.	86
6.7	Sistema de 300 nós – Exemplo de soluções da Tabela 6.6.	88
6.8	Sistema real com 7 nós de carga.	91
6.9	Sistema de 7 nós de carga - comparação com resultados da literatura.	98

6.10	Sistema de 49 nós de carga - comparação com resultados da literatura.	98
6.11	Soluções encontradas antes e depois da aplicação dos operadores - Situação 1 - Primeira execução - Sistema de 49 nós de carga.	102
6.12	Sistema de 49 nós de carga – Situação 1 – Primeira execução.	103
6.13	Soluções encontradas antes e depois da aplicação dos operadores - Situação 2 - Primeira execução - Sistema de 49 nós de carga.	103
6.14	Sistema de 49 nós de carga – Situação 2 – Primeira execução.	104

Lista de Tabelas

1.1	Produção de eletricidade e consumo no Brasil em 2003 e 2012 (em GWh).	2
1.2	Produção de energia hidráulica e eólica no Brasil de 2003 a 2012 (em GWh).	5
5.1	Operadores desenvolvidos no algoritmo genético mono-objetivo.	56
6.1	Parâmetros da distribuição de probabilidade.	78
6.2	Parâmetros utilizados no algoritmo NSGA-II.	79
6.3	Características dos condutores utilizados nas conexões.	79
6.4	Sistema de 21 nós – Desempenho das redes destacadas na Figura 6.2(a).	81
6.5	Sistema de 100 nós – Desempenho das redes destacadas na Figura 6.4(a) (primeira execução).	84
6.6	Sistema de 300 nós – Desempenho das redes destacadas na Figura 6.6(a) (primeira execução).	87
6.7	Características dos condutores – Sistema de 7 nós de carga.	91
6.8	Parâmetros estatísticos das simulações para os métodos A e B.	97
6.9	Características dos condutores utilizados nas conexões.	101
6.10	Sistema de 49 nós de carga – Situação 1 – Primeira execução.	102
6.11	Sistema de 49 nós de carga – Situação 2 – Primeira execução.	104

Lista de Acrônimos

A: conjunto de arestas de um grafo

a: uma aresta do conjunto *A*

AE: algoritmo evolucionário

AG: algoritmo genético

BEN: Balanço Energético Nacional

BTS: Binary Tournament Selection

BFGS: Broyden-Fletcher-Goldfarb-Shanno

CBGA: Chu-Beasley Genetic Algorithm

CSA-DN: Clonal Selection Algorithm for Distribution Networks

FCM: fuzzy C-means

f^{fc} : função custo de faltas da rede

f^{mc} : função custo monetário da rede

G: grafo

G_c : grafo completo

GD: geração distribuída

m: número de arestas de um grafo

M_A : matriz de adjacência de um grafo

MOGA: Multiobjective Optimization Genetic Algorithm

n: número de nós de um grafo

NSGA: Nondominated Sorting Genetic Algorithm

NSGA-II: Nondominated Sorting Genetic Algorithm II

PAES: Pareto-archived Evolution Strategy

PESA-II: Region-based Selection in Evolutionary Multiobjective Optimization

PSO: Particle Swarm Optimization

r: parâmetro de resolução

RMSLS: random-multi start local search

RWS: Roulette Wheel Selection

SPEA: Strength Pareto Evolutionary Algorithm

SPEA2: Strength Pareto Evolutionary Algorithm 2

SUS: Stochastic Universal Sampling

t_c: tipos de cabos disponíveis para se fazer as conexões entre os nós da rede

TS: Tournament Selection

UG: unidade de geração

VEGA: Vector Evaluated Genetic Algorithm

V: conjunto de vértices de um grafo

Capítulo 1

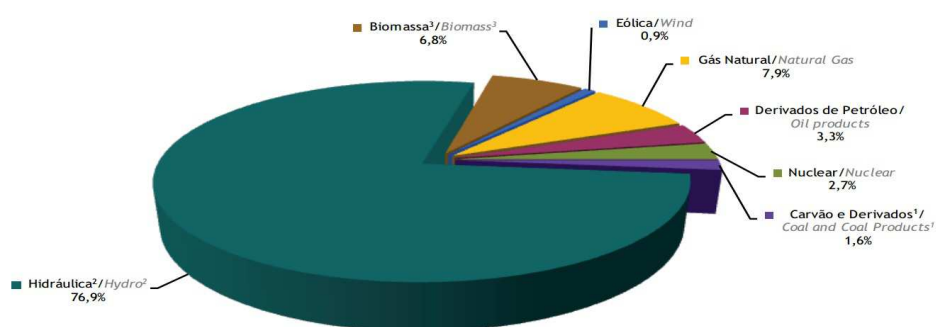
Projeto de Redes de Distribuição de Energia

1.1 Introdução

A grande utilização de técnicas de otimização no projeto de sistemas de energia deve-se a ampla importância econômica e social destes. De acordo com o Balanço Energético Nacional (BEN) 2013 (Ministério de Minas e Energia, 2013) a geração de energia elétrica no Brasil atingiu 552,5TWh em 2012. A Figura 1.1 mostra a estrutura da oferta interna de eletricidade no Brasil no ano de 2012. De acordo com dados da Sinopse do Censo Demográfico 2010 (IBGE, 2010), 98,73% dos domicílios brasileiros possuem energia elétrica. O Programa Luz para Todos alcançou em 2009 a meta inicial de atender 10 milhões de pessoas e, até março de 2012, o programa já chegou para cerca de 14,4 milhões de moradores rurais (Ministério de Minas e Energia, 2012).

A Tabela 1.1 mostra a evolução de alguns dados referentes a eletricidade no Brasil, como produção, consumo e perdas nos anos de 2003 e 2012. Estes dados foram obtidos em Ministério de Minas e Energia (2013). O sinal negativo nos valores indica energia não consumida dentro do país.

O sistema elétrico é dividido em geração, transmissão e distribuição. O sistema de distribuição liga o sistema de transmissão aos consumidores finais. As redes de distribuição, que constituem o foco central desse trabalho, são a parte mais ramificada



Notas: 1-inclui gás de coqueria; 2-inclui importação de eletricidade; 3-biomassa inclui lenha, bagaço de cana, lixo e outras recuperações.

Figura 1.1: Estrutura da oferta interna de eletricidade no Brasil - 2012. Fonte: Adaptado de Balanço Energético Nacional 2013 (Ministério de Minas e Energia, 2013).

Tabela 1.1: Produção de eletricidade e consumo no Brasil em 2003 e 2012 (em GWh).

	2003	2012
Produção	364.340	552.498
Importação	37.151	40.722
Exportação	-6	-467
Variação de estoques, perdas e ajustes	-59.272	-94.355
Consumo total	342.213	498.398
Consumo por setor		
Setor energético	12.009	26.350
Residencial	76.143	117.646
Comercial	48.375	79.809
Público	29.707	39.919
Agropecuário	14.283	23.268
Transportes	980	1.785
Industrial	160.716	209.622

do sistema elétrico, o que faz com estas sejam as principais responsáveis por perdas técnicas e falhas (Ćurčić et al., 2001).

De acordo com o BEN 2013 (Ministério de Minas e Energia, 2013), a energia consumida no setor industrial brasileiro cresceu 0,11% em 2012 em relação ao ano de 2011. A energia dedicada ao setor residencial manteve a tendência de crescimento de 5,07% e os demais setores (comercial, agropecuário, público e transportes) apresentaram variação

positiva de 6,94% quando analisados em bloco. Isso faz com que o sistema elétrico, e conseqüentemente a rede de distribuição, deva ser constantemente expandido ou re-projetado (Carrano et al., 2005; Miranda et al., 1994; Carvalho et al., 1998). Este tipo de comportamento pode conduzir a duas situações indesejáveis:

- Se o sistema de energia é projetado para uma carga sub-estimada, este se tornará incapaz de atender a demanda em um curto intervalo de tempo, sendo necessária uma nova expansão. Neste caso o investimento necessário para se fazer a expansão somado ao investimento inicial para instalação da rede é sempre maior que o investimento necessário caso a rede final fosse instalada a priori.
- Por outro lado, se uma carga super-estimada é considerada no projeto da rede, pode-se ter um sistema excessivamente caro e que trabalha com alto nível de capacidade ociosa.

Portanto, o projeto de redes de distribuição de energia elétrica deve levar em conta não apenas a carga atual conectada a rede, mas a carga para um dado período de tempo futuro. Isso significa que o projeto possui incertezas intrínsecas, já que as cargas futuras não podem ser estimadas com exatidão (Willis and Northcode-Green, 1983; Morsi et al., 1994).

O projeto de redes de distribuição de energia é definido como um problema de otimização combinatória não-linear (Willis et al., 1996; Carrano et al., 2006). O problema consiste em encontrar a topologia e os condutores utilizados em cada conexão. Isto é feito obedecendo à restrições técnicas como: manutenção da estrutura radial da rede, atendimento integral da demanda, manutenção dos níveis de tensão nos nós de carga e obediência dos limites de corrente das linhas.

Devido às características do problema, restringem-se consideravelmente as classes de algoritmos que podem ser utilizados em sua solução. Algoritmos enumerativos (Branch-and-Bound, Branch-and-Cut, etc) (Vanderbei, 2001), apesar de aplicáveis, geralmente não são úteis em instâncias de porte real, devido a sua complexidade computacional

exponencial. Com isso, os métodos heurísticos despontam como alternativas viáveis para tratar estes problemas. Dentre esses algoritmos, vale ressaltar as técnicas evolucionárias, amplamente aplicadas em problemas relacionados as redes de energia elétrica. Alguns trabalhos que utilizam algoritmos evolucionários (AEs) aplicados ao problema de redes de energia elétrica são citados na Seção 1.2.

Com o crescente aumento das cargas conectadas ao sistema de energia, surge a preocupação de o sistema não ser mais capaz de atender toda a demanda. Em locais onde o sistema já se encontra sobrecarregado, uma alternativa é a inserção da Geração Distribuída (GD). A geração distribuída utiliza unidades de menor capacidade espalhadas ao longo do sistema, com o intuito de atender as cargas a menores distâncias (Dugan et al., 2003). O avanço presente na tecnologia e o desejo dos consumidores de terem acesso a uma energia mais confiável e mais barata levou a um aumento no interesse por este tipo de tecnologia (Singh et al., 2009). As unidades de GD são geralmente baseadas em energias renováveis, o que contribui para redução do impacto ambiental. Além disso, para o caso específico do Brasil, a inserção da GD pode reduzir a dependência dos recursos hidráulicos para geração de energia e evitar racionamentos como os ocorridos em 2001 (Dias et al., 2005). A Tabela 1.2 mostra a produção de energia hidráulica e eólica nos anos de 2003 a 2012 no Brasil (Ministério de Minas e Energia, 2013). De acordo com os dados apresentados, pode-se perceber o atual crescimento na produção de energia eólica no Brasil. Do ano de 2003 até o ano de 2005 não houve significativo aumento. Em contrapartida, entre 2005 e 2012, o aumento foi considerável. Estes dados mostram que o interesse pela geração de energia mediante fontes alternativas tem ganhado espaço no país. A produção de energia hidráulica teve aumento de aproximadamente 35.9% de 2003 a 2012.

Com a incorporação da GD no sistema de energia há uma postergação de investimentos que seriam necessários para a construção de novas subestações ou de grandes centrais de geração. Além disso, o impacto ambiental ocasionado pela construção de grandes unidades de geração é evitado.

Tabela 1.2: Produção de energia hidráulica e eólica no Brasil de 2003 a 2012 (em GWh).

	2003	2004	2005	2006	2007
Hidráulica	305.616	320.797	337.457	348.805	374.015
Eólica	61	61	93	237	663
	2008	2009	2010	2011	2012
Hidráulica	369.556	390.988	403.290	428.333	415.342
Eólica	1.183	1.238	2.177	2.705	5.050

No presente trabalho propõe-se o desenvolvimento de um algoritmo baseado no Non-dominated Sorting Genetic Algorithm II (NSGA-II) (Deb et al., 2002) para planejar a estrutura da rede de distribuição. Este planejamento é feito tendo em conta um cenário “mais provável” de carga em um horizonte de projeto dado a priori. O cenário “mais provável” é calculado considerando o crescimento anual esperado para a carga. O processo de otimização é feito levando em conta a minimização de *i*) custos monetários da rede e *ii*) custos de faltas da rede (confiabilidade). As incertezas das cargas são modeladas por funções de distribuição de probabilidade que descrevem o crescimento da carga e a variação do preço da energia em cada nó. Um procedimento de busca local determinística é aplicado a posteriori, com o objetivo de aumentar a confiabilidade e robustez das soluções. Os resultados obtidos são comparados com os resultados obtidos em Tarôco et al. (2010).

Em um segundo momento do trabalho, propõe-se o estudo de técnicas para planejamento da ampliação da capacidade de atendimento de clientes. Neste caso, deve-se acrescentar à topologia da rede um novo conjunto de variáveis de decisão, que são as coordenadas geográficas de novas unidades de geração. Estas variáveis se justificam pela eventual necessidade de se instalar novas unidades de geração para garantir o atendimento dos clientes com índices de qualidade e confiabilidade aceitáveis.

As unidades de geração acima mencionadas podem ser subestações ou unidades de geração de baixa capacidade, comumente utilizadas na geração distribuída (GD). A incorporação de novas unidades de GD tornam o sistema mais confiável e robusto, uma vez que permitem:

- suprir uma determinada área que deve ser desconectada do sistema principal devido à ocorrência de uma falha (micro-redes);
- atender clientes muito distantes dos centros consumidores, sem a necessidade de instalação de longas linhas de transmissão;
- descongestionar a rede em regiões sobrecarregadas;
- reduzir os custos de atendimento em horários de pico ou em períodos de aumento de demanda.

Com o intuito de tornar o algoritmo já citado apto para expansão da capacidade de geração, são propostos quatro mecanismos locais de alocação das unidades de geração. Estes mecanismos discretizam as regiões candidatas em conjuntos de pontos e procuram o ponto (ou os pontos) mais adequado para implantação de uma nova unidade de geração, tendo em conta a minimização dos custos de instalação e perdas. Quando comparada à Carrano et al. (2005) e Carrano et al. (2007b), este tipo de abordagem apresenta algumas vantagens:

- reduz o tempo computacional necessário para execução do método, uma vez que o posicionamento das unidades pode ser realizado dentro do algoritmo evolucionário, sem a necessidade de execuções iterativas;
- permite o posicionamento de múltiplas unidades de geração simultâneas;
- torna possível tratar regiões disjuntas de instalação das unidades de geração.

Os quatro mecanismos propostos para alocação de unidades de geração foram testados em sistemas de 7, 20 e 99 nós de carga considerando a versão mono-objetivo do AG proposto, onde é feita a minimização do custo monetário da rede para um horizonte de tempo de 10 anos. Os resultados obtidos nestes testes foram utilizados para determinação do método de posicionamento de novas unidades de geração a ser utilizado nos testes finais.

Foram obtidos resultados para sistemas de 7 e 49 nós de carga utilizando a versão mono-objetivo do algoritmo proposto e posicionamento de 1 subestação para comparação com resultados obtidos em Carrano et al. (2005). Neste caso não foram analisadas robustez e confiabilidade das redes obtidas.

Para obtenção dos testes finais, o procedimento de busca local determinística desenvolvido na primeira etapa do trabalho, sendo este composto por três operadores: *i*) operador de aprimoramento dos custos, *ii*) operador de aprimoramento da robustez e *iii*) operador de aprimoramento da confiabilidade, foi agrupado com o mecanismo para alocação de novas unidades de geração desenvolvido, dando origem à uma ferramenta de planejamento de sistemas de distribuição capaz de obter redes robustas, confiáveis e menos onerosas. A versão multiobjetivo do algoritmo genético proposto foi utilizada e testes foram feitos para o sistema de 49 nós de carga para o posicionamento de 1 e 2 novas unidades de geração de energia eólica. Nestes testes foram consideradas como variáveis incertas o crescimento da carga, a variação no preço da energia e a variação na potência produzida pela turbina eólica.

1.2 Revisão Bibliográfica

1.2.1 Aplicação de Algoritmos Evolucionários ao Problema de Redes de Energia Elétrica

Como já mencionado anteriormente, os algoritmos evolucionários são uma boa alternativa na resolução de problemas de rede devido à sua flexibilidade e robustez. São algoritmos que não dependem de premissas matemáticas como linearidade, convexidade ou diferenciabilidade, além de serem de fácil implementação computacional. Somado a estas vantagens, ainda pode-se citar sua vasta utilização na literatura para solução de problemas de redes. Alguns trabalhos que utilizam estes algoritmos para a solução de problemas envolvendo o sistema de energia são citados ao longo dos próximos parágrafos.

No trabalho de Miranda et al. (1994) é proposto um algoritmo genético para resolver o problema de planejamento multi-estágio de redes de distribuição. O período de planejamento é dividido em estágios e uma carga de pico é considerada para cada estágio. O projeto é feito para cada estágio por vez e o algoritmo fornece um conjunto de decisões de investimento em ordem cronológica.

Um algoritmo genético modificado é proposto em Su and Lii (2002) para determinar os índices ótimos de confiabilidade dos componentes de um sistema de distribuição. Os índices de confiabilidade considerados são taxa de falha e duração das interrupções. A função objetivo a ser minimizada é o custo anual que inclui os investimentos em componentes do sistema e os custos causados por interrupções.

O algoritmo Ant Colony System (Dorigo and Gambardella, 1997) é utilizado no projeto de redes de distribuição de energia em Gómez et al. (2004). O problema é tratado como sendo um problema não linear inteiro. O processo de otimização é feito considerando a minimização dos custos de instalação e operação.

No trabalho de Parada et al. (2004) é utilizado o algoritmo Simulated Annealing (Kirkpatrick et al., 1983) no projeto de redes de distribuição. A função objetivo engloba os custos referentes à subestações, alimentadores e perdas. A solução do problema é obtida resolvendo dois sub-problemas: P_1 , que é um problema de árvore geradora mínima, e P_2 , que é um problema de fluxo de potência.

Em Carrano et al. (2005) são utilizados um algoritmo genético e um algoritmo quasi-Newton BFGS para resolver o problema da expansão de uma rede de distribuição de energia elétrica. O algoritmo BFGS encontra a posição da subestação considerando fixa a topologia da rede e o algoritmo genético é utilizado para encontrar a topologia da rede considerando a posição da subestação fixa. O processo de otimização é feito para a minimização do custo monetário da rede. Resultados são obtidos para um sistema de distribuição real com 8 nós e para um sistema fictício com 50 nós. Uma extensão multiobjetivo desse algoritmo é proposta em Carrano et al. (2007b). O processo de otimização é feito considerando a minimização do custo monetário da rede e a minimização

dos custos de falta da rede. A estimação do conjunto Pareto é feita associando as técnicas P_λ e P_ϵ . Resultados são obtidos para o mesmo sistema real de 8 nós considerado em Carrano et al. (2005).

O projeto de circuitos de distribuição secundários é formulado como um problema de programação não linear inteiro em Cossi et al. (2005). Para resolver este problema é proposto um algoritmo genético desenvolvido para considerar as características específicas do planejamento de redes secundárias. A função objetivo considera os custos de substituição de condutores, posição de transformadores, balanço de carga e perdas. Um algoritmo de fluxo de potência trifásico é utilizado para avaliar estas grandezas.

Em Ramírez-Rosado and Domínguez-Navarro (2006) para resolver o modelo *fuzzy* multiobjetivo para o planejamento ótimo de sistemas de distribuição de energia elétrica (Ramírez-Rosado and Domínguez-Navarro, 2004) é utilizado um algoritmo de Busca Tabu (Reeves, 1993). As funções objetivo são: custo econômico *fuzzy*, nível de confiabilidade *fuzzy* e maximização da robustez. É também considerado o dimensionamento e localização de alguns poucos alimentadores reservas para aumentar a confiabilidade do sistema. O conceito de vizinhança é utilizado, segundo o qual uma rede vizinha é aquela na qual movimentos específicos são feitos como a adição de uma subestação, a mudança da capacidade da subestação ou a mudança no tamanho do alimentador.

O trabalho apresentado em Silva et al. (2006) considera o planejamento da expansão de uma rede de transmissão com incertezas nas demandas, sendo estas representadas por intervalos. O processo de otimização é feito para a minimização dos custos de instalação de novas linhas. Dois modelos distintos são utilizados: o primeiro considera a incerteza do sistema de potência como um todo e o segundo considera a incerteza de cada barra de carga individualmente. O algoritmo CBGA (Chu-Beasley Genetic Algorithm) (Chu and Beasley, 1997) é usado para resolver o problema. Este algoritmo possui algumas particularidades, como: *i*) utiliza uma função de *unfitness* que quantifica a infactibilidade da solução; *ii*) substitui somente um indivíduo a cada iteração; *iii*) possui uma estratégia de melhoria local para cada indivíduo testado.

O Strength Pareto Evolutionary Algorithm (SPEA) (Zitzler and Thiele, 1999) é utilizado no projeto multiobjetivo de sistema de distribuição de energia em Mendoza et al. (2006). As funções objetivo são a minimização dos custos totais da rede e a maximização da confiabilidade do sistema. As soluções encontradas representam a topologia da rede incluindo os alimentadores reserva. O algoritmo FCM (Fuzzy C-Means) (Bezdek et al., 1999) é usado juntamente com o algoritmo SPEA para reduzir a dimensão do conjunto de soluções não dominadas que é armazenado externamente quando sua dimensão excede o limite especificado.

Em Carrano et al. (2006) o projeto de redes de distribuição de energia é tratado como um problema multiobjetivo onde é feito o processo de otimização tendo como funções objetivo o custo monetário da rede e o custo de falta da rede. É utilizado o algoritmo genético com operadores específicos de cruzamento e mutação. Além da topologia da rede são também encontrados cabos reserva para aumentar a confiabilidade da rede.

O planejamento da expansão de sistemas de distribuição de energia é modelado como um problema dinâmico com variáveis inteiras em Carrano et al. (2008). A expansão do sistema é feita por passos incrementais no tempo. Um algoritmo genético chamado Dynamic Programming Genetic Algorithm (DP-GA) é proposto para resolver o problema. O algoritmo fornece um conjunto de decisões de instalação com o tempo.

No trabalho de Ganguly et al. (2009) o planejamento de redes de distribuição de energia elétrica é feito considerando a minimização dos custos de operação e de instalação da rede e a minimização dos custos de falta da rede. O objetivo é encontrar a melhor topologia para a rede utilizando o algoritmo PSO (Particle Swarm Optimization) (Kennedy and Eberhart, 1995). A solução encontrada pelo algoritmo fornece o número e a localização de cabos reserva na rede, além da topologia em si.

Em Ganguly et al. (2011) o problema de redes de distribuição de energia é resolvido para os casos mono e multiobjetivo. O objetivo é encontrar a topologia da rede e o posicionamento da subestação. No caso mono-objetivo é feita a minimização dos custos de

instalação da rede e perdas de energia considerando o planejamento estático do sistema. No caso multiobjetivo é acrescentada a minimização do total de energia não entregue e o processo de otimização é feito para o problema estático e de expansão do sistema. O algoritmo utilizado é o PSO (Particle Swarm Optimization) (Kennedy and Eberhart, 1995). As soluções fornecem a topologia da rede, o número de alimentadores para cada subestação e a localização da subestação. A robustez da melhor solução encontrada para o caso mono-objetivo é avaliada para um horizonte de tempo futuro considerando taxas de crescimento anual da carga.

No trabalho de Panda and Yegireddy (2013) o algoritmo NSGA-II (Deb et al., 2002) é utilizado para ajustar controladores PI (Proporcional Integral) e PID (Proporcional Integral Derivativo) para o controle automático da geração. Em (Rao and Vaisakh, 2013) um algoritmo de seleção clonal multiobjetivo é utilizado para tratar o problema do despacho ótimo considerando incertezas na carga. Este mesmo problema é tratado no trabalho de Basu (2013) utilizando o algoritmo Artificial Bee Colony (ABC) .

O trabalho de Rivas-Dávalos et al. (2007) mostra uma revisão de trabalhos que utilizam algoritmos evolucionários no projeto multiobjetivo de sistemas de distribuição de energia. De acordo com os autores, os primeiros trabalhos nesta área foram publicados em 1.994. Foi observado que a maior parte destes trabalhos modelaram o problema multiobjetivo com apenas uma função objetivo utilizando funções ponderadas. Grande parte de trabalhos recentes trata o problema em um ambiente multiobjetivo com funções objetivo separadas. Os autores destacam que é irreversível a tendência de se utilizar algoritmos evolucionários multiobjetivo para tratar o problema do projeto de redes de distribuição de energia, já que estes métodos lidam bem com os problemas de rede e superam as limitações geralmente impostas por métodos convencionais.

1.2.2 Planejamento Robusto de Sistemas de Energia

Ao longo dessa seção são citados trabalhos que visam a obtenção de redes de energia robustas a incertezas das variáveis de projeto.

No trabalho de Carvalho et al. (1998) é tratado o problema do planejamento da expansão de redes de distribuição com incertezas. Um conjunto de cenários ponderados representam as características estocásticas de demanda de carga e evolução do custo de investimento. Cada cenário representa uma sequência de possibilidades para um horizonte de tempo discretizado em estágios. Inicialmente, assume-se que, para o primeiro estágio, pode-se prever com boa precisão os parâmetros incertos. Assim, as soluções para os estágios subsequentes terão em comum uma boa solução para o primeiro estágio. Cada cenário tem então mais de um estágio e é considerado como um sub-problema. Uma solução deve ser encontrada para cada um deles.

Nahman and Peric (2003) propõem um método para determinar o grau de incerteza nos cálculos de alguns dados de saída relacionados ao sistema de distribuição: máxima corrente de carga, máxima queda de tensão, perda de energia e índices de confiabilidade. Para isto, os dados de entrada (corrente de pico da demanda de carga, taxa de falha do alimentador por unidade de comprimento, duração da interrupção e tempo para localização da falta) são modelados como variáveis *fuzzy* com funções de pertinência triangulares.

Na referência Carrano et al. (2007a) é tratado o problema da expansão de redes de distribuição de energia considerando incertezas na evolução das cargas. Para encontrar um conjunto de soluções candidatas é aplicado o algoritmo imune inspirado CSA-DN para o cenário de carga “mais provável”. O desempenho das soluções encontradas é avaliado para cenários distintos do mais provável por meio de Simulações de Monte Carlo (Manno, 1999). Uma análise de sensibilidade multiobjetivo é feita para selecionar as soluções mais robustas. Resultados são obtidos para um sistema de 21 nós.

Um algoritmo memético multiobjetivo é utilizado em Mori and Yoshida (2009) para planejamento da expansão de redes de distribuição. O algoritmo usa o operador RMSLS (random-multi start local search) para realizar a busca local. Três funções objetivo devem ser minimizadas: custo de instalação do sistema, perda de potência ativa nos condutores e média de variação de tensão nas barras. Os custos de instalação englobam

novos alimentadores, subestações e unidades de geração. Simulações de Monte Carlo são utilizadas para considerar as incertezas no crescimento da carga em cada nó da rede e a potência de saída dos geradores eólicos.

O algoritmo NSGA-II (Deb et al., 2002) é utilizado em Tarôco et al. (2010) para encontrar soluções robustas no projeto multiobjetivo de redes de distribuição de energia elétrica. Os objetivos considerados são: minimização do custo monetário da rede, minimização do custo de falta da rede (maximização da confiabilidade) e maximização da mínima potência excedente nos condutores (maximização da robustez). O conjunto de soluções factíveis encontrado pelo NSGA-II para o cenário “mais provável” de carga tem seu desempenho avaliado para cenários de carga distintos do “mais provável” utilizando Simulações de Monte Carlo. São consideradas incertezas na evolução da carga e no custo da energia para cada nó. As soluções mais robustas são obtidas em uma análise de sensibilidade multiobjetivo. Estas soluções são submetidas a um algoritmo de busca local para encontrar o conjunto final de soluções eficientes e robustas. Os resultados obtidos são comparados com Souza (2007).

Em Souza et al. (2011), a mesma abordagem proposta em Carrano et al. (2007a) é seguida. É feita uma melhoria do algoritmo através do desenvolvimento de operadores de busca local. Essa alteração leva à obtenção de redes de distribuição mais robustas com custos de instalação mais baixos.

No trabalho de Wang et al. (2011) é proposto o Balanced Genetic Algorithm (BGA) para resolver o problema da expansão multi-estágio de sistemas de energia. Após o processo de otimização, o MDEA (modified data envelopment analysis) é utilizado para avaliar o desempenho de cada plano para diferentes cenários de incerteza. O algoritmo é baseado em três operações: (i) construção de planos de expansão, (ii) avaliação destes planos considerando incertezas (possíveis cenários distintos) e (iii) seleção da melhor estratégia.

Em Martins and Borges (2011) o planejamento da expansão de redes de distribuição é tratado onde a inserção da geração distribuída é considerada em conjunto com téc-

nicas convencionais de expansão. É feita uma otimização multiobjetivo considerando confiabilidade, perda de energia, energia importada da rede de transmissão e custos de investimento, utilizando um algoritmo genético. São levadas em conta incertezas na demanda e na energia fornecida pelas unidades da geração distribuída. Duas abordagens são utilizadas para agregar os resultados obtidos em múltiplos cenários possíveis das variáveis aleatórias: *i*) na primeira abordagem, o algoritmo genético é utilizado para encontrar uma alternativa de expansão para cada cenário, sendo associada ao cenário uma probabilidade de ocorrência. Após a obtenção de todas as soluções, é realizado um processo de decisão, que busca a alternativa mais adequada ao problema. *ii*) na segunda abordagem, o algoritmo genético é executado apenas uma vez, considerando todos os cenários gerados, cada um com sua probabilidade de ocorrência. Nos testes realizados a segunda metodologia mostrou melhores soluções.

1.2.3 Objetivos

Esta tese de doutorado se fundamenta no seguinte objetivo principal:

Construir uma ferramenta de planejamento da instalação e expansão de sistemas de distribuição de energia elétrica que seja capaz de:

- projetar a estrutura da rede (topologia) assim como definir o tipo e capacidade dos condutores utilizados em cada conexão;
- posicionar novas unidades de geração e subestações para ampliação da capacidade de atendimento de clientes;
- alocar e especificar unidades de geração distribuída ao longo do sistema;
- estudar o impacto da inserção de unidades de geração distribuída no sistema de distribuição de energia elétrica.

Todos estes aspectos devem ser tratados em um ambiente multiobjetivo, considerando o custo total de instalação e operação do sistema, assim como sua confiabilidade. Por fim,

as soluções oferecidas ao projetista devem ser robustas a eventuais incertezas existentes nos parâmetros de entrada do problema (carga, disponibilidade de geração, etc).

Pretende-se ainda alcançar os seguintes objetivos específicos:

- desenvolver ferramentas de busca local determinística para melhoria do custo, confiabilidade e robustez das soluções candidatas;
- propor mecanismos de baixo custo para posicionamento de subestações/unidades de geração no sistema de distribuição de energia elétrica;
- fazer um estudo sobre os impactos ocasionados pela inserção da geração distribuída no sistema de distribuição de energia, especialmente no que tange à confiabilidade e robustez do sistema;
- dimensionar e alocar unidades de geração distribuída no sistema de distribuição;
- fazer uma revisão bibliográfica sobre os temas relacionados ao projeto.

Capítulo 2

Geração Distribuída

2.1 Introdução

A geração distribuída (GD) utiliza geradores de baixa capacidade de geração, distribuídos ao longo do sistema elétrico, com o intuito de atender as cargas a uma menor distância (Dugan et al., 2003). A GD tem um potencial interessante para melhoria do sistema de distribuição, devido ao seu menor custo, pequeno tamanho / alta modularização, benefício ambiental e redução das perdas e dos investimentos necessários para suprir o aumento de carga (Haghifam and Hadian, 2010). Sua utilização no sistema de distribuição tem aumentado consideravelmente nos últimos anos (Haghifam and Hadian, 2010).

O conceito de baixa potência empregado na GD varia de autor para autor. Segundo Dugan et al. (2003), devem ser empregados na GD geradores com capacidade inferior a 10MW. Já para Dias et al. (2005), a geração distribuída no Brasil é definida por unidades de geração de até 50MW.

Originalmente, os sistemas de energia elétrica eram constituídos de pequenos geradores, configurados em ilhas isoladas (Dugan et al., 2003). Com o passar do tempo a geração foi então para longe dos centros urbanos para que a geração ficasse próxima às fontes utilizadas na geração (Dugan et al., 2003). Recentemente, a implantação da geração distribuída tem conferido ao sistema um perfil semelhante ao visto no passado

e tem permitido lidar com os crescimentos contínuos de carga de forma adequada.

De acordo com Dugan et al. (2003), os benefícios da geração distribuída podem ser analisados sob três perspectivas:

1. Consumidores finais: os consumidores podem se beneficiar com a existência de um *backup* de geração que, por sua vez, melhora a confiabilidade do sistema. Além disso, os consumidores podem ser remunerados pela comercialização de parte da sua capacidade de geração de energia.
2. Sistema de energia: a instalação de unidades de GD pode reduzir a necessidade de intervenções de expansões no sistema para lidar com o aumento de carga. Ainda que essas instalações sejam necessárias futuramente, a instalação da GD pode postergar estes investimentos, o que reduz seu valor presente.
3. Comerciantes de energia: as unidades de GD podem ser conectadas diretamente ao sistema de energia ou ainda atender cargas ainda desconectadas. Este tipo de vantagem permite atenuar as perdas técnicas e reduzir os custos necessários para atendimento de clientes em áreas de difícil acesso.

Ainda segundo (Dugan et al., 2003), algumas tecnologias merecem maior destaque no contexto da geração distribuída:

1. Turbinas de combustão: as turbinas de combustão comumente utilizadas na co-geração possuem capacidades entre 1MW e 10MW (unidades de maior capacidade são normalmente conectadas ao sistema de transmissão). Nesses equipamentos, o gás natural é o combustível mais comum, embora combustíveis líquidos também sejam utilizados. Recentemente também têm sido utilizadas mini e micro-turbinas, consideravelmente mais compactas, e com capacidades nas casas de 300 – 400kW e 30 – 75kW respectivamente.
2. Células combustível: as células combustível são unidades de geração silenciosas que não apresentam emissões nocivas ao meio ambiente durante seu funcionamento. Estes equipamentos são basicamente baterias dotadas de um processo

eletromecânico baseado na conversão do hidrogênio. É gerada corrente contínua (CC), sendo necessário o uso de inversores. Além disso, o custo da tecnologia é alto.

3. Turbinas eólicas: as turbinas eólicas têm capacidade de geração entre 700 – 1200kW e são geralmente agrupadas em “fazendas eólicas” para criar bancos que variam de 200 a 500MW. Devido às restrições geográficas e às potências envolvidas, são geralmente conectadas ao sistema de transmissão de energia.
4. Células fotovoltaicas: as células fotovoltaicas são geralmente utilizadas junto com bancos de bateria para atendimento de clientes de difícil acesso. A capacidade de cada unidade empregada para fins residenciais varia entre 2 e 6kW. O custo de instalação é alto, além de ser necessária a instalação de inversores devido a geração CC.

2.2 Geração Distribuída no Brasil

A implantação em larga escala da geração distribuída no Brasil traz oportunidades ao mesmo tempo que enfrenta barreiras, como discutido na sequência (Dias et al., 2005):

2.2.1 Oportunidades

Postergação de investimentos

O crescimento da carga conectada ao sistema de energia faz com que novos equipamentos tenham que ser instalados para aliviar a sobrecarga. Se isto não for feito, o risco de ocorrência de falhas aumenta consideravelmente, o que compromete a confiabilidade do sistema e aumenta os custos de operação e manutenção.

A instalação de GD em determinados pontos alivia a sobrecarga do sistema, possibilitando à concessionária postergar investimentos destinados à compra de novos equipamentos e construção de subestações e alimentadores.

Redução de perdas

As perdas de energia que ocorrem quando a energia é transmitida por meio dos sistemas de transmissão e distribuição podem ser significativas, especialmente sob condições de sobrecarga. A inclusão de GD encurta o percurso até o cliente, o que reduz os custos decorrentes das perdas técnicas. Essa redução pode ser utilizada para aumento da margem de lucro ou para adquirir maior competitividade de mercado.

Confiabilidade

A instalação da geração distribuída tem potencial de:

- aumentar a qualidade da energia e garantir fornecimento sem interrupções;
- contribuir para a melhoria da qualidade de energia em áreas congestionadas e em locais estrategicamente (ou economicamente) relevantes;
- evitar longos períodos de interrupção de atendimento de energia.

Atendimento a cargas distantes e comunidades isoladas

Em alguns casos, a construção de linhas de transmissão em determinados locais não é uma tarefa fácil nem barata. Assim, áreas isoladas podem se beneficiar com a instalação de unidades de geração distribuída. A GD pode também contribuir com a melhora no perfil de tensão nos nós de carga localizadas nas extremidades da rede de distribuição.

Redução de áreas alagadas

A instalação da geração distribuída para lidar com o aumento de carga reduziria a necessidade de construção de novas usinas, reduzindo o impacto ambiental e social relativo às áreas alagadas.

Micro-redes / Ilhas de operação

Unidades de GD podem ser instaladas em determinadas áreas para atender a demanda caso ocorra uma falta e a subestação não mais possa fornecer energia para esta área.

2.2.2 Barreiras

Custo das tecnologias

O custo ainda alto das tecnologias utilizadas na GD tem freado o seu desenvolvimento no Brasil. Quando comparados ao custo da energia gerada por meios hídricos, os custos de instalação e operação destas tecnologias ainda é alto. No entanto, espera-se que estes custos reduzam com o tempo, devido ao uso cada vez mais intenso desses equipamentos.

Procedimentos de operação e proteção

A inserção da geração distribuída dá origem à fluxos de energia bidirecionais e pode gerar redes em anel. O sistema de proteção normalmente adotado deve ser modernizado para lidar com este tipo de situação.

Poluição sonora

Uma central de co-geração constituída de turbinas a gás por exemplo, pode gerar grande ruído em seu entorno. Se o valor deste ruído em decibéis ultrapassar o valor permitido, a instalação de sistemas de atenuação de ruído será necessária, o que irá aumentar o custo da instalação.

Emissão de poluentes

A queima de combustíveis em turbinas de combustão, por exemplo, causa a emissão de poluentes ao meio ambiente, podendo necessitar de licenciamento ambiental.

Capítulo 3

Formulação do Problema de Redes de Distribuição de Energia Elétrica

3.1 Representação das variáveis

3.1.1 Grafos

Um grafo $G(V, A)$ é definido como um conjunto finito V de vértices (ou nós), um conjunto finito A de arestas (ou conexões) e uma matriz de adjacência M_A , que associa a cada aresta $a \in A$ um par não ordenado de vértices de V (não necessariamente distintos), chamados de extremos de a (Bondy and Murty, 1976; Wilson, 1996). A Figura 3.1 mostra um exemplo de grafo não-direcional, $G(V, A)$, com seis vértices dados por $V = [1, 2, 3, 4, 5, 6]$ e dez arestas representadas por $A = [a, b, c, d, e, f, g, h, i, j]$.

O grafo completo, que é constituído por todas as possíveis arestas entre os vértices, indica o espaço de busca para o problema de otimização de redes. O grafo completo (G_c) para o conjunto de vértices da Figura 3.1 é mostrado na Figura 3.2. O número de arestas (m) e a matriz de adjacência (M_A) associados a este grafo são dadas pelas Equações (3.1) e (3.2). O número de nós do grafo é dado por n .

O sistema de distribuição de energia elétrica, que é o objeto de estudo deste trabalho, é representado por grafos estruturados como árvores, com arestas não-direcionadas e sem realimentação dos nós. Cada nó do grafo representa um nó de carga do sistema de

distribuição de energia e cada aresta representa a conexão existente entre dois nós do sistema. O projeto de redes de distribuição de energia elétrica consiste em buscar uma árvore que seja sub-grafo de G_c e atenda às restrições técnicas do problema ao mesmo tempo que otimiza um ou mais critérios de projeto.




Figura 3.1: Exemplo de grafo.




Figura 3.2: Grafo completo para o grafo da Figura 3.1

$$m = \frac{n(n-1)}{2} \tag{3.1}$$

$$M_A = \begin{cases} a_{ii} = 0 \\ a_{ij} = 1 \forall i \neq j \end{cases} \quad i, j = 1, \dots, n \tag{3.2}$$

3.1.2 Árvores

Um grafo $G(V, A)$ qualquer pode ser definido como uma árvore, se e somente se, G é um grafo conexo sem ciclos (Figura 3.3). Alguns teoremas importantes sobre árvores são transcritos abaixo:




Figura 3.3: Exemplo de árvore.

Teorema 3.1 *Existe um e apenas um caminho entre qualquer par de vértices em uma árvore.*

Teorema 3.2 *Uma árvore com n vértices possui $n - 1$ arestas.*

As demonstrações desses teoremas podem ser encontradas em (Narsingh, 1984). A remoção ou adição de um ramo em uma árvore faz com que ela deixe de ser árvore, uma vez que o grafo resultante é desconexo ou contém ciclos após a operação. O Teorema de Cayley (1889) (Teorema 3.3) também é extremamente relevante para a otimização de grafos.

Teorema 3.3 *Teorema de Cayley - Em um grafo completo G_c com n vértices e $m = \frac{n(n-1)}{2}$ arestas, existem n^{n-2} árvores que são sub-grafos de G_c .*

Pelo Teorema de Cayley percebe-se que, para o problema de redes representadas por grafos em árvore, o aumento do número de nós faz com que o total de redes que

podem ser obtidas aumente de forma muito rápida.

3.1.3 Representação das Variáveis

Em geral, o grafo completo G_c define o espaço de busca do problema de otimização de redes. Isso significa que existe uma variável binária associada a cada aresta do grafo que define se ela está ou não habilitada.

Essa definição induz uma representação natural, baseada em uma lista de números binários, como a apresentada na Equação (3.3). Nesta codificação, se $x_i = 1$, então os nós referentes à conexão i estão conectados; por outro lado, se $x_i = 0$, não existe conexão entre eles.

$$\begin{array}{rcl}
 \text{de} & 1 & 1 \dots 2 \quad 2 \dots n_{n-1} \\
 \text{para} & 2 & 3 \dots 3 \quad 4 \dots n_n \quad x_i \in [0,1] \\
 X & = & [x_1 \quad x_2 \quad \dots \quad x_k \quad x_{k+1} \quad \dots \quad x_m]
 \end{array} \quad (3.3)$$

Neste trabalho, as variáveis x_i podem assumir valores distintos de 0 ou 1, pois elas representam o tipo de cabo a ser utilizado (Ramírez-Rosado and Bernal-Agustín, 1998). Portanto, supondo a disponibilidade de t_c cabos distintos (ordenados por capacidade de corrente), as restrições $x_i \in [0,1]$ devem ser substituídas pelas apresentadas na Equação (3.4).

$$x_i \in \{0, \dots, t_c\} \quad \forall i \in \{1, \dots, m\} \quad (3.4)$$

3.1.4 Representação das Subestações / Unidades de Geração

Para os problemas em que é considerado o posicionamento de novas subestações e unidades de geração, estas são representadas pelas coordenadas x e y de onde serão instaladas. Informações adicionais, como tipo de unidade e capacidade, podem ser facilmente incorporadas à representação por meio de índices inteiros.

3.2 Formulação dos Problemas Mono e Multiobjetivo de Redes de Distribuição de Energia Elétrica

O projeto de redes de distribuição de energia elétrica consiste em buscar uma ou mais árvores que sejam sub-grafos de G_c , atendam às restrições técnicas do problema e minimizem uma ou mais funções de custo. Formulações mono e multiobjetivo deste problema são descritas na sequência.

3.2.1 Formulação Geral do Problema Mono-objetivo

Considerando a representação das variáveis para o problema de redes de distribuição de energia elétrica apresentada na Seção 3.1.3 e sendo f^{mc} uma função que se deseja minimizar, pode-se formular o problema de projeto de redes de distribuição de energia como:

$$\{\mathcal{N}, \mathcal{S}\}^* = \arg \min_{\mathcal{N}, \mathcal{S}} f^{mc}(\mathcal{N}, \mathcal{S}) \quad (3.5)$$

$$\text{sujeito a: } \{\mathcal{N}, \mathcal{S}\} \in \mathcal{F}_{\mathcal{N}, \mathcal{S}} \quad (3.6)$$

onde $\mathcal{F}_{\mathcal{N}, \mathcal{S}}$ é o conjunto de soluções factíveis.

No caso específico das redes de distribuição, três aspectos devem ser levados em conta:

- minimização do investimento no sistema;
- minimização dos custos de manutenção da rede;
- minimização das perdas na rede.

Os aspectos acima citados podem ser agregados em uma única função objetivo, que representa a função custo da rede. Esta agregação é possível porque todos eles são representados por grandezas econômicas, que diferem apenas no momento em que os recursos

financeiros são aplicados (Ramírez-Rosado and Bernal-Agustín, 1998; Carrano et al., 2006). A Equação(3.7) representa a função objetivo para o problema de redes de distribuição de energia elétrica para o caso mono-objetivo.

$$\begin{aligned}
 f^{mc}(\mathcal{N}, \mathcal{S}) = & \sum_{i \in \mathcal{S}} sc(s_i) + \sum_{i \in \mathcal{N}_N} bc(n_i) \cdot l(i_a, i_b) + \sum_{i \in \mathcal{N}_S} bc(n_i) \cdot l(i_a, i_b) + \\
 & + \sum_{t=1}^{dt} \left\{ \sum_{i \in \mathcal{N}_N} [l(i_a, i_b) \cdot mc(n_i) + lc(i)] + \right. \\
 & \left. + \sum_{i \in \mathcal{N}_S} [l(i_a, i_b) \cdot mc(n_i) + lc(i)] \right\} (1 - ir)^{t-1}
 \end{aligned} \tag{3.7}$$

onde:

$f^{mc}(\mathcal{N}, \mathcal{S})$ é o custo monetário da rede com condutores \mathcal{N} e unidades de geração \mathcal{S} ;

$\mathcal{N} = [n_1 \dots n_m]$ é o conjunto de condutores instalados na rede, tal que $\mathcal{N} = \mathcal{N}_N \cup \mathcal{N}_S$;

$\mathcal{S} = [s_1 \dots s_g]$ é o conjunto de unidades de geração instaladas na rede;

\mathcal{N}_N é o conjunto de condutores que não estão conectados a nenhuma unidade de geração em \mathcal{S} ;

\mathcal{N}_S é o conjunto de condutores que estão conectados a ao menos uma unidade de geração em \mathcal{S} ;

dt é o tempo de projeto considerado;

$sc(s_i)$ é o custo de instalação de uma unidade de geração do tipo/capacidade s_i (em $R\$$);

$bc(n_i)$ é o custo de instalação de um condutor do tipo/capacidade n_i (em $R\$/\text{km}$);

$l(i_a, i_b)$ é o comprimento do condutor necessário para conectar os nós a e b (em km);

(i_a, i_b) são os nós extremos de cada conexão i ;

$mc(n_i)$ é o custo de manutenção de um condutor do tipo/capacidade n_i (em R\$/km/ano);

$lc(i) = 8760 \cdot lf \cdot et \cdot P^L(i)$ é o custo total de perdas no ramo do tipo i (em R\$/ano);

ir é a taxa de juros anual;

lf é o fator de perda;

et é a tarifa de energia (em R\$/kWh);

$P^L(i)$ é a perda de energia no ramo i (em kW).

A rede deve atender a requisitos técnicos de projeto. Portanto, ao menos quatro restrições devem ser atendidas (Willis et al., 1996):

- c_1 : atendimento de todos os consumidores;
- c_2 : manutenção da estrutura radial da rede;
- c_3 : trabalhar sob o limite de capacidade de transferência de potência das linhas;
- c_4 : atender aos níveis de tensão regulamentados para os nós de carga.

Quanto a localização das unidades de geração, duas restrições devem ser obedecidas:

- c_5 : as coordenadas x e y possuem valores mínimos e máximos delimitados pelas regiões candidatas para se posicionar as unidades de geração;
- c_6 : as unidades de geração não podem ser posicionadas em algumas regiões devido a acidentes geográficos ou razões técnicas e financeiras.

O atendimento das restrições c_1 a c_4 garantem que $\mathcal{N} \in \mathcal{F}_{\mathcal{N},\mathcal{S}}$. Por sua vez, as restrições c_5 e c_6 são necessárias para assegurar que $\mathcal{S} \in \mathcal{F}_{\mathcal{N},\mathcal{S}}$.

Quando o problema de redes de distribuição de energia elétrica é tratado de acordo com a formulação acima, deve-se obter ao fim do processo de otimização uma única

solução que é a rede que representa custo monetário mínimo e atende a todas as restrições do problema. A solução obtida mostra a topologia da rede, as coordenadas da subestação ou unidade de geração e sua capacidade. No caso de unidades de geração distribuída, a solução também indica o tipo de energia alternativa utilizada.

A formulação adotada é adequada mesmo quando não é necessário posicionar novas unidades de geração. Neste caso basta desconsiderar os termos da Equação (3.7) associados à elas. Neste caso, a função custo monetário da rede torna-se:

$$f^{mc}(\mathcal{N}) = \sum_{i \in \mathcal{N}_N} bc(n_i) \cdot l(i_a, i_b) + \sum_{t=1}^{dt} \left\{ \sum_{i \in \mathcal{N}_N} [l(i_a, i_b) \cdot mc(n_i) + lc(i)] \right\} (1 - ir)^{t-1} \quad (3.8)$$

3.2.2 Formulação Geral do Problema Multiobjetivo

Em muitos casos práticos, a minimização do custo não é suficiente para garantir a obtenção de bons resultados no problema de redes de distribuição de energia elétrica. A abordagem multiobjetivo para este problema aqui tratada leva em consideração dois aspectos:

- minimização da quantidade média anual de interrupções;
- minimização da duração média das interrupções.

Estes dois aspectos podem ser agregados em uma única função, que é mostrada na Equação (3.11). Essa função é uma estimativa da confiabilidade do sistema por meio do prejuízo esperado em decorrência de suas falhas.

A formulação multiobjetivo para o problema é a seguinte:

$$\mathcal{X}_{\mathcal{N}, \mathcal{S}} = \arg \min_{\mathcal{N}, \mathcal{S}} \begin{cases} f^{mc}(\mathcal{N}, \mathcal{S}) \\ f^{fc}(\mathcal{N}, \mathcal{S}) \end{cases} \quad (3.9)$$

$$\text{sujeito a: } \{\mathcal{N}, \mathcal{S}\} \in \mathcal{F}_{\mathcal{N}, \mathcal{S}} \quad (3.10)$$

onde $\mathcal{X}_{\mathcal{N}, \mathcal{S}}$ é o conjunto de soluções eficientes (Pareto ótimas) para o problema.

A função $f^{mc}(\mathcal{N}, \mathcal{S})$ é exatamente a mesma apresentada na Equação (3.7).

Por sua vez, a função $f^{fc}(\mathcal{N}, \mathcal{S})$ está relacionada à confiabilidade do sistema. Esta função estima o custo incorrido no sistema pela eventual ocorrência e duração de faltas, como pode ser visto na Equação (3.11).

$$\begin{aligned} f^{fc}(\mathcal{N}, \mathcal{S}) = & \sum_{t=1}^{dt} \left\{ \sum_{i \in \mathcal{N}_N} \lambda(n_i) \cdot l(i_a, i_b) [dr(n_i) \cdot P^A(i) \cdot et + fc(i)] \right. \\ & \left. + \sum_{i \in \mathcal{N}_S} \lambda(n_i) \cdot l(i_a, i_b) [dr(n_i) \cdot P^A(i) \cdot et + fc(i)] \right\} (1 - ir)^{(t-1)} \end{aligned} \quad (3.11)$$

onde:

$f^{fc}(\mathcal{N}, \mathcal{S})$ é o custo de falta da rede com condutores \mathcal{N} e unidades de geração \mathcal{S} ;

$\lambda(n_i)$ é a taxa de falha do ramo tipo n_i (em falhas/km/ano);

$dr(n_j)$ é a duração média por falta do ramo tipo n_j (em h/falha);

$P^A(i)$ é a potência ativa no ramo i (em kW);

$fc(i)$ é o custo médio por falha do ramo i .

A resolução deste problema leva a um conjunto de soluções eficientes, também conhecido como conjunto de Pareto. O projetista possui então várias opções de redes que podem ser instaladas e deve fazer uma análise de trade-off para definir a mais adequada. A análise de trade-off consiste em avaliar as trocas entre soluções candidatas sob o ponto de vista de ganho em um objetivo e perda no outro. Um exemplo deste

tipo de estudo no problema de redes de distribuição pode ser visto em (Carrano et al., 2006).

Da mesma forma que na formulação mono-objetivo, as soluções não dominadas encontradas na abordagem multiobjetivo trazem a topologia da rede, as coordenadas da subestação ou unidade de geração e sua capacidade. No caso de unidades de geração distribuída, a solução também indica o tipo de energia alternativa utilizada. Além disso, esta abordagem também pode ser utilizada mesmo quando não é necessário posicionar novas unidades de geração. Neste caso, basta desprezar os termos referentes à unidade de geração em (3.11), como mostrado em (3.12).

$$f^{fc}(\mathcal{N}) = \sum_{t=1}^{dt} \left\{ \sum_{i \in \mathcal{N}_N} \lambda(n_i) \cdot l(i_a, i_b) [dr(n_i) \cdot P^A(i) \cdot et + fc(i)] \right\} (1 - ir)^{(t-1)} \quad (3.12)$$

Capítulo 4

Otimização e Computação Evolucionária

4.1 Conceitos Relevantes ao Trabalho

Nesta seção alguns conceitos relacionados à otimização multiobjetivo utilizados neste trabalho são descritos. É também descrita a métrica *T-norm* utilizada nos operadores de cruzamento e mutação nos algoritmos genéticos mono e multiobjetivo utilizados.

Conjunto Pareto e Pareto Dominância

O vetor de soluções no espaço de parâmetros para um problema multiobjetivo é dado por x sendo $x \in R^n$. Sendo $f(.) : R^n \mapsto R^m$ o vetor de m funções objetivo desse problema, o conjunto \mathcal{X}^* de soluções eficientes é dado por:

$$\mathcal{X}^* = \arg \min_x \begin{cases} f_1(x) \\ \vdots \\ f_m(x) \end{cases} \quad (4.1)$$

$$\text{sujeito a: } \begin{cases} g_1(x) \leq 0 \\ \vdots \\ g_k(x) \leq 0 \end{cases} \quad (4.2)$$

A região F_x , na qual o problema se encontra restrito, é definida pelo conjunto de restrições apresentado em 4.2. Em geral não existe um único ponto $x \in F_x$ tal que $f(\cdot)$ alcança um mínimo para todas as funções. Então:

$$\mathcal{X}^* = \{x^* \in F_x \mid \nexists z \in F_x \text{ onde } f(z) \leq f(x^*) \text{ e } f(z) \neq f(x^*)\} \quad (4.3)$$

Onde os operadores relacionais \leq e \neq são definidos para vetores $u, v \in R^m$, tal que:

$$\begin{aligned} u \leq v &\Leftrightarrow u_i \leq v_i \quad \forall i = 1, \dots, m \\ u \neq v &\Leftrightarrow \exists i \mid u_i \neq v_i \quad i = 1, \dots, m \end{aligned} \quad (4.4)$$

São chamados dominados os pontos $x \in F_x$ que não pertencem ao conjunto \mathcal{X}^* , uma vez que há outros pontos, $z \in F_x$, tais que $f(z) \leq f(x)$ e $f(z) \neq f(x)$. Isto indica que $f(z)$ é melhor que $f(x)$ em pelo menos uma coordenada sem ser pior em qualquer outra coordenada. Neste caso z domina x . O conjunto \mathcal{X}^* é formado por soluções eficientes, sendo estas as soluções que não são dominadas por nenhuma outra solução. Este conjunto é denominado conjunto Pareto.

Considerando as funções objetivo f^{mc} e f^{fc} utilizadas neste trabalho e que devem ser minimizadas, e sendo N_1 e N_2 duas redes factíveis, se $[f^{mc}(N_1) \leq f^{mc}(N_2)]$ e $[f^{fc}(N_1) < f^{fc}(N_2)]$ ou $[f^{mc}(N_1) < f^{mc}(N_2)]$ e $[f^{fc}(N_1) \leq f^{fc}(N_2)]$ é verdadeiro, então N_1 domina N_2 . Isto indica que a rede N_1 é tão boa quanto a rede N_2 em um objetivo e é também melhor que N_2 no outro objetivo. O conjunto Pareto para o problema de redes de distribuição de energia é dado por:

$$\mathcal{N}^* = \{N^* \in \mathcal{N} \mid \nexists N \in \mathcal{N} \text{ tal que } N \text{ domina } N^*\} \quad (4.5)$$

Através do conjunto Pareto é possível para o projetista avaliar o efeito da substituição de uma solução por outra, considerando a perda em um objetivo com o simultâneo ganho em outro.

Dominância Estocástica

A dominância estocástica é necessária quando a função objetivo associada a uma determinada solução é representada por uma função distribuição de probabilidade.

Neste trabalho o desempenho das redes encontradas é avaliado para cenários distintos do mais provável utilizando simulações de Monte Carlo. Assim, para cada solução há um conjunto de valores para f^{mc} e f^{fc} . Então, torna-se necessária a utilização da dominância estocástica proposta em (Carrano et al., 2010). Neste caso, a rede N_1 domina a rede N_2 se e somente se:

$$\left\{ \begin{array}{l} f_q^{mc}(N_1) \leq f_q^{mc}(N_2) \quad \forall q \in [0, 1] \\ f_q^{fc}(N_1) \leq f_q^{fc}(N_2) \quad \forall q \in [0, 1] \\ \exists q \in [0, 1] \quad \text{tal que} \quad f_q^{mc}(N_1) < f_q^{mc}(N_2) \quad \text{ou} \quad f_q^{fc}(N_1) < f_q^{fc}(N_2) \end{array} \right. \quad (4.6)$$

onde q corresponde ao quantil $q\%$ entre os considerados para a função.

A Equação 4.6 é equivalente ao conceito de dominância estocástica original discutido em Penmaraju and Skiena (2003). Como as distribuições contínuas das funções não estão disponíveis neste trabalho, não é possível a comparação de todos os quantis no intervalo $[0,1]$. Assim, foi utilizada uma aproximação discreta do conceito de dominância estocástica utilizando cinco quantis $q = [0,05 \ 0,25 \ 0,50 \ 0,75 \ 0,95]$.

Representação de Redes no Espaço Contínuo

A definição da métrica T -norm apresentada a seguir foi adaptada de (Carrano, 2007) e (Carrano et al., 2010).

Considere uma rede N qualquer, que pode ser definida em um grafo $G(V, A)$, com t_c tipos de conexões distintas. De acordo com os conceitos de espaços métricos (Lima, 1995), a rede N pode ser representada como um vetor \vec{N} no espaço \mathbb{R}^m de Hilbert. Esta representação é a seguinte:

$$\vec{N} = \sum_{i=1}^m (w_i^N \cdot p_1 + N_i \cdot w_i^N \cdot p_2) \vec{e}_i \quad (4.7)$$

onde:

w_i^N é o peso topológico da aresta i na rede N . Este peso é um real positivo se a conexão i existe ou 0 caso contrário;

p_1 é um fator de penalidade 1;

p_2 é um fator de penalidade 2;

N_i é o tipo de conexão da aresta i na rede N ;

\vec{e}_i é o i -ésimo vetor da base canônica.

A representação de redes feita conforme a Equação (4.7), faz com que o problema seja inserido no espaço \mathbb{R}^m . Assim, o espaço onde estão definidas as soluções deste problema passa a ter as propriedades do espaço de Hilbert.

Duas definições importantes envolvendo redes são a posição relativa e a distância entre duas redes.

Sejam duas redes quaisquer A e B :

$$\vec{A} = \sum_{i=1}^m (w_i^A \cdot p_1 + A_i \cdot w_i^A \cdot p_2) \vec{e}_i = \sum_{i=1}^m c_i^{AO} \cdot \vec{e}_i \quad (4.8)$$

$$\vec{B} = \sum_{i=1}^m (w_i^B \cdot p_1 + B_i \cdot w_i^B \cdot p_2) \vec{e}_i = \sum_{i=1}^m c_i^{BO} \cdot \vec{e}_i \quad (4.9)$$

A posição relativa de A em relação a B é definida como:

$$\begin{aligned} \overrightarrow{r_p(A, B)} &= \sum_{i=1}^m [p_2 (A_i \cdot w_i^A - B_i \cdot w_i^B) + p_1 (w_i^A - w_i^B)] \vec{e}_i \\ &= \sum_{i=1}^m c^{AB} \cdot \vec{e}_i \end{aligned} \quad (4.10)$$

\vec{A} também pode ser visto como a posição relativa de A em relação à origem (O).

Ao se calcular a norma Euclidiana de 4.10, está sendo calculada a distância entre

as redes A e B . Isto é mostrado na Equação (4.11). Esta é a métrica definida como T -norm.

$$\begin{aligned} d_s(A, B) = \|\overrightarrow{(A, B)}\| &= \sqrt{\sum_{i=1}^m [p_2 (A_i \cdot w_i^A - B_i \cdot w_i^B) + p_1 (w_i^A - w_i^B)]^2} \\ &= \sqrt{\sum_{i=1}^m (c_i^{AB})^2} \end{aligned} \quad (4.11)$$

O peso das conexões (w_i^N) é calculado usando a Equação (4.12).

$$w_i^N = \frac{s_a^N - s_b^N}{2} \quad (4.12)$$

$$s_x^N = 1 - \frac{d_{x,raiz}^N}{\max(d_{j,raiz}^N)} \quad (4.13)$$

onde:

a e b são os nós extremos da conexão i na rede N ;

s_x^N é o peso do nó x na rede N ;

$d_{x,raiz}^N$ é a distância total do caminho entre o nó x e o nó raiz da rede N (em km);

$\max(d_{j,raiz}^N)$ é a máxima distância dos caminhos entre um nó j e a raiz da rede N , para todos os j pertencentes ao conjunto V .

Conexões próximas à raiz da rede têm influência maior na norma da rede do que conexões próximas às extremidades da rede. Assim, uma mudança em uma conexão próxima à raiz causa uma grande modificação no vetor que representa a rede, enquanto uma mudança em uma conexão extrema da rede causaria uma modificação pequena no vetor que representa a mesma. Em uma rede de distribuição de energia elétrica, o fluxo de potência sofre uma grande perturbação se ocorrer uma mudança nas conexões próximas a subestação (raiz da rede) enquanto que uma mudança nas conexões terminais da rede provoca suaves alterações no fluxo.

4.2 Algoritmos Evolucionários

As características de exploração dos algoritmos evolucionários, que combina mecanismos de busca local e global, fazem destes ferramentas de busca robustas e efetivas quando se deseja encontrar soluções que aproximam o ótimo global (Wanner, 2006). Esse aspecto, associado à sua forte capacidade de adaptação e facilidade de implementação, justificaram a grande aceitação recente dos algoritmos evolucionários nos mais diferentes tipos de aplicação. Exemplos de algoritmos evolucionários são: Algoritmo Genético (Goldberg, 1989), Algoritmos de Colônia de Formigas (Dorigo et al., 1996; Dorigo and Gambardella, 1997; Dorigo et al., 1999), Sistemas Imunológicos Artificiais (de Castro, 2001; de Castro and Von Zuben, 2002; de Castro and Timmis, 2003) e Particle Swarm Optimization (Kennedy and Eberhart, 1995).

O problema do planejamento de redes de distribuição de energia elétrica é um problema combinatório, não-linear, não-convexo e altamente restrito (Ganguly et al., 2009). O aumento do número de nós da rede faz com que o total de soluções que podem ser obtidas aumente pelo menos exponencialmente. A solução de problemas de média e grande dimensão apresenta custo computacional elevado, devido ao alto número de variáveis a ser considerado. Devido a estas características, os algoritmos evolucionários se mostram adequados para lidar com esta classe de problemas. Além disso, estes algoritmos são capazes de encontrar um conjunto de soluções para o problema em apenas uma execução quando é considerada a otimização multiobjetivo. Uma importante limitação dos algoritmos evolucionários é que, embora sejam ferramentas capazes de encontrar uma aproximação do ótimo global do problema, eles pecam no sentido da precisão da busca pelo ótimo (Wanner, 2006). Uma maneira de melhorar o desempenho destes algoritmos é a incorporação a eles de métodos de busca local interna e externamente.

Alguns trabalhos que aplicam algoritmos evolucionários a problemas de redes de energia elétrica são citados na Seção 1.2.1.

Neste capítulo é feita a descrição do algoritmo genético mono objetivo e de al-

guns algoritmos genéticos multiobjetivo apresentados na literatura. Alguns conceitos relacionados à otimização multiobjetivo e o conceito da métrica T -norm também são descritos.

4.2.1 Algoritmos Genéticos

Os algoritmos genéticos (AG's) são inspirados na teoria da evolução de Charles Darwin, segundo a qual os indivíduos mais aptos têm maior chance de sobrevivência e são os principais responsáveis pela geração das novas populações de descendentes (Goldberg, 1989). O algoritmo começa com um conjunto de soluções, chamado de população, que é submetido a aplicações sucessivas de operações de seleção, cruzamento e mutação, para composição de nova geração de indivíduos. Isto é motivado pela esperança de que a nova população seja, em média, superior a anterior. Soluções são selecionadas para formar novas gerações de soluções de acordo com sua aptidão (ou *fitness*), de tal forma que quanto maior a aptidão, maiores as chances de reprodução.

Descrição do Algoritmo Genético Mono-objetivo

A estrutura básica de um AG mono-objetivo é apresentada na sequência (adaptado de (Carrano, 2007)).

Estrutura do Algoritmo Genético Mono-objetivo

- 1: $pop_0 \leftarrow$ gerar população(N);
- 2: $fit_0 \leftarrow$ calcular $fitness(f_0)$;
- 3: $conv \leftarrow$ false;
- 4: $ger \leftarrow 1$;
- 5: **while** $conv = \text{false}$ **do**
- 6: $pop_{ger} \leftarrow$ seleção(fit_{ger-1}, pop_{ger-1});
- 7: $pop_{ger} \leftarrow$ shuffle(pop_{ger});
- 8: **for** $i = 1$ até $\frac{N}{2}$ **do**

```

9:   if random  $\leq p_{cruz}$  then
10:      $(pop_{ger}^i, pop_{ger}^{\frac{N}{2}+1}) \leftarrow \text{cruzamento}(pop_{ger}^i, pop_{ger}^{\frac{N}{2}+1});$ 
11:   end if
12: end for
13: for  $i = 1$  até  $N$  do
14:   if random  $\leq p_{mut}$  then
15:      $(pop_{ger}^i) \leftarrow \text{mutação}(pop_{ger}^i);$ 
16:   end if
17: end for
18:  $fit_{ger} \leftarrow \text{calcular } fitness(f_{ger});$ 
19: if convergiu then
20:    $conv \leftarrow \text{true};$ 
21: else
22:    $ger \leftarrow ger + 1;$ 
23: end if
24: end while

```

Alguns aspectos importantes dessa estrutura são descritos a seguir¹:

Parâmetros de Entrada:

Para a execução do AG, devem ser definidos os seguintes parâmetros:

N – tamanho da população: inteiro, par;

p_{cruz} – probabilidade de cruzamento por par de indivíduos: real;

p_{mut} – probabilidade de mutação: real.

A escolha inadequada dos parâmetros N , p_{cruz} e p_{mut} pode gerar aumento no tempo de convergência do algoritmo, convergência prematura, estagnação da busca, maior necessidade de recursos computacionais e não convergência para uma solução viável (Catarina and Bach, 2003).

¹Trecho adaptado de (Fonseca, 1995)

População:

A população dos AG's deve ser considerada em dois níveis: fenótipo e genótipo. O genótipo é a representação de uma solução em um domínio codificado, onde o algoritmo atua. Por sua vez, o fenótipo é a representação dessa mesma solução no domínio de interesse do problema (Goldberg, 1989). Qualquer estrutura conveniente pode ser utilizada para codificar o fenótipo em genótipo (Rothlauf, 2006). Na maior parte dos casos, os genótipos são construídos mediante sequências de bits, que têm como inspiração as sequências genéticas contidas em cromossomos biológicos. No entanto, outros tipos de representações têm recebido grande atenção recentemente, como codificações reais, inteiras, baseadas em caracteres, etc (Rothlauf, 2006).

Avaliação da População e Atribuição da Fitness:

Todos os indivíduos da população são avaliados por meio da função objetivo que define o problema. Os valores da função objetivo calculados são utilizados para atribuição da *fitness*. Maiores valores de *fitness* são associados aos melhores indivíduos e a melhoria da população é consequência da repetida seleção dos indivíduos mais aptos, que têm maior chance de produzir bons descendentes (Fonseca, 1995).

Seleção:

Nos AG's a seleção é geralmente realizada de forma estocástica. Um dos métodos mais utilizados é a roleta estocástica (do inglês, Roulette Wheel Selection ou RWS) (Goldberg, 1989). Este método consiste de uma sequência de N eventos de seleção independentes, onde o *slot* da roleta referente a cada indivíduo é proporcional à sua *fitness*. A seleção é realizada com reposição, sendo que as probabilidades são mantidas constantes durante os N eventos de seleção.

Como a roleta estocástica provoca erros de seleção, Baker (1987) propôs um método de seleção chamado amostragem universal estocástica (do inglês, Stochastic Universal Sampling ou SUS). Neste método, a roleta é construída de forma exatamente igual ao RWS, mas a seleção é realizada com N ponteiros simultâneos, dispostos uniformemente

espaçados.

O Torneio Binário (do inglês, Binary Tournament Selection ou BTS) (Hancock, 1994) é outro método comumente utilizado para seleção em AG's. Em cada passo desse método, são escolhidos dois indivíduos aleatoriamente (com reposição) e o melhor deles é selecionado para ser passado para a próxima geração. O processo se repete até que N indivíduos tenham sido selecionados.

No AG é comum selecionar os melhores indivíduos para estarem presentes na próxima geração, pois eles podem ser perdidos quando operadores de cruzamento e mutação são executados. Esta técnica é chamada elitismo e, em geral, melhora a convergência do algoritmo.

Cruzamento:

No cruzamento os genótipos de dois indivíduos “pais” são combinados para geração de um ou mais “filhos”. Espera-se que este operador funcione de forma semelhante a uma operação de interpolação, onde os indivíduos gerados compartilham similaridades com os pais tanto em genótipo quanto em fenótipo (hereditariedade).

Mutação:

Em uma operação de mutação, o genótipo de um indivíduo de entrada é modificado conforme alguma regra probabilística. Como apenas uma pequena parte do genótipo é modificada, espera-se que as variações no fenótipo também sejam limitadas (localidade). As regras adotadas para mutação podem variar com a representação e com o problema. Em geral, este tipo de operador realiza um papel importante de busca local e global dentro do algoritmo.

Critério de Parada:

Vários critérios podem ser utilizados para definir a condição de parada de AG's. Dentre eles, vale citar:

- obtenção de um ótimo cujo valor de função objetivo seja conhecido;

- estabilização do valor da função objetivo;
- estabilização (perda de diversidade) da população;
- execução de um número pré-determinado de gerações;
- execução de um número pré-determinado de avaliações de função.

Em geral, não é possível relacionar o critério de parada com algum critério forte de convergência, como é feito nos algoritmos determinísticos.

Descrição do Algoritmo Genético Multiobjetivo e o Nondominated Sorting Genetic Algorithm II (NSGA-II)

Os mecanismos de seleção normalmente utilizados nos algoritmos evolucionários mono-objetivo não são aplicáveis aos problemas multicritério. Isso se justifica pelo fato destes operadores dependerem das relações clássicas de comparação ('=', '<', '>', '≤' e '≥') que, muitas vezes, não se observam em comparações de vetores. Portanto, os algoritmos evolucionários multiobjetivo variam das versões mono-objetivo no mecanismo empregado para seleção. Por sua vez, os operadores de cruzamento e mutação podem ser utilizados em qualquer das versões do algoritmo, sem qualquer necessidade de adaptação.

O primeiro algoritmo genético multiobjetivo implementado foi o Vector Evaluated Genetic Algorithm (VEGA) desenvolvido por Schaffer (1984). Neste algoritmo, um número de sub-populações é gerado através de uma seleção proporcional de acordo com cada objetivo em questão. Assim, para um problema com q objetivos, q sub-populações de tamanho N/q são geradas, sendo N o tamanho da população. Estes indivíduos são agrupados para se obter uma nova população de tamanho N para então serem aplicados os processos de cruzamento e mutação. Durante algumas gerações o algoritmo é eficiente, mas, em alguns casos, ele se torna tendencioso em direção a alguns indivíduos ou regiões.

Segundo Goldberg (1989), as limitações do VEGA podem ser atenuadas pelo uso de duas técnicas: *sharing* (compartilhamento) e *nondominated sorting*. Técnicas de *sharing* são métodos utilizados para que o algoritmo alcance regiões de busca não exploradas da fronteira Pareto. A técnica do *nondominated sorting* consiste em dividir a população em fronteiras (ou *fronts*), com base nas relações de dominância entre os indivíduos.

As ideias de Goldberg (1989) foram utilizadas para a construção de diversos algoritmos que tentavam aprimorar o VEGA. Da primeira geração desses algoritmos, três que merecem destaque são: o Multiobjective Optimization Genetic Algorithm (MOGA) (Fonseca and Fleming, 1993), o Nondominated Sorting Genetic Algorithm (NSGA) (Srinivas and Deb, 1994) e o Strength Pareto Evolutionary Algorithm (SPEA) (Zitzler and Thiele, 1999).

No MOGA (Fonseca and Fleming, 1993), a seleção por *nondominated sorting* é implementada por meio da atribuição de um *rank* a cada indivíduo da população. Essa atribuição é feita pelos seguintes passos: *i*) A todos os indivíduos não dominados é atribuído *rank* igual 1. *ii*) Cada um dos indivíduos restantes recebe *rank* igual ao número de pontos que o dominam mais 1. No processo de seleção, de acordo com o valor do “rank”, blocos de pontos são selecionados ou excluídos para formar a população de “pais” que sofrerão cruzamento e mutação para formar a população de “arquivo”.

Este processo de seleção faz com que haja uma pressão de seleção muito grande, o que pode levar a uma convergência prematura do algoritmo (Goldberg and Deb, 1991). No MOGA é utilizado um operador de nicho, que tenta distribuir a população na região do conjunto de Pareto. No entanto, este operador trabalha no espaço de objetivos e não no espaço de parâmetros, o que pode levar a uma redução da diversidade neste segundo espaço. Além disso, o MOGA pode não encontrar múltiplas soluções em problemas onde diferentes pontos do conjunto Pareto ótimo correspondem ao mesmo valor de função objetivo (Srinivas, 1994).

No SPEA (Zitzler and Thiele, 1999) uma população inicial P é criada e os indivíduos

não dominados que fazem parte desta população são selecionados e armazenados em um conjunto chamado população externa P' . As soluções de P' que são dominadas por outra solução também pertencente a P' são eliminadas. O *fitness* de cada indivíduo das duas populações é calculado. O *fitness* dos indivíduos pertencentes a P' é calculado da seguinte forma: para cada indivíduo i da população externa P' é atribuído um valor real chamado *strength* (s_i) proporcional ao número de indivíduos j na população P que ele domina. Se n é o número de indivíduos dominados por i e N o tamanho da população P , s_i é dado por $s_i = \frac{n}{N+1}$. O *fitness* f_i do indivíduo i é o valor de s_i . O *fitness* do indivíduo j pertencente a população P é calculado somando-se os *strengths* de todas as soluções de P' que dominam j . É somado 1 a este valor para garantir que os indivíduos de P' tenham melhor valor de *fitness*. Indivíduos são selecionados do conjunto formado pela população e população externa até que a *mating pool* esteja completa. Operadores de cruzamento e mutação são aplicados. Se o tamanho da população externa exceder o tamanho especificado, um procedimento de *clustering* é aplicado para eliminação de soluções pouco representativas.

No NSGA (Srinivas and Deb, 1994), um processo de divisão da população em *fronts* é realizado antes da seleção. Neste processo, os indivíduos recebem um valor de *fitness* proporcional ao *front* que pertencem, de tal forma que os indivíduos não dominados recebem o maior valor possível. Para manter a diversidade da população, é aplicado um operador de *sharing* que corrige a *fitness* com base na concentração de indivíduos ao redor de cada ponto. O operador de roleta estocástica utiliza estes valores corrigidos de *fitness* para construir a nova população. Como os indivíduos pertencentes ao primeiro *front* têm maior valor de *fitness* eles terão mais cópias. Este tipo de seleção geralmente leva a uma convergência mais rápida na direção das regiões não dominadas. Já o operador de *sharing* ajuda a distribuir a população na região não dominada.

Com o passar dos anos, algumas críticas surgiram em relação aos algoritmos de primeira geração e, em especial, ao NSGA:

- elevada complexidade computacional do processo de divisão das soluções em

fronts;

- falta de elitismo;
- necessidade de especificar o parâmetro de *sharing*.

Para contornar estes problemas, foram propostas modernizações destes algoritmos como, por exemplo, o NSGA-II (Nondominated Sorting Genetic Algorithm II) (Deb et al., 2002), SPEA2 (Strength Pareto Evolutionary Algorithm 2) (Zitzler et al., 2001), PAES (Pareto-archived Evolution Strategy) (Knowles and Corne, 1999) e PESA-II (Region-based Selection in Evolutionary Multiobjective Optimization) (Corne et al., 2001). No restante desta seção o NSGA-II é descrito de forma mais detalhada, tendo em vista que esta é a ferramenta evolucionária utilizada neste trabalho para o tratamento de instâncias multiobjetivo dos problemas considerados.

Non-dominated Sorting Genetic Algorithm II – NSGA-II

O algoritmo NSGA-II (Deb et al., 2002) é uma versão melhorada do NSGA. Este foi proposto para contornar os problemas já citados do algoritmo original. Três novos operadores são propostos: o *fast nondominated sorting*, *crowding distance assignment* e *crowded comparison*. A população P_0 de indivíduos de tamanho N é dividida em *fronts* utilizando a técnica do *fast nondominated sorting*. Seleção utilizando torneio binário, operadores de cruzamento e mutação são aplicados para formar uma população de *offspring* Q_0 , também de tamanho N . Nas gerações posteriores a população P_t da t -ésima geração é agrupada com a população Q_t , formando uma superpopulação R_t de tamanho $2N$. R_t é dividida em *fronts* e a população P_{t+1} é preenchida com as soluções dos *fronts* de R_t , até atingir seu tamanho máximo. Se o número de soluções pertencentes a um determinado *front* for maior que o número de soluções que devem ser selecionadas, as soluções com maior *crowding* são escolhidas. Os operadores de seleção, cruzamento e mutação são aplicados em P_{t+1} para formação de Q_{t+1} . Esse processo se repete até que a convergência seja alcançada.

Algumas vantagens do NSGA-II podem ser citadas (Deb et al., 2002):

1. A diversidade entre as soluções não dominadas é introduzida utilizando o procedimento de *crowded comparison*, que é usado no processo de seleção e na fase de redução da população. Assim, não é necessário especificar nenhum parâmetro de nicho.
2. Esta versão possui complexidade computacional menor que o NSGA.
3. O operador *crowded comparison* guia o processo de seleção com o intuito de atingir uma fronteira uniformemente distribuída.

O pseudo-código do NSGA-II é apresentado no algoritmo abaixo (adaptado de (Deb et al., 2002)), que possui os seguintes parâmetros de entrada: tamanho da população (N), probabilidade de cruzamento, probabilidade de mutação e número máximo de gerações.

Estrutura Básica do NSGA-II

- 1: *inicializar* P_0
- 2: *fast – non – dominated – sort*(P_0)
- 3: $Q_0 \leftarrow$ *criar – arquivo*
- 4: **for** $t = 1$ até *maxger* **do**
- 5: $R_t \leftarrow P_{t-1} \cup Q_{t-1}$
- 6: $F \leftarrow$ *fast – non – dominated – sort*(R_t)
- 7: $P_t \leftarrow \emptyset$ e $i = 1$
- 8: **while** $|P_t| + |F_i| \leq N$ **do**
- 9: *crowding – distance – assignement*(F_i)
- 10: $P_t \leftarrow P_t \cup F_i$
- 11: $i = i + 1$
- 12: **end while**
- 13: *ordenar* F_i

-
- 14: $P_t \leftarrow P_t \cup F_i[1 : (N - |P_t|)]$
 - 15: $Q_t \leftarrow \text{criar} - \text{novo} - \text{arquivo}$
 - 16: $t = t + 1$: incrementar o contador de geração
 - 17: **end for**
-

No pseudo-código do NSGA-II:

- inicializar P_0 : criar população inicial de tamanho N ;
- fast-non-dominated-sort (P_0): dividir P_0 em *fronts*;
- criar-arquivo: aplicar operadores de seleção, cruzamento e mutação em P_0 para criar Q_0 de tamanho N ;
- crowding-distance-assignment (F_i): calcular crowding distance em F_i ;
- ordenar F_i : ordenar F_i em ordem decrescente usando crowded comparison.

Como já mencionado, quando comparado ao NSGA original, o NSGA-II traz três novas operações:

- *fast nondominated sorting*;
- *crowding distance assignment*;
- *crowded comparison*.

Cada uma dessas operações é discutida de forma superficial na sequência. A referência Deb et al. (2002) é a mais indicada para obter maiores informações sobre estes procedimentos.

Fast nondominated sorting

O *fast nondominated sorting* é utilizado para dividir a população em *fronts* de tal forma que, após a execução os indivíduos do primeiro *front* recebem *rank* 1, os indivíduos do segundo *front* recebem *rank* 2 e assim por diante.

O seguinte algoritmo (adaptado de (Deb et al., 2002)) é utilizado para realizar esta divisão:

Fast Nondominated Sorting

```

1: for each  $p \in \mathcal{P}$  do
2:    $S_p = \emptyset$ 
3:    $n_p = 0$ 
4:   for each  $q \in \mathcal{P}$  do
5:     if  $p \prec q$  then
6:        $S_p = S_p \cup q$ 
7:     else if  $q \prec p$  then
8:        $n_p = n_p + 1$ 
9:     end if
10:  end for
11:  if  $n_p = 0$  then
12:     $p_{rank} = 1$ 
13:     $F_1 = F_1 \cup p$ 
14:  end if
15: end for
16:  $i = 1$ 
17: while  $F_i \neq \emptyset$  do
18:    $Q = \emptyset$ 
19:   for each  $p \in F_i$  do
20:     for each  $q \in S_p$  do
21:        $n_q = n_q - 1$ 
22:     if  $n_q = 0$  then
23:        $q_{rank} = i + 1$ 
24:        $Q = Q \cup q$ 

```

```

25:     end if
26:   end for
27: end for
28:    $i = i + 1$ 
29:    $F_i = Q$ 
30: end while

```

No algoritmo, $a \prec b$ se a solução a domina a solução b .

Como citado, este algoritmo reduz a complexidade do processo de divisão das soluções em *fronts* de $\mathcal{O}(mn^3)$ para $\mathcal{O}(mn^2)$, onde m é o número de objetivos e n o número de soluções na população. Já podem ser encontradas na literatura implementações que reduzem essa complexidade para $\mathcal{O}(mn \log(n))$ (Jensen, 2003).

Crowding Distance Assignment

O operador de atribuição da *crowding distance* é utilizado para estimar a densidade de soluções ao redor de uma determinada solução no espaço de objetivos. Esta densidade é calculada pelo perímetro do cubo formado pelas soluções vizinhas em cada um dos objetivos, como mostrado na Figura 4.1. O valor calculado ($I_{distance}$) é utilizado para comparar soluções no mesmo *front*, de tal forma que, quanto maior o $I_{distance}$ da solução melhor.

O procedimento é utilizado para cada *front*, e é apresentado no algoritmo abaixo (adaptado de (Deb et al., 2002)):

Crowding Distance

```

1:  $l = |\mathcal{F}_i|$ 
2:  $I[*]_{distance} = 0$ 
3: for each objective  $m$  do
4:    $I = sort(I, m)$ 

```

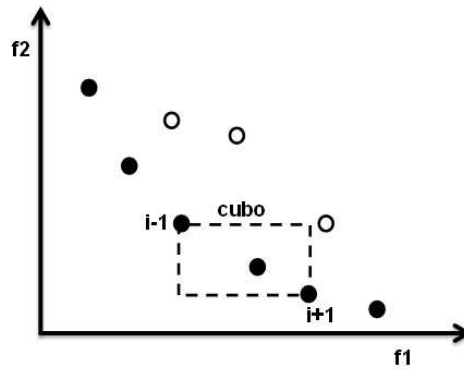



Figura 4.1: Cálculo da *crowding distance*. Os pontos marcados por círculos cheios pertencem ao mesmo *front*.

```

5:   $I[1]_{distance} = I[l]_{distance} = \infty$ 
6:  for  $i = 2$  até  $(l - 1)$  do
7:     $I[i]_{distance} = I[i]_{distance} + \frac{(I[i + 1].m - I[i - 1].m)}{f_m^{max} - f_m^{min}}$ 
8:  end for
9: end for

```

onde:

\mathcal{F}_i é o conjunto de soluções no *front* i ;

$sort(I, m)$ ordena I pelo m -ésimo objetivo;

$I[i].m$ retorna o valor do objetivo m para indivíduo i ;

$I[i]_{distance}$ é o valor de *crowding distance* do indivíduo i .

Deste procedimento é fácil notar que a melhor solução em cada objetivo recebe valor infinito para a *crowding distance*, tendo prioridade entre todas as soluções do mesmo *front*. Também deve ser observado que os objetivos são normalizados para avaliação da *crowding distance*, o que evita distorções causadas por diferenças de escala entre os objetivos.

Crowded Comparison

Este operador é uma adaptação do torneio binário para o NSGA-II. Dadas duas

soluções a e b , o operador segue o seguinte procedimento para escolher a solução vencedora:

Crowded Comparison

```
1: if  $rank[a] < rank[b]$  then
2:   select  $a$ 
3: end if
4: if  $rank[a] > rank[b]$  then
5:   select  $b$ 
6: end if
7: if  $rank[a] = rank[b]$  then
8:   if  $I[a]_{distance} > I[b]_{distance}$  then
9:     select  $a$ 
10:  else
11:    select  $b$ 
12:  end if
13: end if
```

Portanto, o operador dá preferência para a solução em um $rank$ mais baixo. Caso as duas soluções estejam no mesmo $rank$, então a solução com maior *crowding distance* é escolhida.

Capítulo 5

Algoritmo Proposto para o Projeto de Redes de Distribuição de Energia Elétrica

Neste capítulo são apresentados os modelos para descrição das variáveis incertas consideradas neste trabalho. Em seguida são descritos os algoritmos mono e multiobjetivo utilizados e os operadores de busca local determinística desenvolvidos. Além disso, é feita também a descrição do operador para localização de novas subestações/unidades de geração proposto. Por fim, a ferramenta de projeto de sistemas de distribuição de energia elétrica obtida com o agrupamento do algoritmo genético com os operadores desenvolvidos é apresentada.

5.1 Modelos para Descrição das Variáveis Incertas

Antes de apresentar os algoritmos desenvolvidos, é importante apresentar os modelos que são utilizadas para representar as variáveis incertas do problema, tendo em vista que estes modelos são utilizados nos operadores.

5.1.1 Modelo de Crescimento da Carga

O aumento das cargas do sistema é, talvez, a maior fonte de incerteza no planejamento de sistemas de distribuição a médio e longo prazo. Neste trabalho, o crescimento

de cada carga foi modelado como uma variável gaussiana independente, com média definida como o crescimento esperado e um desvio padrão de cerca de 20% desse valor. Posteriormente, esses crescimentos são transformados em uma função de distribuição de probabilidade conjunta por meio de uma matriz de correlação.

Qualquer modelo de predição de carga pode ser utilizado para determinar a carga em um horizonte de tempo futuro. Alguns modelos são apresentados em Cho et al. (1995); Ren-jun and Xian-zhong (2002). A técnica descrita neste trabalho para considerar incertezas no projeto de redes de distribuição de energia elétrica é válida qualquer que seja o modelo escolhido.

5.1.2 Modelo de Variação do Preço da Energia

Fatores como erros de predição na posição dos centros de carga e de seus módulos, alterações na disponibilidade dos recursos utilizados na geração e variações do mercado financeiro afetam o valor gasto pela concessionária para atendimento de cada cliente. Portanto, o preço da energia deve ser descrito como uma variável aleatória, com o intuito de modelar essas variações. Por uma questão de simplicidade, também foram utilizadas distribuições normais independentes para descrever o preço da energia em cada um dos nós do sistema. Essa distribuição tem média zero e desvio padrão de 5%. Assim como na carga, essas distribuições são transformadas em uma função de distribuição conjunta por meio de uma matriz de correlação.

Para estimar a distribuição do preço da energia, a concessionária deve estimar o gasto que tem com cada consumidor. A concessionária conhece a energia gerada e a energia faturada. Por meio desses dados, e da inferência das perdas técnicas e não-técnicas ao longo do sistema, é possível estimar o custo de atendimento de cada cliente ou conjunto de clientes.

5.1.3 Distribuição de Probabilidade Conjunta das Variáveis Incertas

Considerando I o vetor das variáveis incertas do problema e I_i o vetor das variáveis incertas no ano i , o vetor das variáveis incertas no ano I_{i+1} é dado por:

$$I_{i+1} = I_i + \Delta_i \quad (5.1)$$

onde:

Δ_i é um vetor de variáveis aleatórias que representa a variação de cada variável do problema de um ano para o seguinte.

Para representar a dependência entre as variáveis, o vetor Δ_i é calculado por meio da Equação (5.2).

$$\Delta_i = D\delta_i \quad (5.2)$$

onde:

δ_i é o vetor das variáveis aleatórias independentes;

D é a matriz que representa a dependência entre as variáveis incertas.

Este modelo tem por intuito representar dependências entre as variáveis. Por exemplo, o crescimento da carga em uma determinada região pode estimular o crescimento também nas regiões vizinhas, ou o preço da energia em uma dada região tende a afetar os preços também na vizinhança.

Ao fim deste procedimento são obtidas duas funções de distribuição de probabilidades conjuntas (aumento das cargas e preço da energia). Estas funções são utilizadas em simulações de Monte Carlo (Manno, 1999) para geração de cenários alternativos de atendimento dos clientes.

5.1.4 Modelo de Variação da Potência Produzida pela Unidade de Geração de Energia Eólica

Neste trabalho foram consideradas unidades eólicas como inserção de geração distribuída no sistema de distribuição de energia elétrica. A escolha destas unidades foi feita devido à simplicidade com a qual as mesmas podem ser tratadas e à disponibilidade de dados referentes à turbinas eólicas comerciais e potencial eólico do estado de Minas Gerais (do Amarante et al., 2010).

A variação na velocidade do vento provoca considerável variação na potência produzida por uma turbina eólica. Esta variação ocorre até mesmo em intervalos de tempo de segundos e é devida à localização geográfica da turbina, ao período do dia e do ano e à posição das pás da turbina.

Para descrever a velocidade do vento, a distribuição de probabilidade mais comumente utilizada é a distribuição de Weibull. A função distribuição de probabilidade da distribuição de Weibull é dada pela Equação (5.3) (Bollen and Hassan, 2011).

$$F(t) = 1 - \exp\left(-\left(\frac{t}{\theta}\right)^m\right) \quad (5.3)$$

onde:

θ é o valor característico;

m é o fator de forma.

Neste trabalho a distribuição de Weibull é utilizada para modelar a variação na potência produzida pela turbina eólica. Esta distribuição é utilizada na geração de cenários alternativos criados por simulações de Monte Carlo.

A mesma forma como foi tratada a variação da potência gerada pela turbina eólica pode ser utilizada para unidades de geração distribuída que utilizam diferentes tecnologias. Nestes casos, deve-se fazer a alteração da distribuição de probabilidade utilizando a mais adequada para modelar a variação da potência gerada pela unidade de GD.

5.1.5 Simulação de Monte Carlo

Neste presente trabalho, cenários alternativos de atendimento dos consumidores são gerados por meio de simulações de Monte Carlo (Manno, 1999). Este tipo de análise oferece como resultado indicadores relevantes sobre o sistema como estabilidade, robustez, custo de instalação/operação esperados e confiabilidade. Além disso, os resultados obtidos nas simulações de Monte Carlo serão utilizados para identificar pontos críticos do sistema e gerar fortalecimentos da rede nestes pontos.

5.2 Algoritmos Propostos

Nesta seção são discutidos os algoritmos propostos para o planejamento de sistemas de distribuição de energia elétrica. Atualmente existem duas versões disponíveis, uma mono-objetivo e outra multiobjetivo.

5.2.1 AG Mono-objetivo

O algoritmo genético mono-objetivo utilizado neste trabalho é o mesmo proposto em Carrano et al. (2010). Neste algoritmo é feita uma representação vetorial de redes que permite definir operadores para otimização de redes que se assemelham aos operadores utilizados em espaço contínuo. A métrica proposta que define as redes no espaço contínuo é chamada *T-norm* e é descrita na Seção 4.1.

Dada a representação das redes no espaço contínuo, as operações típicas deste espaço que podem ser definidas para redes são:

- geração de pontos a distâncias pré-definidas;
- exploração de vizinhanças e busca local;
- interpolação em linha;
- busca unidimensional.

As operações citadas acima podem ser usadas para obter operadores de nicho, cruzamento e mutação. Os operadores desenvolvidos em Carrano et al. (2010) e utilizados neste trabalho garantem que as redes obtidas sejam factíveis. Estes operadores são citados na Tabela 5.1. Para maiores detalhes dos mesmos, a referência Carrano et al. (2010) deve ser consultada.

Tabela 5.1: Operadores desenvolvidos no algoritmo genético mono-objetivo.

Operador	Operação em que se baseia
Mutação 1 - “Large-scale mutation”	Geração de pontos a distâncias pré-definidas
Mutação 2 - “Local search mutation”	Exploração de vizinhanças e busca local
Cruzamento 1 - “Quadratically-biased crossover”	Interpolação em linha
Cruzamento 2 - “Golden section crossover”	Interpolação em linha
Cruzamento 3 - “Optimum enhancement crossover”	Busca unidimensional

Os operadores desenvolvidos são propostos para a criação de um algoritmo genético que se torna genérico para otimização de redes em árvore não sendo necessário nenhum tipo de codificação especial. Eles também podem ser utilizados na implementação de outros algoritmos evolucionários dedicados ao problema de redes como algoritmos imuno-inspirados, particle swarm optimization e evolução diferencial.

O processo de otimização para o caso mono-objetivo é feito considerando a minimização do custo monetário da rede – Equação 3.7.

5.2.2 AG Multiobjetivo

Para o problema multiobjetivo foi proposta uma implementação do NSGA-II utilizando os mesmos operadores de cruzamento e mutação descritos para o caso mono-objetivo. Os operadores característicos do NSGA-II (*fast nondominated sorting*, *crowding distance* e *crowded comparison*) são mantidos. O processo de otimização é feito para minimização do custo monetário da rede e minimização do custo de faltas da rede (maximização da confiabilidade), Equação (3.7) e Equação (3.11), respectivamente.

Além dos operadores básicos empregados nestes algoritmos, foram propostos alguns operadores específicos, concebidos com base na estrutura do problema. Estes operadores, por lidarem com questões particulares do problema, tendem a aumentar a eficiência dos algoritmos utilizados (Carrano et al., 2006). Uma breve descrição de cada um deles é apresentada nas próximas seções. O fluxo de carga executado como passo intermediário em cada um deles é calculado utilizando a *toolbox* Matpower 4.0 (Zimmerman et al., 2011). Nos casos onde somente uma unidade de geração deve ser posicionada o método adotado para cálculo do fluxo é o proposto em Teng (2003). No caso de posicionamento de duas ou mais unidades de geração, o cálculo é feito pelo método de Newton Raphson.

5.3 Operadores Específicos Propostos

Quatro operadores específicos foram propostos para definição dos tipos/capacidades de condutores no sistema de distribuição. Estes operadores lidam com os seguintes pontos relevantes:

1. atribuição das capacidades dos condutores com base nos critérios de capacidade de corrente (CCC) e queda de tensão (CQT);
2. aprimoramento dos custos;
3. aprimoramento da robustez;
4. aprimoramento da confiabilidade.

O primeiro operador é uma ferramenta utilizada para redução do espaço dimensional do problema e os três últimos operadores são operadores de busca local determinística. Estes operadores são discutidos na sequência.

5.3.1 Operador de Atribuição da Capacidade de Condutores

As capacidades dos condutores devem ser tratadas como variáveis de otimização, que fazem parte do problema assim como os locais onde os condutores devem ser instalados. Em boa parte dos trabalhos, este dimensionamento é realizado juntamente com o projeto da rede, como variáveis independentes (Ramírez-Rosado and Bernal-Agustín, 1998; Carrano et al., 2007a, 2006; Tarôco et al., 2010; Souza et al., 2011). Esse tipo de abordagem, apesar de modelar de forma mais precisa o problema, aumenta consideravelmente o espaço de busca do problema de otimização. Supondo a existência de n nós (carga e alimentação) e a disponibilidade de apenas um tipo de condutor, o número de soluções com estrutura factível que podem ser obtidas é definido pela Equação (5.4) (Cayley, 1889).

$$T_{sol} = n^{n-2} \quad (5.4)$$

Caso o número de tipos/capacidades de condutores disponíveis seja expandido para t tipos de cabos, então o número de soluções com estrutura viável passa ser definido pela Equação (5.5), que é consideravelmente maior que o número de soluções definido pela Equação (5.4) para $t > 1$.

$$T_{sol} = n^{n-2} \cdot t^{n-1} \quad (5.5)$$

Esse aumento do número de combinações torna o problema consideravelmente mais difícil e pode reduzir substancialmente a chance de se obter soluções ótimas. Baseado nesse aspecto, foi proposto um operador determinístico que faz a atribuição das capacidades dos condutores baseado nos critérios de capacidade de corrente (CCC) e queda de tensão (CQT). Para realização dessa atribuição são executados os seguintes passos¹:

1. Atribuir o cabo de menor capacidade a todos os ramos.
2. Executar o fluxo de carga DC.
3. Atribuir a cada ramo o cabo com a menor capacidade capaz de atender a corrente

¹Todo o processo é realizado para o cenário de carga esperado (mais provável).

encontrada no passo 2.

4. Executar o fluxo de carga AC.
5. Atualizar os ramos considerando as correntes encontradas no passo 4.
6. Enquanto o perfil de tensão não for atendido ($< 0.92\text{pu}$):
 - (a) Ordenar os ramos em ordem decrescente de perdas.
 - (b) Substituir o cabo utilizado no ramo com mais perdas por um cabo de capacidade imediatamente superior. Caso já esteja sendo utilizado o cabo de maior capacidade, passar para o próximo ramo da lista, e assim sucessivamente.
 - (c) Executar o fluxo de carga AC.

Neste procedimento, os passos 1 a 5 são executados uma única vez, e garantem o atendimento do CCC. Já o passo 6 é iterativo, e atualiza os cabos nos ramos até que o perfil de tensão atenda ao CQT. A adequação ao CCC antes do CQT se justifica pelo fato de esse bloco demandar a execução de apenas dois fluxos de carga (um AC e um DC) e por ele definir uma solução inicial consideravelmente melhor para o passo 6, que pode demandar várias execuções do algoritmo de fluxo AC. Além disso, como o passo 6 apenas aumenta a capacidade dos condutores, fica garantido que as restrições do CCC, atendidas nos passos de 1 a 5, não se tornam violadas.

O fluxograma da Figura 5.1 mostra de forma esquemática o operador de atribuição da capacidade de condutores.

O tempo necessário para execução desse procedimento pode ser reduzido se a solução final de cada fluxo de potência for utilizada como condição inicial da próxima execução do algoritmo de fluxo. O fluxo DC empregado nos passos 2 e 3 melhora o condicionamento do sistema que será resolvido no passo 4, reduzindo o tempo necessário para sua solução.

Nos algoritmos propostos, o operador de atribuição da capacidade de condutores é executado antes da avaliação de cada solução. Portanto, os cabos utilizados nos ramos

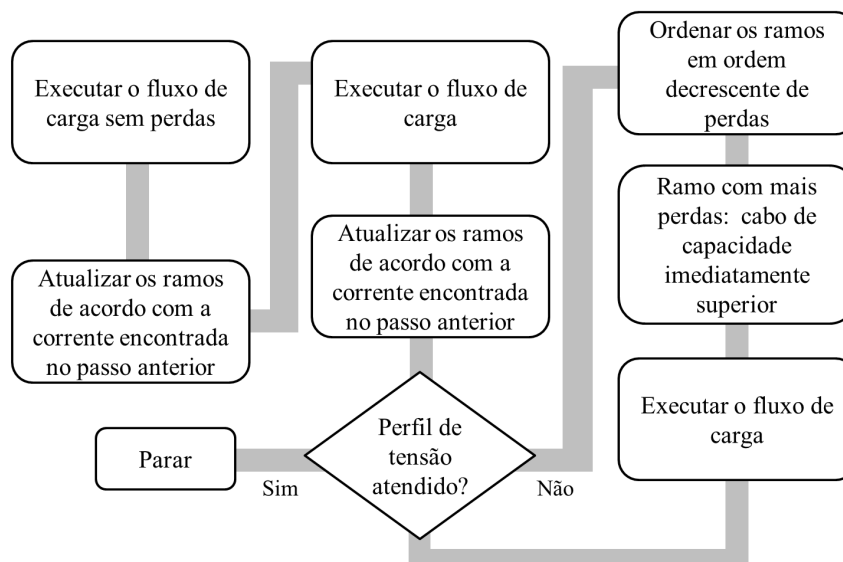


Figura 5.1: Operador de atribuição da capacidade de condutores.

de cada solução da população são atualizados antes da avaliação das Equações (3.7) e (3.11).

5.3.2 Operador de Aprimoramento dos Custos

Os cabos obtidos pelo Operador de Atribuição da Capacidade de Condutores (Seção 5.3.1) possuem as capacidades mínimas que garantem o atendimento dos critérios de capacidade de corrente e queda de tensão. No entanto, estes cabos não são necessariamente os melhores sob o ponto de vista de custo: muitas vezes o aumento de custo causado pela substituição de um dado condutor por um de maior capacidade é compensado pela redução das perdas proporcionada por esta troca.

Tendo em conta o custo monetário da rede, Equação (3.7), foi proposto um operador que tenta determinar a capacidade mais adequada para o cabo utilizado em cada ramo da rede. Este operador se baseia nas seguintes operações:

1. Ordenar os ramos em ordem decrescente de perdas.
2. Para cada ramo da rede:
 - (a) Enquanto houver melhora no custo da rede:
 - i. Substituir o cabo utilizado no ramo por um cabo de capacidade imediatamente superior.
 - ii. Se o custo da nova solução for pior que o da anterior, reverter o cabo empregado no ramo para o último utilizado (capacidade imediatamente inferior).

Esse procedimento é aplicado às soluções obtidas pelos algoritmos genéticos utilizados, não sendo portanto utilizado durante a execução do algoritmo. Apesar de demandar várias avaliações de solução, esse número é baixo quando comparado ao número de avaliações gastas pelo algoritmo, tendo em vista que o número de soluções retornadas pelo algoritmo é, em geral, pequeno.

A Figura 5.2 mostra de forma esquemática o operador de aprimoramento dos custos.

5.3.3 Operador de Aprimoramento da Robustez

A robustez de uma rede de distribuição está relacionada à sua capacidade em lidar com cargas distintas das inicialmente previstas na etapa de projeto. Como mostrado em Tarôco et al. (2010), esta robustez pode ser modelada por meio da capacidade de corrente excedente nas linhas de distribuição do sistema. Nesse sentido, é possível notar que o Operador de Aprimoramento dos Custos tem efeito positivo na robustez do sistema, uma vez que ele aumenta a capacidade de alguns dos condutores. No entanto, a real robustez do sistema só pode ser estimada por meio de simulações de Monte Carlo, onde várias condições distintas de carga e custo de atendimento são testadas.

Foi proposto um operador que utiliza os resultados obtidos nas simulações de Monte Carlo para aprimoramento da robustez do sistema. Esse operador é aplicado a cada

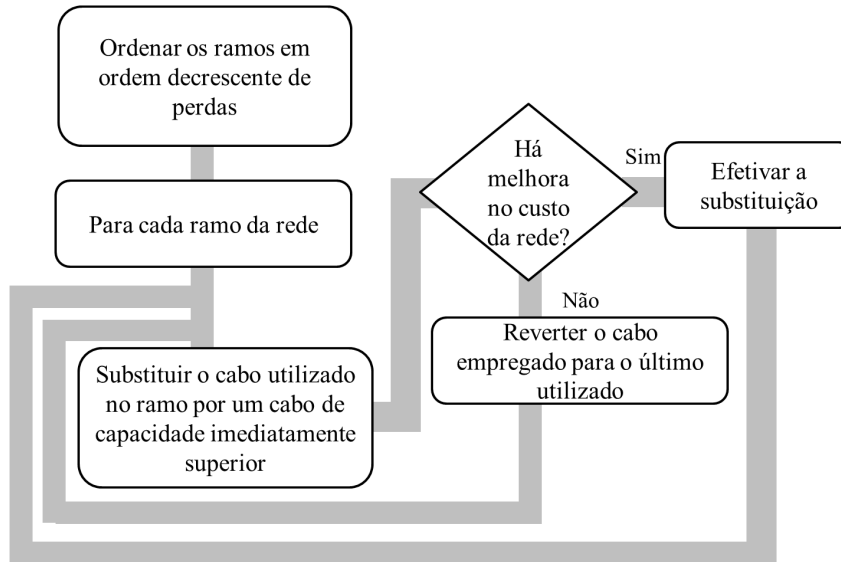


Figura 5.2: Operador de aprimoramento dos custos.

uma das soluções eficientes obtidas após a execução do Operador de Aprimoramento dos Custos, e consiste dos seguintes passos:

1. Executar simulações de Monte Carlo para N cenários distintos das variáveis aleatórias, seguindo as funções de probabilidade descritas na Seção 5.1.
2. Ordenar os ramos em ordem decrescente de taxa de inactibilidade, sendo a taxa de factibilidade do ramo i (ti_i) definida por:

$$ti_i = \frac{nc_{ins}(i)}{nc_{total}} \quad (5.6)$$

onde:

nc_{ins} é o número de cenários em que o ramo i não foi capaz de suportar a corrente; nc_{total} é o número total de cenários analisados.

3. Caso a maior taxa de inactibilidade seja maior que zero ($\max_i(ti_i) > 0$) e o cabo

utilizado no ramo de maior taxa de inactibilidade não seja da maior capacidade disponível:

- (a) Substituir o cabo do ramo com maior taxa de inactibilidade pelo cabo de maior capacidade dentre as seguintes opções: cabo de capacidade imediatamente superior ou cabo de menor capacidade que garanta ao ramo uma taxa de inactibilidade inferior à máxima taxa estabelecida pelo projetista (ti_{max}).
 - (b) Incluir a nova solução criada no conjunto de soluções a analisar, para análise posterior (essa solução será avaliada por este mesmo operador em uma iteração futura).
4. Caso a solução de entrada possua uma taxa de inactibilidade máxima superior à definida pelo projetista ($\max_i(ti_i) > ti_{max}$):
- (a) Descartar a solução.
5. Caso contrário:
- (a) Incluir a solução de entrada no conjunto de soluções candidatas.

Após a aplicação deste operador a todas as soluções, é realizada uma análise de dominância do conjunto de soluções candidatas, para exclusão das soluções dominadas. Ao fim deste processo, apenas soluções consideradas como robustas ($\max_i(ti_i) < ti_{max}$) são retornadas ao projetista.

Os passos descritos para o operador de aprimoramento da robustez são mostrados em forma de fluxograma na Figura 5.3.

Deve-se notar que este processo é convergente, uma vez que ao fim da avaliação de um conjunto de soluções, o número de soluções inseridas no conjunto a analisar é menor ou igual à dimensão deste conjunto. Além disso, o custo computacional despendido por este operador pode ser controlado pelo número de avaliações de função disponíveis.

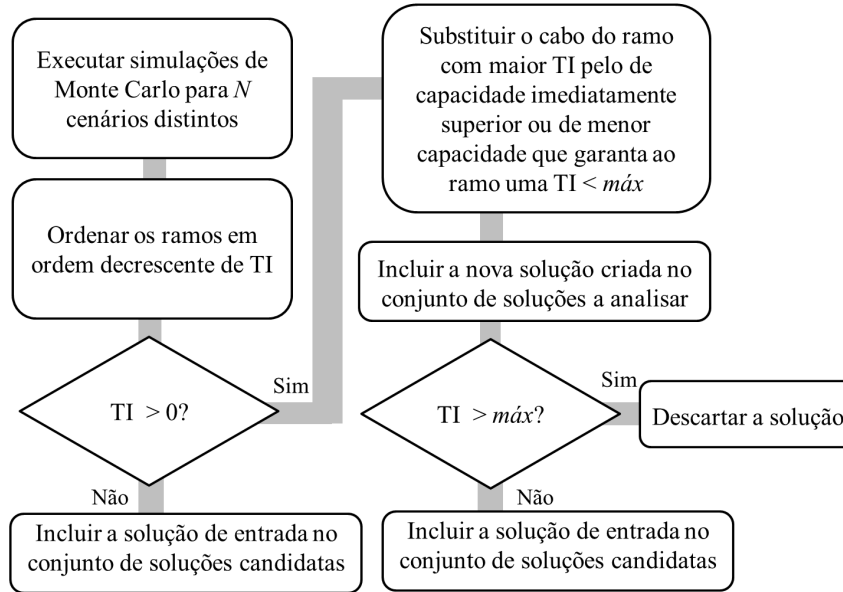


Figura 5.3: Operador de aprimoramento da robustez.

5.3.4 Operador de Aprimoramento da Confiabilidade

Os três operadores discutidos acima lidam apenas com as capacidades dos condutores, não alterando o tipo de condutor empregado. Devido a isso, a confiabilidade das soluções (Equação 3.11) não é afetada por estes operadores. No caso específico deste trabalho, estes operadores dimensionam apenas condutores nus, de menor confiabilidade.

Para aumentar a confiabilidade das soluções, foi proposto um novo operador, o operador de aprimoramento da confiabilidade, que substitui os cabos de alguns ramos específicos por cabos isolados, mais confiáveis. Este operador é aplicado a cada uma das soluções eficientes obtidas ao final do operador de aprimoramento da robustez, e é estruturado como segue:

1. Executar simulações de Monte Carlo para N cenários distintos das variáveis aleatórias, seguindo as funções de probabilidade descritas na Seção 5.1.

2. Ordenar os ramos em ordem decrescente de fluxo de potência.
3. Substituir o cabo nu do ramo com maior fluxo de potência por um cabo isolado de capacidade igual ou superior. Caso o cabo já seja isolado ou não exista cabo isolado de tal capacidade, passar para o próximo ramo da lista, e assim por diante.
4. Incluir a nova solução criada no conjunto de soluções a analisar, para análise posterior (essa solução será avaliada por este mesmo operador em uma iteração futura).
5. Caso a solução de entrada possua uma taxa de infactibilidade máxima superior à definida pelo projetista $\left(\max_i(tl_i) > tl_{max}\right)$:
 - (a) Descartar a solução.
6. Caso contrário:
 - (a) Incluir a solução de entrada no conjunto de soluções candidatas.

Assim como no último operador, após a aplicação deste procedimento a todas as soluções, é realizada uma análise de dominância do conjunto de soluções candidatas. Ao fim, tem-se também um conjunto de soluções robustas, mas com a função de confiabilidade consideravelmente melhorada. O custo computacional desse operador também pode ser controlado por um número máximo de avaliações disponíveis.

A Figura 5.4 mostra de maneira esquemática o operador de aprimoramento da confiabilidade.

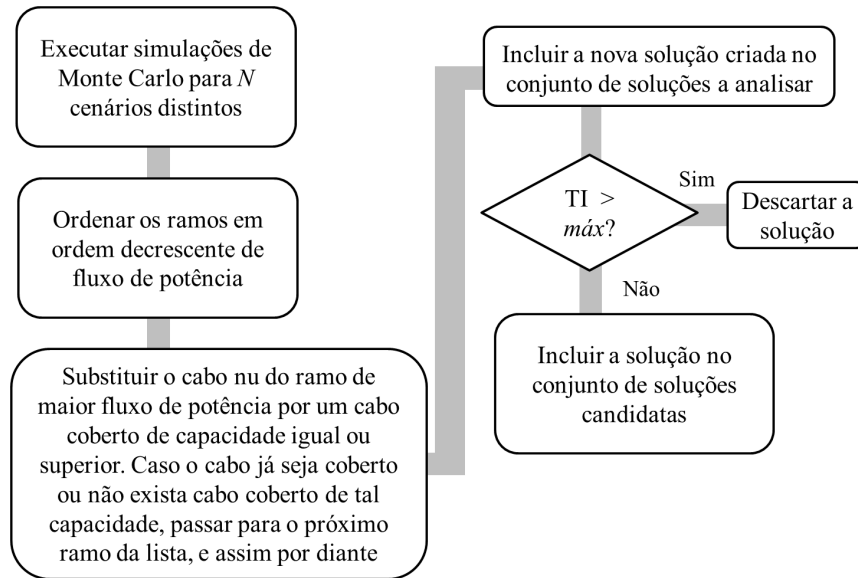


Figura 5.4: Operador de aprimoramento da confiabilidade.

5.4 Operador para Posicionamento de Unidades de Geração

Em muitos casos se faz necessário posicionar novas unidades de geração para ampliação da capacidade de atendimento de clientes. Esta situação pode ocorrer em cidades que estejam em crescimento econômico e populacional. O sistema de distribuição de energia elétrica presente nestes locais deve acompanhar o aumento da carga, mantendo uma capacidade ociosa para permitir aumentos futuros de carga em um conflito entre minimização dos custos de instalação no instante presente e minimização de futuras necessidades de re-projeto de unidades de geração (Carrano et al., 2005).

No trabalho de Carrano et al. (2005) um algoritmo híbrido formado por um algoritmo genético em conjunto com o algoritmo BFGS é utilizado para a solução do problema de expansão de redes de distribuição de energia elétrica. O algoritmo genético é utilizado para se obter a topologia da rede mantendo fixas as coordenadas da

subestação e o algoritmo BFGS é utilizado para obter o posicionamento da subestação considerando fixa a topologia da rede. O processo de otimização é feito considerando a minimização dos custos iniciais e futuros investimentos a serem aplicados.

Em Carrano et al. (2007b) é apresentada a versão multiobjetivo do algoritmo híbrido utilizada em Carrano et al. (2005). É considerada a minimização do custo monetário da rede e a maximização da confiabilidade. A estimação do conjunto Pareto-ótimo é feita associando as técnicas P_λ e P_ϵ .

Os procedimentos descritos nos trabalhos citados acima apresentam algumas desvantagens: (i) um algoritmo em separado deve ser implementado para posicionamento da subestação (quasi-Newton BFGS); (ii) não são capazes de lidar com regiões disjuntas para posicionamento da subestação; e (iii) requerem várias execuções do algoritmo genético e BFGS para encontrar uma única solução.

Um novo procedimento para posicionamento de novas unidades de geração foi proposto neste trabalho. Este operador realiza os seguintes passos: dadas as regiões candidatas para instalação das unidades de geração (\mathcal{R}), o número de unidades de geração (UG) a serem posicionadas (n) e um parâmetro de resolução (r):

1. Dividir as regiões candidatas em pontos igualmente espaçados, considerando a resolução r (Figura 5.5). Cada um desses pontos é considerado como uma posição candidata para as UGs.
2. Para cada uma das n unidades de geração a serem posicionadas:
 - (a) Posicionar a UG inicialmente na média aritmética das coordenadas dos nós que estão conectadas a ela.
 - (b) Encontrar a posição candidata mais próxima da posição encontrada no passo anterior (Figura 5.6).
3. Avaliar o fluxo de potência;

4. Verificar se a corrente em cada condutor não excede sua capacidade e, se necessário, faça o ajuste do tipo de condutor.
5. Para cada uma das n unidades de geração a serem posicionadas:
 - (a) Atualizar a posição da UG para a a média ponderada das coordenadas dos nós que estão conectadas a ela. Neste caso, o peso de cada nó é a quantidade de potência ativa em cada aresta que conecta o nó à UG;
 - (b) Encontrar a posição candidata mais próxima da posição encontrada no passo anterior.
6. Executar o operador de Atribuição da Capacidade de Condutores.

Este procedimento deve ser utilizado dentro do algoritmo, antes da avaliação da solução. O procedimento utiliza o operador de Atribuição da Capacidade de Condutores como um passo intermediário, não sendo portanto necessária a sua execução externa ao procedimento.

Diferentes modelos podem ser desenvolvidos para posicionamento da unidade de geração baseado no operador descrito. Quatro modelos distintos são propostos neste trabalho sendo chamados método A, método B, método C e método D. Estes modelos são descritos abaixo. Para os quatro métodos é necessário executar, como o passo inicial, a divisão das regiões candidatas em pontos igualmente espaçados, considerando a resolução r . Cada um desses pontos é considerado como uma posição candidata para as UGs.

Método A

1. Para cada uma das n unidades de geração a serem posicionadas:
 - (a) Posicionar a UG inicialmente na média aritmética das coordenadas dos nós que estão conectadas a ela.

- (b) Encontrar a posição candidata mais próxima da posição encontrada no passo anterior.
2. Executar o operador de Atribuição da Capacidade de Condutores.
3. Para cada uma das n unidades de geração a serem posicionadas:
 - (a) Atualizar a posição da UG para a média ponderada das coordenadas dos nós que estão conectadas a ela. Neste caso, o peso de cada nó é o custo de instalação, perdas e manutenção do cabo utilizado na aresta que conecta o nó à UG.
 - (b) Encontrar a posição candidata mais próxima da posição encontrada no passo anterior.
4. Executar o operador de Atribuição da Capacidade de Condutores.

Método B

1. Avaliar o fluxo de potência DC.
2. Para cada uma das n unidades de geração a serem posicionadas:
 - (a) Admitir como posição da UG a média ponderada das coordenadas dos nós que estão conectadas a ela. Neste caso, o peso de cada nó é a quantidade de potência ativa em cada aresta que conecta o nó à UG.
 - (b) Encontrar a posição candidata mais próxima da posição encontrada no passo anterior.
3. Executar o operador de Atribuição da Capacidade de Condutores.
4. Para cada uma das n unidades de geração a serem posicionadas:

- (a) Admitir como posição da UG a média ponderada das coordenadas dos nós que estão conectadas a ela. Neste caso, o peso de cada nó tem a seguinte expressão:

$$w = (P_{i,j})^{2.5} \cdot dt \cdot bc(n_{i,j}) \quad (5.7)$$

onde:

$P_{i,j}$ é a potência ativa que flui do nó i para o nó j ;

dt é o tempo de projeto considerado;

$bc(n_{i,j})$ é o custo de instalação de um condutor do tipo/capacidade n_i (em R\$/km) utilizado na conexão do nó i para o nó j .

- (b) Encontrar a posição candidata mais próxima da posição encontrada no passo anterior.

5. Executar o operador de Atribuição da Capacidade de Condutores.

Método C

1. Para cada uma das n unidades de geração a serem posicionadas:

- (a) Posicionar a UG inicialmente na média aritmética das coordenadas dos nós que estão conectadas à ela.
- (b) Encontrar a posição candidata mais próxima da posição encontrada no passo anterior.

2. Avaliar o fluxo de potência DC.

3. Verificar se a corrente em cada condutor não excede sua capacidade e, se necessário, faça o ajuste do tipo de condutor.

4. Avaliar o fluxo DC.

5. Para cada uma das n unidades de geração a serem posicionadas:
 - (a) Atualizar a posição da UG para a a média ponderada das coordenadas dos nós que estão conectadas à ela. Neste caso, o peso de cada nó é a quantidade de potência ativa em cada aresta que conecta o nó à UG.
 - (b) Encontrar a posição candidata mais próxima da posição encontrada no passo anterior.
6. Executar o operador de Atribuição da Capacidade de Condutores.

Método D

1. Para cada uma das n unidades de geração a serem posicionadas:
 - (a) Posicionar a UG inicialmente na média aritmética das coordenadas dos nós que estão conectadas à ela.
 - (b) Encontrar a posição candidata mais próxima da posição encontrada no passo anterior.
2. Avaliar o fluxo de potência DC.
3. Verificar se a corrente em cada condutor não excede sua capacidade e, se necessário, faça o ajuste do tipo de condutor.
4. Avaliar o fluxo de potência DC.
5. Para cada uma das n unidades de geração a serem posicionadas:
 - (a) Atualizar a posição da UG para a a média ponderada das coordenadas dos nós que estão conectadas à ela. Neste caso, o peso de cada nó é a quantidade de potência ativa em cada aresta que conecta o nó à UG.
 - (b) Encontrar a posição candidata mais próxima da posição encontrada no passo anterior.

6. Avaliar o fluxo de potência AC.
7. Para cada uma das n unidades de geração a serem posicionadas:
 - (a) Atualizar a posição da UG para a média ponderada das coordenadas dos nós que estão conectadas à ela. Neste caso, o peso de cada nó é a quantidade de potência ativa em cada aresta que conecta o nó à UG.
 - (b) Encontrar a posição candidata mais próxima da posição encontrada no passo anterior.
8. Executar o operador de Atribuição da Capacidade de Condutores.

Os métodos para posicionamento de subestação/unidade de geração desenvolvidos fornecem as coordenadas da posição de cada subestação ou UG e também o fluxo em cada um dos condutores. Para todos os quatro métodos propostos, os resultados de uma execução do algoritmo de fluxo de potência são utilizadas como condição inicial para o subsequente. Isso reduz o custo computacional dos métodos.

Estes métodos permitem o tratamento de regiões candidatas disjuntas para instalação das unidades de geração. A necessidade de se considerar regiões candidatas disjuntas é justificada pela existência de acidentes geográficos, regiões urbanas ou áreas de alto custo de compra/desapropriação. Um exemplo disso é mostrado na Figura 5.7. O algoritmo de otimização proposto é capaz de lidar com esta situação.

Por fim, vale ressaltar que o parâmetro r está relacionado com a precisão com que o espaço é representado, afetando o número de posições candidatas a serem consideradas.

Quando comparado aos mecanismos anteriormente propostos, esses procedimentos trazem algumas vantagens:

- os procedimentos podem ser utilizados para posicionar múltiplas unidades de geração simultaneamente;
- os operadores são capazes de lidar com múltiplas regiões candidatas para instalação;

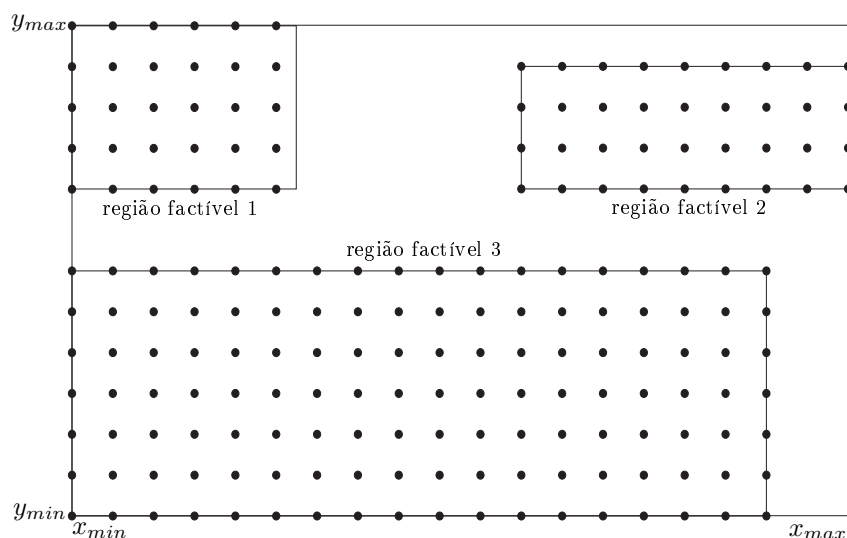


Figura 5.5: Três regiões factíveis disjuntas e suas posições candidatas.

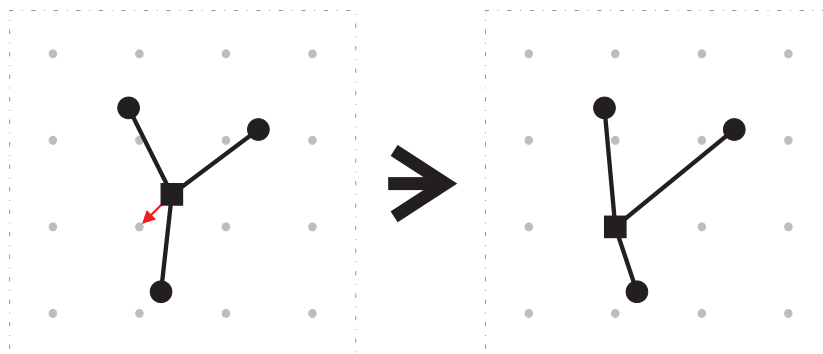


Figura 5.6: Escolhendo a posição candidata mais próxima para posicionar a unidade de geração.

- por serem aplicados dentro do algoritmo, antes do procedimento de avaliação, os operadores modelam melhor o acoplamento entre posicionamento das unidades de geração e topologia;
- o custo computacional despendido por estes métodos é consideravelmente menor que os anteriormente propostos (Carrano et al., 2005, 2007b), tendo em vista que não são necessárias múltiplas execuções do AG.

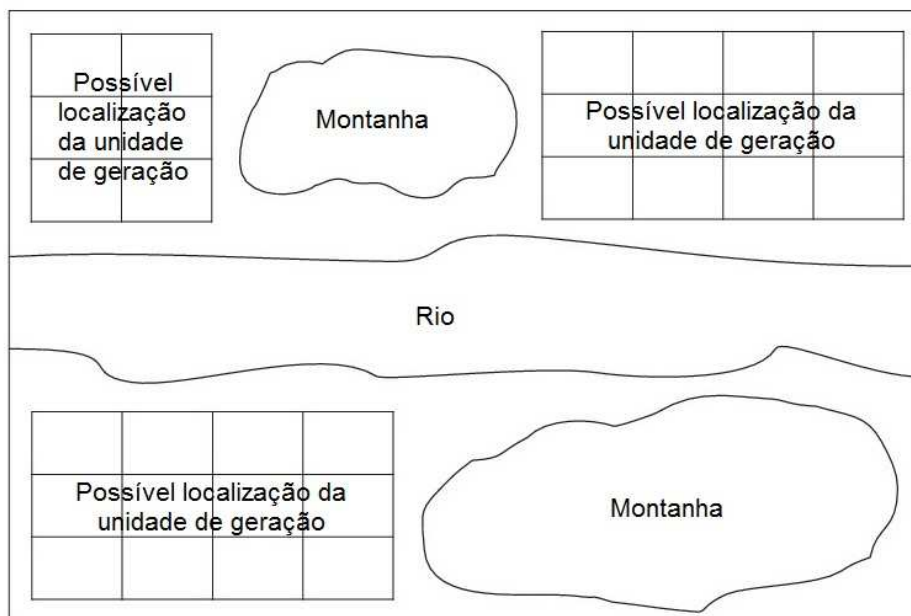


Figura 5.7: Exemplo de possíveis regiões para localização de unidade de geração quando existem acidentes geográficos.

5.5 Ferramenta de Planejamento de Sistemas de Distribuição

Os algoritmos e operadores discutidos ao longo deste capítulo foram utilizados para construir uma ferramenta de projeto de sistemas de distribuição. Essa ferramenta é capaz de realizar as seguintes atividades: (i) planejamento da estrutura da rede; (ii) atribuição dos tipos e capacidades dos condutores nos ramos; (iii) localização de novas unidades de geração, e; (iv) avaliação dos efeitos das incertezas no sistema projetado. São levados em conta critérios relevantes no projeto de sistemas de distribuição, a saber: (a) custo esperado de instalação e operação; (b) confiabilidade esperada, e; (c) robustez.

Essas atividades são realizadas por meio da seguinte sequência de tarefas:

1. Executar o AG para projeto da rede, atribuição das capacidades de condutores e posicionamento das unidades de geração².

²Tanto o algoritmo mono-objetivo quanto o algoritmo multiobjetivo podem ser utilizados. Os

2. Executar o Operador de Aprimoramento dos Custos para cada uma das soluções do atual conjunto de soluções a analisar (o conjunto de soluções a analisar é composto pelas soluções do passo 1 e as novas soluções obtidas no operador).
3. Executar uma análise de dominância do conjunto de soluções candidatas para exclusão das soluções dominadas.
4. Executar o Operador de Aprimoramento da Robustez para cada uma das soluções do atual conjunto de soluções a analisar.
5. Executar uma análise de dominância do conjunto de soluções candidatas para exclusão das soluções dominadas.
6. Executar o Operador de Aprimoramento da Confiabilidade para cada uma das soluções do atual conjunto de soluções a analisar.
7. Executar uma análise de dominância do conjunto de soluções candidatas para exclusão das soluções dominadas.

Ao fim desse procedimento espera-se ter o conjunto de soluções eficientes e robustas, tendo em conta os critérios de projeto estabelecido.

Capítulo 6

Resultados e Discussão

Neste capítulo são apresentados os resultados obtidos utilizando os algoritmos propostos em situações distintas de planejamento:

- Na primeira parte dos resultados, o algoritmo multiobjetivo (NSGA-II) foi utilizado para planejamento de redes menos onerosas, mais robustas e mais confiáveis em instâncias de 21, 100 e 300 nós. Nestes casos não foi considerado o posicionamento de novas unidades de geração e subestações.
- Foi feito um estudo para o ajuste da resolução r e definição do método de posicionamento de subestação/unidade de geração a ser adotado. Foram tratadas três instâncias: (i) um sistema real de 7 nós de carga, (ii) um sistema de 20 nós de carga e (iii) um sistema de 99 nós de carga. Neste estudo não foram analisadas a robustez e confiabilidade destes sistemas. O processo de otimização consiste apenas da execução do algoritmo genético seguida da aplicação do operador de aprimoramento dos custos.
- A versão mono-objetivo do algoritmo proposto foi utilizado para obtenção de resultados para os sistemas de 7 e 49 nós de carga para comparação com resultados obtidos na literatura. Neste caso não é analisada a robustez e confiabilidade das soluções.
- Nos resultados finais, a ferramenta de planejamento de sistemas de distribuição

desenvolvida e descrita na Seção 5.5 foi utilizada no planejamento do sistema com 49 nós de carga considerando uma subestação fixa e o posicionamento de 1 e 2 novas unidades para geração de energia eólica. Neste caso, foi utilizada a versão multiobjetivo do algoritmo genético desenvolvido.

6.1 Planejamento Multiobjetivo de Redes Confiáveis e Robustas

Inicialmente, a ferramenta de projeto multiobjetivo proposta foi aplicada ao planejamento de sistemas para que sejam menos onerosos, mais confiáveis e mais robustos. Nessas simulações não foi considerado o posicionamento de novas unidades de geração. Três sistemas foram tratados, um com 21 nós, já tratado anteriormente na literatura, um com 100 nós e um com 300 nós.

6.1.1 Sistema de 21 nós

O primeiro problema considerado foi o sistema de 21 nós da Figura 6.1, tratado em (Tarôco et al., 2010; Carrano et al., 2006; Carrano, 2007; Carrano et al., 2007a; Souza et al., 2011). O mesmo possui 20 nós de carga. Cinco nós deste sistema pertencem a uma rede já existente, enquanto que os outros 16 nós ainda devem ser conectados.

Neste caso o algoritmo proposto foi utilizado para determinar as novas conexões a serem instaladas, os tipos de cabos a serem utilizados nestas conexões e, se necessário, redimensionar a rede já existente. A formulação proposta na Seção 3.2.2 é utilizada sendo as funções objetivo dadas pelas Equações (3.7) e (3.11). O objetivo neste caso foi encontrar um conjunto de soluções robustas que sejam eficientes em relação ao custo monetário e ao custo de falhas. O horizonte de projeto considerado foi de 10 anos e a evolução anual dos módulos das cargas e dos custos de atendimento dos nós foram modelados como variáveis incertas, seguindo o modelo apresentado na Seção 5.1. Os parâmetros das funções de distribuição de probabilidade consideradas são mostrados




Figura 6.1: Sistema de 20 nós de carga.

na Tabela 6.1. Vale lembrar que estes parâmetros se referem às distribuições normais, definidas para cada nó.

Tabela 6.1: Parâmetros da distribuição de probabilidade.

	Taxa de crescimento de carga		Variação no preço da energia	
	Um ano	Dez anos	Um ano	Dez anos
Média	0,050	0,629	0,000	0,000
Desvio padrão	0,025	0,280	0,050	0,629

Os parâmetros utilizados no NSGA-II são mostrados na Tabela 6.2. As conexões podem ser feitas utilizando 9 tipos de condutores, cujas características elétricas são apresentadas na Tabela 6.3. Os sete primeiros condutores são nus (menos confiáveis) enquanto que os dois últimos são cobertos.

As soluções eficientes obtidas pelo NSGA-II passaram por um processo de melhoria composto pelos três novos operadores propostos: operador de aprimoramento dos custos, operador de aprimoramento da robustez e operador de aprimoramento da confiabilidade. Os conjuntos finais obtidos são apresentados nas Figuras 6.2(a) e 6.2(b), para o cenário médio e o pior cenário, respectivamente. Os dados foram normalizados com base nos maiores custos para o cenário médio, para facilitar a visualização.

São mostrados os resultados de três simulações da nova ferramenta (Proposto 1,

Tabela 6.2: Parâmetros utilizados no algoritmo NSGA-II.

Tamanho da população	50
Número máximo de avaliações de função	300.000 NSGA-II: 100.000 APR1: 100.000 APR2: 100.000
Probabilidade de cruzamento (por par)	0,80
Probabilidade de mutação (por indivíduo)	0,40
Operadores de cruzamento	2
Operadores de mutação	4
Tamanho máximo da população de arquivo	250
Taxa de infactibilidade aceitável	25%
Número de cenários na Simulação de Monte Carlo	1000

Tabela 6.3: Características dos condutores utilizados nas conexões.

Tipo de condutor	A	B	C	D	E
1	0,4853	1,6118	2.817	32.126,23	1.733,54
2	0,4679	1,0145	3.776	32.321,31	1.733,54
3	0,4505	0,6375	5.115	32.653,55	1.733,54
4	0,4428	0,5205	5.975	32.780,81	1.733,54
5	0,4331	0,4019	6.860	33.378,78	1.733,54
6	0,4237	0,3184	7.983	33.752,81	1.733,54
7	0,4026	0,2006	10.828	34.100,00	1.733,54
8	0,3037	0,8220	4.278	43.000,00	218,77
9	0,2467	0,2646	8.652	45.476,95	218,77

- A - Reatância (em Ω/km);
- B - Resistência (em Ω/km);
- C - Potência nominal (em kW);
- D - Custo de instalação (em $\$/\text{km}$);
- E - Custo de manutenção (em $\$/\text{km}/\text{ano}$).

Proposto 2 e Proposto 3) e as três simulações apresentadas em Tarôco et al. (2010) (Literatura 1, Literatura 2 e Literatura 3). Vale ressaltar que todas soluções mostradas são robustas sob o critério de robustez estabelecido neste trabalho.

No caso da ferramenta proposta, foram obtidas exatamente as mesmas 50 soluções nas três execuções realizadas. Já nos resultados observados na literatura, houve alguma variação entre as execuções. Por um lado, é possível notar que a ferramenta proposta

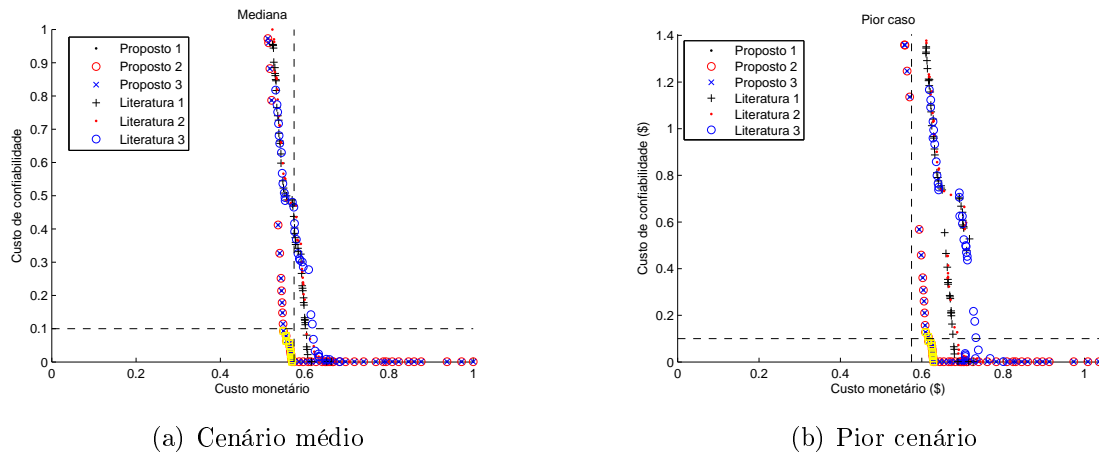


Figura 6.2: Sistema de 21 nós – Conjuntos de soluções finais obtidos para o sistema de 21 nós.

alcançou uma fronteira que domina as anteriormente obtidas. Esse aprimoramento dos resultados provavelmente se justifica por três aspectos:

- a redução do tamanho do espaço de busca do problema proporcionado pelo uso do operador de atribuição da capacidade de condutores aumentou a capacidade de convergência do algoritmo;
- o algoritmo proposto emprega operadores que utilizam explicitamente os resultados obtidos pelas simulações de Monte Carlo para gerar novas soluções. Este tipo de procedimento permite alcançar soluções robustas de melhor qualidade, uma vez que reduz consideravelmente o número de soluções não-robustas avaliadas;
- a ferramenta encontrada na literatura foi concebida para lidar com três objetivos (custo, confiabilidade e robustez). Considerar três objetivos aumenta a dimensão do objeto de interesse (conjunto de Pareto), fazendo com que sejam necessários mais pontos para uma amostragem adequada. Por consequência, a convergência do algoritmo fica prejudicada.

Por outro lado, existem algumas lacunas nas fronteiras obtidas. Essas lacunas também se justificam pelo uso de um operador de atribuição de condutores determinístico

ao invés de deixar as capacidades como variáveis livres de projeto: este tipo de abordagem impede a obtenção de algumas topologias, uma vez que o algoritmo NSGA-II não é capaz de encontrar soluções que possuam a mesma topologia e tipos de condutores distintos.

É possível notar um “joelho” na fronteira de soluções obtidas (soluções abaixo das linhas horizontal e vertical traçadas). Essas são as soluções que realmente constituem escolhas racionais, tendo em vista que todas as outras requerem um aumento grande em um dos objetivos para uma redução pequena no outro. Foram escolhidas as dez soluções mais bem espaçadas neste joelho (soluções em amarelo) como alternativas viáveis para implantação. O desempenho obtido por estas soluções é apresentado na Tabela 6.4.

Tabela 6.4: Sistema de 21 nós – Desempenho das redes destacadas na Figura 6.2(a).

Ind	$f_1 \times 10^6$	$f_2 \times 10^6$	$f_3 \times 10^6$	$f_4 \times 10^6$	f_5
12	1,4686	1,6284	1,9066	2,6134	0
13	1,4858	1,6464	1,6086	2,2210	0
14	1,4871	1,6472	1,2999	1,8288	0
15	1,5068	1,6668	1,1533	1,6347	0
16	1,5101	1,6694	0,9542	1,4035	0
18	1,5146	1,6732	0,6178	0,9079	0
19	1,5169	1,6742	0,4664	0,6978	0
20	1,5189	1,6764	0,2987	0,4843	0
21	1,5213	1,6789	0,1473	0,2983	0
22	1,5234	1,6809	0,0189	0,0264	0

Ind - Índice da solução;

f_1 - Mediana do custo monetário da rede (em \$);

f_2 - Custo monetário da rede para o pior caso (em \$);

f_3 - Mediana do custo de falha da rede (em \$);


f_4 - Custo de falha da rede para o pior caso (em \$);

f_5 - Taxa de infactibilidade.


Considerando por exemplo uma troca da solução 12 pela 22, é possível notar que a mediana do custo monetário da rede aumenta cerca de 3,7%, enquanto que o custo de confiabilidade diminui aproximadamente 99%. Portanto, a solução 22 aparenta ser uma solução adequada ao problema. Deve-se notar também que as razões observadas

entre as soluções para o caso médio e o pior caso são semelhantes nas duas funções estimadas.

As redes 12 e 22 são mostradas nas Figuras 6.3(a) e 6.3(b), respectivamente.



(a) Solução 12



(b) Solução 22

Figura 6.3: Sistema de 21 nós – Exemplo de soluções da Tabela 6.4.

Os resultados apresentados para a ferramenta proposta foram obtidos com, em média, 110.000 avaliações de função. Este número é consideravelmente inferior ao número máximo estabelecido que foi de 300.000, sendo 100.000 em cada etapa. Essa diferença se

justifica pelo fato dos operadores de aprimoramento serem convergentes. Eles conseguiram alcançar plena convergência com apenas 10.000 das 200.000 avaliações disponíveis.

6.1.2 Sistema de 100 nós

O sistema de 100 nós proposto em Carrano et al. (2006) foi adaptado para ser tratado neste trabalho. Este sistema possui 99 nós de carga. Foram necessárias adaptações porque a referência original não levava em conta a expansão das cargas ao longo do tempo. Foram considerados os mesmos tipos de cabos e as mesmas funções de distribuição de probabilidade para a evolução das cargas. Os parâmetros do algoritmos também foram os mesmos, exceto pelo número de avaliações de função, que foi ampliado para 1.500.000 avaliações (500.000 para o NSGA-II, 500.000 para o APR1 e 500.000 para o APR2).

Duas fronteiras Pareto obtidas são apresentadas nas Figuras 6.4(a) e 6.4(b), para o cenário médio e o pior cenário respectivamente. A primeira fronteira é composta de 274 soluções, enquanto que a segunda possui 265 soluções. Apesar de não serem idênticas, as duas fronteiras convergiram exatamente para a mesma região geométrica do espaço de objetivos, o que indica convergência. As pequenas diferenças apresentadas provavelmente se justificam pela limitação do tamanho do arquivo no NSGA-II (250 soluções).

Mais uma vez foi notada uma região na fronteira Pareto onde as soluções apresentam alternativas mais adequadas para a escolha (região inferior as linhas tracejadas na Figura 6.4(a)). Dez dessas soluções foram escolhidas e apresentadas na Tabela 6.5, para a primeira execução. As alternativas encontradas na segunda execução não são aqui apresentadas por serem muito semelhantes às obtidas na primeira.

As soluções 62 e 107 dessa tabela são apresentadas nas Figuras 6.5(a) e 6.5(b), respectivamente. Quando comparada à solução 62, a solução 107 tem seu custo monetário aumentado em cerca de 3,4% e seu custo de falha diminui em cerca de 99%. Quando comparada à solução mais barata dentre todas as obtidas, a solução 107 aumenta o

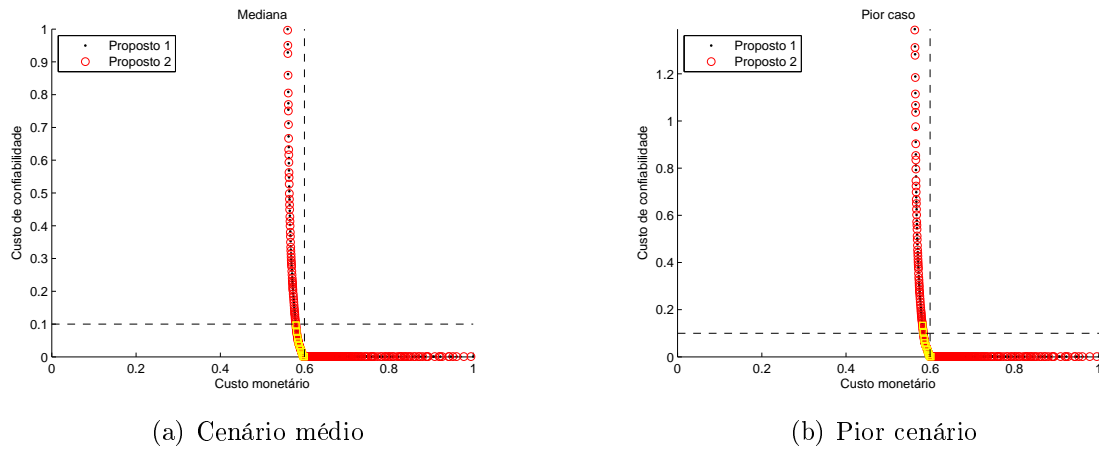


Figura 6.4: Sistema de 100 nós – Conjuntos de soluções finais obtidos para o sistema de 100 nós.

Tabela 6.5: Sistema de 100 nós – Desempenho das redes destacadas na Figura 6.4(a) (primeira execução).


Ind	$f_1 \times 10^6$	$f_2 \times 10^6$	$f_3 \times 10^6$	$f_4 \times 10^6$	f_5
62	6,8016	6,8269	4,2310	5,8364	0
67	6,8219	6,8467	3,3283	4,5219	0
72	6,8468	6,8712	2,5161	3,2954	0
77	6,8650	6,8893	1,9898	2,6195	0
82	6,8961	6,9203	1,5076	1,9849	0
87	6,9307	6,9548	1,0240	1,3495	0
92	6,9552	6,9792	0,6859	0,8952	0
97	6,9768	7,0008	0,3817	0,5098	0
102	6,9941	7,0181	0,1384	0,2011	0
107	7,0312	7,0547	0,0400	0,0559	0

custo monetário em cerca de 7,0%, enquanto reduz o custo de falhas em 99,9%.


Os resultados apresentados nesta seção foram obtidos com cerca de 580.000 avaliações de função (média das duas execuções).

6.1.3 Sistema de 300 nós

Um sistema de distribuição de energia elétrica com 300 nós foi gerado para avaliar a ferramenta em um problema de maior porte. Este sistema possui 299 nós de carga. Foram consideradas cargas iguais, distribuídas uniformemente num quadrado de $20 \times$



(a) Solução 62



(b) Solução 107

Figura 6.5: Sistema de 100 nós – Exemplo de soluções da Tabela 6.5.

20 km. Todos os parâmetros utilizados anteriormente foram repetidos aqui, exceto pelo número máximo da avaliações de função, que foi aumentado para 4.500.000 (1.500.000 no NSGA-II, 1.500.000 no APR1, 1.500.000 no APR2).

As fronteiras Pareto-ótimas obtidas em duas execuções são mostradas nas Figuras 6.6(a) e 6.6(b) (caso médio e pior caso). Foi obtida uma primeira fronteira com 558 soluções e uma segunda fronteira com 548 soluções, ambas sobre a mesma região do espaço de objetivos.

Assim como nos casos anteriores, 10 soluções do “joelho” da fronteira Pareto-ótima foram escolhidas como soluções candidatas para implantação. O índices de desempenho observados para estas soluções são apresentados na Tabela 6.6, para a primeira execução.




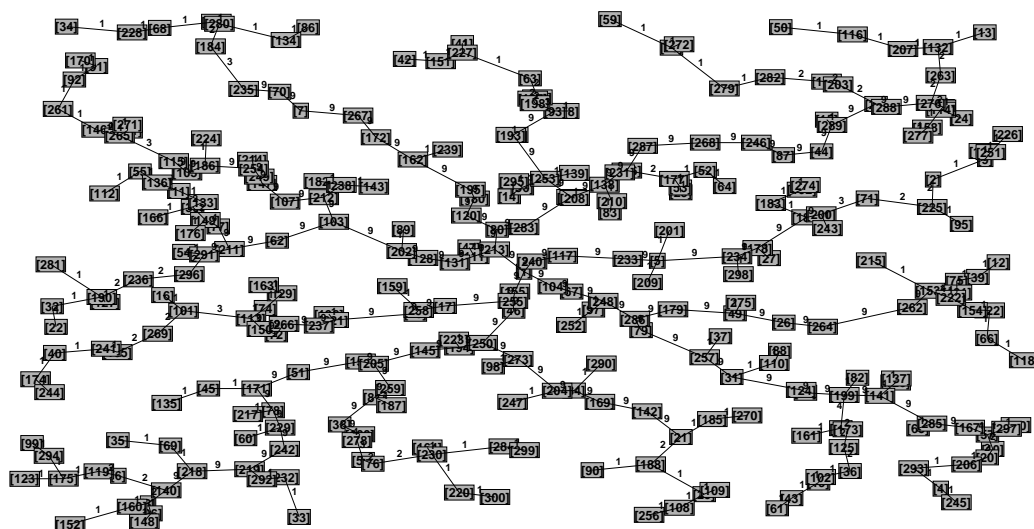
Figura 6.6: Sistema de 300 nós – Conjuntos de soluções finais obtidos para o sistema de 300 nós.

As redes referentes às soluções 132 e 310 da Tabela 6.6 são mostradas nas Figuras 6.7(a) e 6.7(b), respectivamente. Quando comparada a 132, a solução 310 aprimora o custo de falhas em 99%. Este ganho vem acompanhado de um aumento de 3,6% no custo monetário.

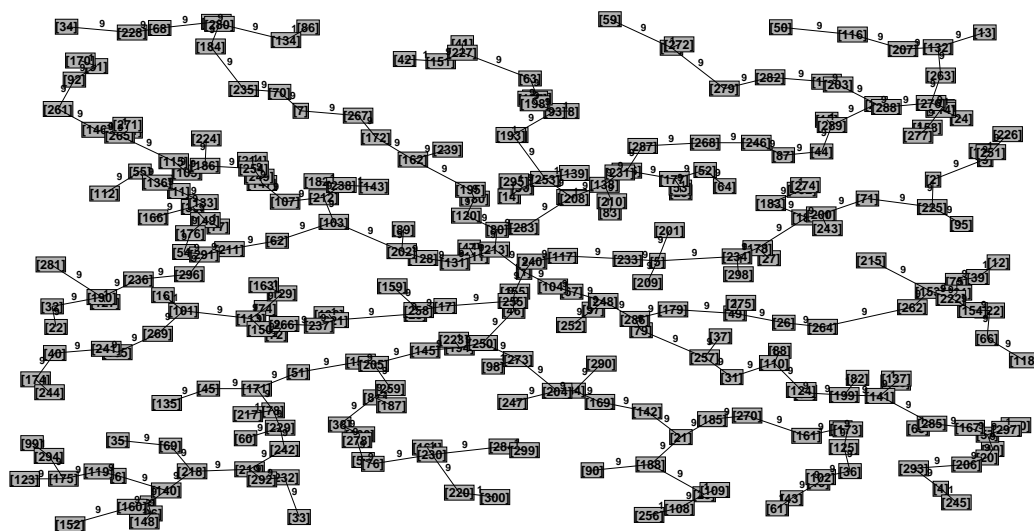
Para obtenção desses resultados foram gastas, em média 1.772.000 avaliações de função.

Tabela 6.6: Sistema de 300 nós – Desempenho das redes destacadas na Figura 6.6(a) (primeira execução)

Ind	$f_1 \times 10^7$	$f_2 \times 10^7$	$f_3 \times 10^7$	$f_4 \times 10^7$	f_5
132	1,0971	1,1116	1,3431	1,7119	0,0423
152	1,1011	1,1155	0,9795	1,2540	0,0412
172	1,1054	1,1198	0,7039	0,9107	0,0412
191	1,1090	1,1232	0,5409	0,6968	0,0412
211	1,1150	1,1292	0,3584	0,4549	0,0400
231	1,1201	1,1343	0,2460	0,3164	0,0400
251	1,1276	1,1417	0,1419	0,1827	0,0400
270	1,1322	1,1463	0,0777	0,0988	0,0400
290	1,1353	1,1495	0,0341	0,0431	0,0400
310	1,1368	1,1510	0,0128	0,0161	0,0400



(a) Solução 32



(b) Solução 310

Figura 6.7: Sistema de 300 nós – Exemplo de soluções da Tabela 6.6.

6.2 Ajuste da resolução r e definição do método de posicionamento de subestação/unidade de geração a ser adotado

Foi proposta uma adaptação dos algoritmos genéticos propostos para realizar o posicionamento de novas unidades de geração juntamente com o projeto da rede. Nessa adaptação, um módulo de posicionamento das unidades de geração é acoplado ao procedimento de avaliação da função, antes do operador de atribuição da capacidade dos condutores. Portanto, a cada avaliação de solução são realizados três passos: *(i)* posicionamento das unidades de geração; *(ii)* definição das capacidades dos condutores; *(iii)* avaliação das funções propriamente ditas.

O módulo de posicionamento da UG que deve ser acoplado ao procedimento de avaliação é um dos procedimentos apresentados na Seção 5.4. Foram propostos quatro procedimentos distintos, com o intuito de avaliar qual o mais adequado.

Quando comparado à abordagens anteriores (Carrano et al., 2005, 2007b), o procedimento proposto traz algumas vantagens:

1. permite posicionar várias UGs simultaneamente;
2. permite lidar com várias regiões candidatas disjuntas para instalação das UGs;
3. trata de forma mais adequada o acoplamento entre os problemas de projeto da rede e posicionamento da subestação;
4. tende a ser consideravelmente mais rápido.

Por outro lado, a discretização do espaço pode reduzir a qualidade das soluções obtidas. Além disso, os procedimentos propostos são todos determinísticos gulosos, o que pode levar a perda do ótimo global para o problema.

No estudo feito para o ajuste da resolução r e definição do método de posicionamento de subestação/unidade de geração a ser adotado foram tratadas três instâncias: *(i)* um

sistema real de 7 nós de carga, (ii) um sistema de 20 nós de carga e (iii) um sistema de 99 nós de carga. Não foram analisadas a robustez e confiabilidade destes sistemas. Portanto, o processo de otimização consiste apenas da execução do algoritmo genético mono-objetivo seguida da aplicação do operador de aprimoramento dos custos.

6.2.1 Ajuste da Resolução r

Inicialmente foi utilizado o modelo geral descrito na Seção 5.4 para ajuste do parâmetro de resolução r , que pode afetar o resultado obtido pelo modelo de alocação de unidades de geração. Este modelo geral deu origem aos métodos A, B, C e D, que serão analisados posteriormente.

O problema considerado neste ajuste foi um caso real confrontado pela CEMIG. Neste problema o sistema a ser tratado possui 7 nós de carga (Figura 6.8) e foi inicialmente tratado na literatura em Carrano et al. (2005). Este sistema está localizado no norte do estado de Minas Gerais, que é uma região em franco crescimento econômico e populacional. Uma nova unidade de geração deve ser instalada, já que o sistema não está sendo capaz de atender toda a demanda. Este sistema será referido ao longo deste texto como sistema de 7 nós de carga.

Neste problema, a unidade de geração pode ser localizada em qualquer ponto delimitado pelos valores máximos e mínimos das coordenadas x e y . Dois tipos de condutores puderam ser utilizados nas conexões. As características elétricas destes condutores são mostradas na Tabela 6.7. A unidade de geração é o nó 1 do sistema.

Foram testados os seguintes valores para o parâmetro r : $r = 4,00\text{km}$, $r = 2,00\text{km}$, $r = 1,00\text{km}$, $r = 0,50\text{km}$ e $r = 0,25\text{km}$. Foi considerado um horizonte de projeto de 10 anos, com o critério de parada definido como 5.000 avaliações de função. O fator de perda adotado é de 0,35 e taxa de juros de 10% ao ano.

Para as resoluções de $r = 4\text{km}$ e $r = 2\text{km}$ foram obtidos os mesmos resultados para as coordenadas da subestação e para o valor do custo monetário da rede. O aumento da resolução para 1km proporciona uma melhoria de 0,8% no custo monetário, resultado




Figura 6.8: Sistema real com 7 nós de carga.

Tabela 6.7: Características dos condutores – Sistema de 7 nós de carga

A	B	C	D	E	F	G	H
1	50	208	0,7394	0,2682	4.970	35.000,00	975,00
2	150	415	0,2469	0,2417	9.915	50.000,00	975,00

- A - Tipo de condutor;
- B - Diâmetro (mm^2);
- C - Corrente nominal (A);
- D - Resistência (Ω);
- E - Reatância (Ω);
- F - Potência nominal (kW);
- G - Custo de instalação ($\$/km$);
- H - Custo de manutenção ($\$/km/ano$).

que se mantém para as outras duas resoluções. Com base nesses resultados é possível notar que a resolução não apresenta efeito muito predominante no custo. Portanto, para o restante das simulações, foi considerado $r = 0,25km$.

6.2.2 Definição do método de posicionamento de subestação/unidade de geração a ser adotado

Para a definição do método de posicionamento de subestação/unidade de geração a ser adotado foram realizados inicialmente testes com o sistema de 7 nós de carga e métodos de posicionamento A, B, C e D. A partir dos resultados obtidos, foram selecionados dois métodos que apresentaram resultados mais satisfatórios para serem analisados em sistemas maiores (20 e 99 nós de carga). Os testes realizados para os sistemas de 7, 20 e 99 nós de carga foram feitos para diferentes situações de projeto, sendo que para cada uma delas o algoritmo foi executado dez vezes.

Para as simulações seguintes feitas para os sistemas de 7, 20 e 99 nós de carga, o fator de perda considerado foi de 0,664 e taxa de juros de 5% ao ano.

- Sistema de 7 nós de carga

O sistema de 7 nós de carga descrito na seção acima foi utilizado na primeira bateria de testes dos quatro métodos propostos para posicionamento das unidades de geração.

As simulações foram feitas considerando um horizonte de projeto de 10 anos. O critério de parada adotado foi o número máximo de avaliações de função (5.000 avaliações). Foram testadas três situações de projeto distintas. As regiões candidatas são dadas em km.

Situação de projeto 1

- Número de unidades de geração: 1;
- Regiões candidatas: limites mínimos e máximos de x e y descritos pelos pontos $[(0;0);(42;28)]$.

Situação de projeto 2

- Número de unidades de geração: 1;
- Regiões candidatas: quadrado definido por $[(0;0);(5;5)]$.

Situação de projeto 3

- Número de unidades de geração: 1;
- Regiões candidatas: retângulo definido por $[(37;23);(42;28)]$.

Para a primeira situação de projeto considerando o sistema de 7 nós de carga, o método B apresentou o melhor desempenho, obtendo a solução menos onerosa. Os outros três métodos obtiveram exatamente a mesma solução. Para a situação 2 o método A foi o que apresentou os melhores resultados, seguido pelo método B. Os métodos C e D ficaram empatados na terceira posição. Na situação 3 os quatro métodos apresentaram os mesmos resultados. Os resultados obtidos indicam que os métodos A e B apresentam melhor desempenho. Portanto, estes foram os métodos selecionados para serem utilizados nos testes de maior dimensão (20 e 99 nós de carga).

- Sistema de 20 nós de carga

O mesmo sistema com 20 nós de carga considerado na Seção 6.1 foi utilizado para validação das ferramentas propostas. As simulações foram feitas utilizando os mesmos parâmetros empregados no sistema de 7 nós de carga, exceto pelo número máximo de avaliações de função que foi alterado para 50.000. Os condutores disponíveis para projeto são os apresentados na Tabela 6.3. Foram consideradas quatro situações de projeto distintas.

Situação de Projeto 1

- Número de unidades de geração: 1;

- Regiões candidatas: limites mínimos e máximos de x e y descritos pelos pontos $[(0;0);(10,5;7,5)]$.

Situação de Projeto 2

- Número de unidades de geração: 1;
- Regiões candidatas: dois retângulos definidos por $[(0;0);(3;3)]$ e $[(10,5;7,5);(8,5;6)]$.

Situação de Projeto 3

- Número de unidades de geração: 2;
- Regiões candidatas: limites mínimos e máximos de x e y descritos pelos pontos $[(0;0);(10,5;7,5)]$.

Situação de Projeto 4

- Número de unidades de geração: 3;
- Regiões candidatas: limites mínimos e máximos de x e y descritos pelos pontos $[(0;0);(10,5;7,5)]$.

- Sistema de 99 nós de carga

O mesmo sistema de 99 nós de carga descrito na Seção 6.1 foi considerado nesta parte do trabalho. Para ser tratado aqui, a subestação do nó 1 foi removida do sistema. O critério de parada adotado foi o valor máximo de avaliações de função, definido em 250.000. Os outros parâmetros foram mantidos os mesmos das execuções anteriores.

Situação de Projeto 1

- Número de unidades de geração: 1;

- Regiões candidatas: limites mínimos e máximos de x e y descritos pelos pontos $[(0;0);(20;20)]$.

Situação de Projeto 2

- Número de unidades de geração: 2;
- Regiões candidatas: limites mínimos e máximos de x e y descritos pelos pontos $[(0;0);(20;20)]$.

Situação de Projeto 3

- Número de unidades de geração: 3;
- Regiões candidatas: limites mínimos e máximos de x e y descritos pelos pontos $[(0;0);(20;20)]$.

Análise dos Resultados

A comparação entre os métodos A e B de posicionamento de unidades de geração foi realizada com base nos resultados obtidos nas 10 execuções feitas para cada situação de projeto considerada para cada instância (7, 20 e 99 nós de carga). Foi adotado o seguinte procedimento de comparação:

1. Os valores finais de função obtidos nas execuções dos dois métodos para cada situação de projeto são armazenados em dois vetores, com dez posições cada.
2. Estes vetores são submetidos a um procedimento de *bootstrapping* (Efron, 1979), com 10.000 iterações, para extração das funções de distribuição de probabilidade empíricas das médias obtidas pelos métodos.
3. A média e o desvio padrão de cada uma dessas distribuições são então utilizados em um teste T de Welch (Welch, 1938), formulado com as seguintes hipóteses:

$$\begin{cases} H_0 & : \mu_A - \mu_B = 0 \\ H_1 & : \mu_A - \mu_B \neq 0 \end{cases}$$

O p-valor (p_v) obtido no teste leva a uma de 3 possíveis conclusões¹:

- se $p_v \leq 0,025$, então pode-se afirmar, com suporte estatístico, que o método A é melhor que o método B;
- se $0,025 \leq p_v \leq 0,975$, então não existe evidência estatística de diferença entre os métodos;
- se $p_v \geq 0,975$, então pode-se afirmar, com suporte estatístico, que o método B é melhor que o método A.

Na Tabela 6.8 são apresentados média, desvio padrão, diferença entre as médias e p-valores obtidos em todas as instâncias de 7, 20 e 99 nós de carga.

De acordo com os p-valores pode-se concluir que o método A venceu em 3 instâncias, o método B venceu em 2 instâncias e houve empate nas restantes. O método A venceu o método B nas instâncias B007S2, B020S4 e B099S3, o que indica que o mesmo apresenta melhores resultados quando mais de uma UG deve ser posicionada. Nas instâncias em que não existe comprovação estatística de diferença, foi possível notar que a média observada para o método A foi, em geral, mais baixa. Isso sugere um melhor desempenho desse método. Talvez, com o aumento da amostra, fossem observadas diferenças estatísticas nesses casos.

Com base nesses resultados optou-se por manter o Método A como o mecanismo padrão para posicionamento de UG neste trabalho. Este método é utilizado nos testes realizados nas seções seguintes.

¹O nível de significância estabelecido foi $\alpha = 0,05$.

Tabela 6.8: Parâmetros estatísticos das simulações para os métodos A e B.

Instância	Método A		Método B		$\overline{x_A} - \overline{x_B}$ (%)	p-valor
	$\overline{x_A} (\times 10^6)$	$s_A (\times 10^4)$	$\overline{x_B} (\times 10^6)$	$s_B (\times 10^4)$		
B007S1	5,4398	0,0000	5,3546	0,0000	1,5912	1,0000
B007S2	6,2226	0,0000	6,2933	0,0000	-1,1363	0,0000
B007S3	8,0054	0,0000	8,0054	0,0000	0,0000	0,5000
B020S1	1,3120	4,4245	1,2476	1,3344	5,1735	0,9994
B020S2	1,4228	3,8452	1,4293	3,4918	-0,4578	0,3482
B020S3	1,2238	5,8360	1,2591	3,8982	-2,8884	0,0656
B020S4	1,1000	2,7572	1,2016	3,2447	-9,2358	0,0000
B099S1	6,4358	3,1362	6,4218	1,1871	0,2179	0,8973
B099S2	6,4114	2,3357	6,4349	4,5757	0,3669	0,0853
B099S3	6,3844	2,2337	6,4159	3,6204	-0,4932	0,0167

B007S1 - 7 nós de carga – situação 1;

B007S2 - 7 nós de carga – situação 2;

B007S3 - 7 nós de carga – situação 3;

B020S1 - 20 nós de carga – situação 1;

B020S2 - 20 nós de carga – situação 2;

B020S3 - 20 nós de carga – situação 3;

B020S4 - 20 nós de carga – situação 4;

B099S1 - 99 nós de carga – situação 1;

B099S2 - 99 nós de carga – situação 2;

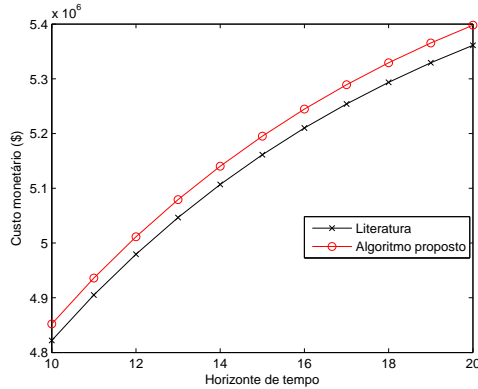
B099S3 - 99 nós de carga – situação 3.

6.3 Comparação de resultados obtidos pelo método proposto com resultados obtidos na literatura


A ferramenta de planejamento de sistemas de distribuição de energia elétrica desenvolvida neste trabalho e descrita na Seção 5.5 foi utilizada no planejamento mono-objetivo de dois sistemas distintos para comparação com os resultados obtidos em Carrano et al. (2005). Estes sistemas são: (i) o sistema de 7 nós de carga já utilizado em resultados anteriores e (ii) o sistema fictício de 49 nós de carga para o qual os dados podem ser encontrados em Carrano et al. (2005). Não foram executados os operadores de aprimoramento da robustez e confiabilidade porque o trabalho de (Carrano et al., 2005) não leva em conta estes aspectos.

Os resultados obtidos para o sistema de 7 nós de carga são mostrados na Figura 6.9. A Figura 6.9(a) mostra os valores do custo monetário da rede para um horizonte de tempo de 10 a 20 anos para o método da literatura e para a ferramenta desenvolvida.

A diferença entre os valores do custo monetário obtidos pelos dois métodos é mostrada na Figura 6.9(b).



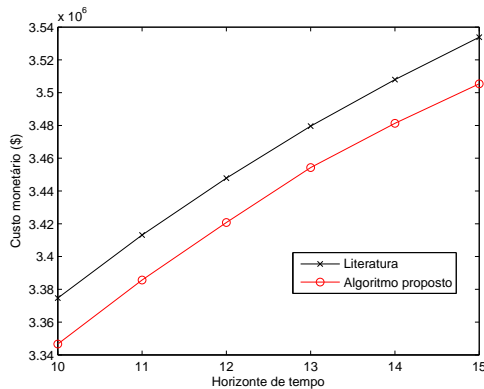
(a) Custo monetário da rede




(b) Diferença no custo monetário da rede

Figura 6.9: Sistema de 7 nós de carga - comparação com resultados da literatura.

Para o sistema de 49 nós de carga os resultados são mostrados na Figura 6.10.



(a) Custo monetário da rede



(b) Diferença no custo monetário da rede

Figura 6.10: Sistema de 49 nós de carga - comparação com resultados da literatura.

Para o sistema de 7 nós de carga os valores de custo monetário da rede são bem próximos, sendo que os valores obtidos pelo método proposto são em média 0,66% superiores. Para o sistema de 49 nós de carga os valores de custo monetário da rede também são bem próximos sendo que os valores obtidos pelo método proposto são em média 0,79% inferiores. Em relação ao tempo de máquina, para o sistema de 7 nós

de carga, o tempo necessário para execução do algoritmo proposto é dez vezes menor que o tempo gasto pelo método da literatura. Para o sistema de 49 nós de carga, este tempo é cinquenta vezes menor.

6.4 Aplicação da Ferramenta de Planejamento de Sistemas de Distribuição de Energia Elétrica no Projeto Multiobjetivo de Redes Considerando o Posicionamento de Novas Unidades de Geração de Energia Eólica

A ferramenta de planejamento de sistemas de distribuição de energia elétrica desenvolvida neste trabalho e descrita na Seção 5.5 foi utilizada no planejamento multiobjetivo do sistema com 49 nós de carga. O processo de otimização é feito para o cenário “mais provável” de carga em um horizonte de tempo de 10 anos. O crescimento da carga em cada nó da rede de distribuição, a variação do preço da energia e a variação da potência gerada pela turbina eólica foram modelados como variáveis incertas, seguindo o modelo apresentado na Seção 5.1. Os condutores utilizados para conexão dos nós e os dados referentes aos mesmos são mostrados na Tabela 6.9. O critério de parada adotado foi o número máximo de 500.000 avaliações de função. As novas unidades de geração a serem posicionadas são turbinas eólicas. Para os testes feitos foram utilizados dados da turbina E53 do fabricante Enercon disponível em Enercon (2013).

Na distribuição de Weibull utilizada neste trabalho para modelar a variação da velocidade do vento em determinada região, é necessária a determinação de dois parâmetros: m (fator de forma) e θ (valor característico). Na determinação destes parâmetros dados foram obtidos em mapas disponíveis no Atlas Eólico de Minas Gerais (do Amarante et al., 2010). O mapa 4.6 foi utilizado para verificar o valor esperado da

velocidade do vento sendo adotado o valor de 8 m/s. Consultando o mapa 4.10 para a região com velocidade do vento de 8 m/s tem-se o valor de m igual a 2. Com m igual a 2 e valor esperado 8 m/s, obtém-se θ igual a 9,0270. Estes dados são utilizados para criação de cenários distintos de potência entregue pela turbina eólica. Para os valores de m e θ obtidos, a distribuição de Weibull apresenta como média o valor de velocidade do vento de 8m/s. Consultando os dados da turbina E53 utilizada, a potência gerada pela mesma para esta velocidade é de 336kW. Este é o valor utilizado na especificação da capacidade da unidade de geração.

O número de cenários distintos do “mais provável” para os quais o desempenho das redes foi avaliado é 1.000 cenários. Foi considerado que a rede já possui uma subestação fixa sendo a posição da mesma dada pelas coordenadas (8, 75; 4, 25). Quando apenas uma UG deve ser posicionada, ela é representada pelo nó 1. Quando duas UGs devem ser posicionadas elas são dadas pelos nós 1 e 2.

Os gráficos mostrados nos resultados são para a mediana do custo monetário e do custo de confiabilidade para cada solução considerando os cenários distintos criados. Nestes gráficos são mostradas as soluções encontradas pelo NSGA-II e as soluções após a execução dos operadores de melhoria dos custos, robustez e confiabilidade. Diferentes situações de projeto são consideradas. Para cada situação de projeto são mostrados dados referentes à solução com maior custo monetário, à solução com maior custo de faltas e à solução considerada uma das melhores opções de rede a ser implantada. Esta rede é a solução destacada em cada figura que mostra o conjunto de soluções obtido. A escolha desta rede foi feita baseada no fato de ser uma rede com reduzido custo de confiabilidade e pequeno aumento no valor do custo monetário quando comparada com as redes com menor custo monetário obtidas. Foram feitas três execuções do algoritmo para cada situação de projeto considerada.

Tabela 6.9: Características dos condutores utilizados nas conexões

A	B	C	D	E	F
1	208	0,7394	0,2682	35000,00	975,00
2	415	0,2469	0,2417	50000,00	975,00
4	380	0,2646	0,2567	80000,00	100,00

A - Tipo de condutor;
 B - Corrente nominal (A);
 C - Resistência (Ω);
 D - Reatância (Ω);
 E - Custo de instalação ($\$/km$);
 F - Custo de manutenção ($\$/km/ano$).

6.4.1 Sistema de 49 nós de carga

Situação de projeto 1

- Número de unidades de geração: 1;
- Regiões candidatas: limites mínimos e máximos de x e y descritos pelos pontos $[(0;0);(19;10)]$.

Os resultados para a primeira execução do algoritmo para o sistema de 49 nós de carga e posicionamento de uma UG são mostrados na Figura 6.11 e na Tabela 6.10. A rede para a solução destacada na Figura 6.11 é mostrada na Figura 6.12.

Para as outras duas execuções do algoritmo, os resultados obtidos foram semelhantes.

Situação de projeto 2

- Número de unidades de geração: 2;
- Regiões candidatas: limites mínimos e máximos de x e y descritos pelos pontos $[(0;0);(19;10)]$.

Os resultados obtidos para a primeira execução da situação de projeto 2 são mostrados na Figura 6.13 e na Tabela 6.11. A rede para a solução destacada na Figura 6.13 é mostrada na Figura 6.14. As UGs estão conectadas ao nó 28 com condutor tipo 4.

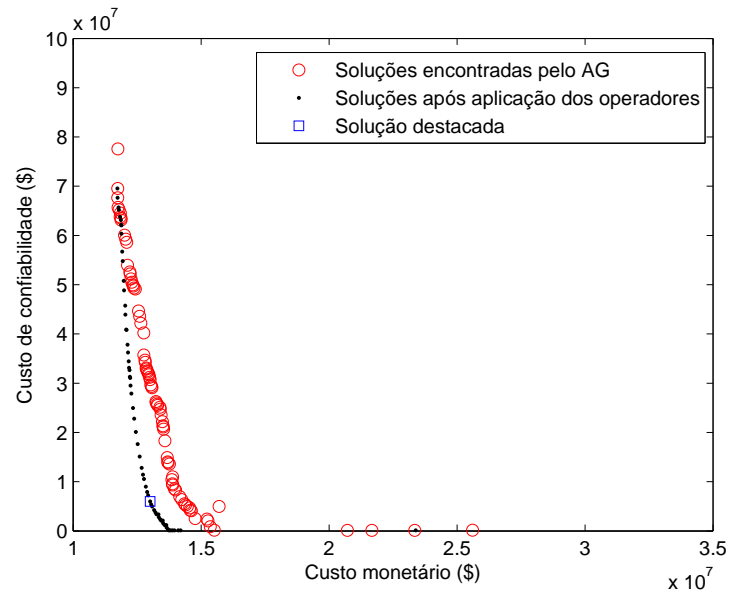


Figura 6.11: Soluções encontradas antes e depois da aplicação dos operadores - Situação 1 - Primeira execução - Sistema de 49 nós de carga.

Tabela 6.10: Sistema de 49 nós de carga – Situação 1 – Primeira execução

Solução	$x_{1s(i)}$	$y_{1s(i)}$	$f^{mc} \times 10^7$	$f^{fc} \times 10^7$	TI
1	6,25	8,25	1,1733	6,9539	0
2	6,25	8,25	1,3009	0,5981	0
3	4,25	8,25	2,3383	0,0106	0

$x_{1s(i)}$ - coordenada x da unidade de geração

1;

$y_{1s(i)}$ - coordenada y da unidade de geração

1;

f^{mc} - Custo monetário da rede (em \$);

f^{fc} - Custo de faltas da rede (em \$);

Solução 1 - Solução com maior f^{fc} ;

Solução 2 - Solução destacada;

Solução 3 - Solução com maior f^{mc} ;

TI - taxa de ineficiência.

Foram obtidos resultados bem próximos para as outras duas execuções do algoritmo.




Figura 6.12: Sistema de 49 nós de carga – Situação 1 – Primeira execução.




Figura 6.13: Soluções encontradas antes e depois da aplicação dos operadores - Situação 2 - Primeira execução - Sistema de 49 nós de carga.

Tabela 6.11: Sistema de 49 nós de carga – Situação 2 – Primeira execução

Solução	$x_{1s(i)}$	$y_{1s(i)}$	$x_{2s(i)}$	$y_{2s(i)}$	$f^{mc} \times 10^7$	$f^{fc} \times 10^7$	TI
1	14,25	4,25	14,25	4,25	1,1403	9,2950	0
2	14,25	4,25	14,25	4,25	1,3078	1,0194	0
3	14,25	4,25	14,25	4,25	1,4292	0,0110	0

$x_{2s(i)}$ - coordenada x da unidade de geração

2;

$y_{2s(i)}$ - coordenada y da unidade de geração 2.




Figura 6.14: Sistema de 49 nós de carga – Situação 2 – Primeira execução.

6.4.2 Análise de Resultados

De acordo com os resultados obtidos para o sistema de 49 nós de carga pode-se perceber que a execução dos operadores de aprimoramento dos custos, robustez e confiabilidade às soluções encontradas pelo NSGA-II levam a um conjunto de soluções com reduzido custo monetário e custo de confiabilidade na mesma faixa de valores do custo de confiabilidade das soluções encontradas pelo NSGA-II. Além disso, as redes

encontradas após a aplicação dos operadores são redes robustas com reduzida taxa de infactibilidade. A taxa de infactibilidade das redes consideradas opções mais adequadas para implantação é nula. A presença de soluções dominadas nos gráficos é devido ao fato de o resultado mostrado ser referente a mediana dos custos monetários e de confiabilidade das redes, baseada nos cenários das simulações de Monte Carlo. No algoritmo, a dominância foi caracterizada pelo desempenho das soluções no cenário médio.

Capítulo 7

Conclusões e Propostas de Continuidade

7.1 Conclusões

Neste trabalho o algoritmo NSGA-II foi utilizado para encontrar a topologia e condutores utilizados nas conexões dos nós de redes de distribuição de energia elétrica. Os objetivos considerados no processo de otimização foram minimização do custo monetário da rede e minimização dos custos de falta da rede. As soluções obtidas pelo algoritmo passaram por um processo de melhoria constituído dos seguintes operadores: operador de aprimoramento dos custos, operador de aprimoramento da robustez e operador de aprimoramento da confiabilidade. Estes operadores foram desenvolvidos com o objetivo de encontrar redes mais confiáveis e robustas. Testes foram realizados para sistemas com 21, 100 e 300 nós, não sendo considerado o posicionamento de novas unidades de geração. Em uma comparação feita com os resultados obtidos por (Tarôco et al., 2010) na instância de 21 nós observou-se resultados consideravelmente superiores.

Operadores para posicionamento de novas subestações/unidades de geração foram desenvolvidos. Estes operadores são inseridos no bloco de avaliação de função, não sendo necessárias portanto alterações no algoritmo de otimização. Este tipo de procedimento possui vantagens em relação à métodos propostos na literatura (Carrano et al., 2005, 2007b): permite o tratamento de regiões candidatas disjuntas para instalação das UGs;

não requer um algoritmo em separado para fazer a alocação da UG; podem ser utilizados para posicionar múltiplas unidades de geração simultaneamente; modela melhor o acoplamento entre posicionamento das unidades de geração e topologia, e; apresenta custo computacional consideravelmente menor.

Com relação aos testes multiobjetivo, onde não foi considerado o posicionamento de UGs, foi observada boa convergência das ferramentas propostas: em todas as instâncias testadas (21, 100 e 300 nós) nota-se que o algoritmo levou a conjuntos de soluções eficientes que convergem claramente para uma mesma região do espaço de busca, o que sugere forte repetibilidade dos resultados. Quando analisadas utilizando Simulações de Monte Carlo, as soluções encontradas foram extremamente robustas às incertezas nas variáveis de projeto, o que indica que a ferramenta é adequada para planejamento do sistema a médio e longo prazo. Por fim, os resultados obtidos foram consideravelmente superiores aos previamente obtidos na literatura em uma das instâncias consideradas.

Os métodos propostos para o posicionamento das unidades de geração e subestações foram avaliados em uma bateria de testes. Foram consideradas 3 instâncias (7, 20 e 99 nós de carga) com o posicionamento de 1 a 3 unidades de geração. Estes testes foram utilizados para avaliação dos quatro métodos de posicionamento propostos. Os resultados obtidos foram satisfatórios e foi possível definir um método de posicionamento mais adequado.

Foi feita uma comparação dos resultados obtidos para os sistemas com 7 e 49 nós de carga utilizando a versão mono-objetivo do algoritmo genético proposto com o trabalho de Carrano et al. (2005). Não foram analisadas a robustez e confiabilidade das soluções. Os resultados obtidos pelo método proposto foram bem próximos aos da literatura, sendo que para o sistema com 49 nós de carga, as redes encontradas pelo método proposto apresentaram custo monetário reduzido se comparadas com as encontradas pelo método da literatura.

Nos testes realizados para o sistema de 49 nós de carga com a versão multiobjetivo do algoritmo genético proposto e considerando como incertezas de projeto a variação

da carga em cada nó, a variação do preço da energia e a variação da potência fornecida pela unidade de energia eólica, foi possível observar que a ferramenta de planejamento de sistemas de distribuição desenvolvida neste trabalho é capaz de encontrar soluções mais confiáveis e robustas e com menor custo monetário se comparadas com as soluções encontradas pelo NSGA-II antes da aplicação dos operadores.

A ferramenta de planejamento de sistemas de distribuição desenvolvida neste trabalho mostrou-se uma ferramenta capaz de encontrar resultados satisfatórios para diferentes instâncias testadas obtendo redes robustas, confiáveis e menos onerosas.

7.2 Propostas de Continuidade

Para dar continuidade a este trabalho, pretende-se realizar as seguintes tarefas:

- Propor um algoritmo que considere a inserção de unidades de geração de pequeno porte para nível residencial.
- Pretende-se propor um algoritmo de agrupamento de nós de carga com o intuito de estabelecer micro-redes. Essas redes podem ser utilizadas como ilhas de operação no caso de falhas do sistema, o que pode ser altamente benéfico para sua robustez.
- Deve ser proposto um algoritmo capaz de planejar a instalação da redundância nas redes encontradas. Este algoritmo será responsável por alocar chaves normalmente fechadas (NF), chaves normalmente abertas (NA) e linhas de reserva, com o intuito de favorecer a operação do sistema em ilhas. Estas alternativas de configuração poderão ser utilizadas futuramente, durante a operação do sistema, para fins de reconfiguração e restauração.

Referências Bibliográficas

- Baker, J. E. (1987). Reducing bias and inefficiency in the selection algorithm. In *Proceedings of 2th International Conference on Genetic Algorithms and their application*, pages 14–21, Massachusetts, United States.
- Basu, M. (2013). Artificial bee colony optimization for multi-area economic dispatch. *International Journal of Electrical Power & Energy Systems*, 49:181–187.
- Bezdek, J. C., Pal, M. R., Keller, J., and Krisnapuram, R. (1999). *Models and Algorithms for Pattern Recognition and Image Processing*. MA: Kluwer.
- Bollen, M. H. J. and Hassan, F. (2011). *Integration of Distributed Generation in the Power System*. John Wiley & Sons.
- Bondy, J. A. and Murty, U. S. R. (1976). *Graph Theory with Applications*. MacMillan.
- Carrano, E. G. (2007). *Algoritmos Evolucionários Eficientes para Otimização de Redes*. PhD thesis, Universidade Federal de Minas Gerais, Belo Horizonte, Brasil.
- Carrano, E. G., Cardoso, R. T. N., Takahashi, R. H. C., Fonseca, C. M., and Neto, O. M. (2008). Power distribution network expansion scheduling using dynamic programming genetic algorithm. *IET Generation, Transmission and Distribution*, 2(3):444–455.
- Carrano, E. G., Guimaraes, F. G., Takahashi, R. H. C., Neto, O. M., and Campelo, F. (2007a). Electric distribution network expansion under load-evolution uncertainty using an immune system inspired algorithm. *IEEE Transactions on Power Systems*, 22(2):851–861.
- Carrano, E. G., Soares, L. A. E., Takahashi, R. H. C., Saldanha, R. R., and Neto, O. M. (2006). Electric distribution multiobjective network design using a problem-specific genetic algorithm. *IEEE Transactions on Power Delivery*, 21(2):995–1005.
- Carrano, E. G., Takahashi, R. H. C., Cardoso, E. P., Saldanha, R. R., and Neto, O. M. (2005). Optimal substation location and energy distribution network design using a hybrid GA-BFGS algorithm. *IEE Proceedings on Generation, Transmission and Distribution*, 152(6):919–926.

- Carrano, E. G., Takahashi, R. H. C., Fonseca, C. M., and Neto, O. M. (2007b). Bi-objective combined facility location and network design. In *Proceedings of 4th International Conference on Evolutionary Multi-criterion Optimization*, pages 486–500.
- Carrano, E. G., Takahashi, R. H. C., Fonseca, C. M., and Neto, O. M. (2010). Non-linear network optimization – An embedding vector space approach. *IEEE Transactions on Evolutionary Computation*, 14:206–226.
- Carvalho, P. M. S., Ferreira, L. A. F. M., Lobo, F. G., and Barruncho, L. M. F. (1998). Optimal distribution network expansion planning under uncertainty by evolutionary decision convergence. *Electric Power & Energy Systems*, 20:125–129.
- Catarina, A. S. and Bach, S. L. (2003). Estudo do efeito dos parâmetros genéticos sobre a solução otimizada e sobre o tempo de convergência em algoritmos genéticos com codificações binária e real. *Acta Scientiarum. Technology*, 25(2):147–152.
- Cayley, A. (1889). A theorem on trees. *Quart. Journal of Mathematics*, 23:376–378.
- Cho, M. Y., Hwang, J. C., and Chen, C. S. (1995). Customer short term load forecasting by using arima transfer function model. In *Proceedings of the International Conference on Energy Management and Power Delivery*, volume 1, pages 317–322.
- Chu, P. C. and Beasley, J. E. (1997). A genetic algorithm for the generalized assignment problem. *Computers and Operations Research*, 24(1):17–23.
- Corne, D. W., Jerram, N. R., Knowles, J. D., and Oates, M. J. (2001). PESA-ii: Region-based selection in evolutionary multiobjective optimization. *Proceedings of the Genetic and Evolutionary Computation Conference*.
- Cossi, A. M., Romero, R., and Mantovani, J. R. S. (2005). Planning of secondary distribution circuits through evolutionary algorithms. *IEEE Transactions on Power Delivery*, 20(1):205–213.
- Ćurčić, S., Strbac, G., and Zhang, X. P. (2001). Effect of losses in design of distribution circuits. *IEE Proceedings on Generation, Transmission and Distribution*, 148(4):343–349.
- de Castro, L. N. (2001). *Engenharia Imunológica: Desenvolvimento e Aplicação de Ferramentas Computacionais Inspiradas em Sistemas Imunológicos Artificiais*. PhD thesis, Universidade Estadual de Campinas, Campinas, Brasil.
- de Castro, L. N. and Timmis, J. (2003). Artificial immune systems as a novel soft computing paradigm. *Soft Computing*, 7(8):526–544.
- de Castro, L. N. and Von Zuben, F. J. (2002). Learning and optimization using the clonal selection principle. *IEEE Transactions on Evolutionary Computation*, 6(3):239–251.

- Deb, K., Pratap, A., Agarwal, S., and Meyarivan, T. (2002). A fast and elitist multiobjective genetic algorithm. *IEEE Transactions on Evolutionary Computation*, 6(2):182–197.
- Dias, M. V. X., Borotni, E. C., and Haddad, J. (2005). Geração distribuída no Brasil: oportunidades e barreiras. *Revista Brasileira de Energia*, 11(2).
- do Amarante, O. A. C., da Silva, F. J. L., and de Andrade, P. E. P. (2010). *Atlas Eólico Minas Gerais*. Cemig, Belo Horizonte, MG.
- Dorigo, M., Caro, G. D., and Gambardella, L. M. (1999). Ant algorithms for discrete optimization. *Artificial Life*, 5(3):137–172.
- Dorigo, M. and Gambardella, L. M. (1997). Ant colony system: A cooperative learning approach to the traveling salesman problem. *IEEE Transactions on Evolutionary Computation*, 1(1):53–66.
- Dorigo, M., Maniezzo, V., and Coloni, A. (1996). The ant system: Optimization by a colony of cooperating agents. *IEEE Transactions on Systems, Man and Cybernetics*, 26(1):1–13.
- Dugan, R. C., McGranaghan, M. F., Santoso, S., and Beaty, H. W. (2003). *Electrical Power System Quality*. McGrawHill, 2nd edition.
- Efron, B. (1979). Bootstrap methods: Another look at the jackknife. *The Annals of Statistics*, 7:1–26.
- Enercon (2013). [<http://www.wobben.com.br/upload/downloads/enercon-product-overview-ingles-1316009318.pdf>; acessado em 03-julho-2013].
- Fonseca, C. M. (1995). *Multiobjective genetic algorithms with applications to control engineering problems*. PhD thesis, University of Sheffield, UK.
- Fonseca, C. M. and Fleming, P. J. (1993). Genetic algorithms for multiobjective optimization: formulation, discussion and generalization. In *International Conference on Genetic Algorithms*, San Mateo, USA.
- Ganguly, S., Sahoo, N. C., and Das, D. (2009). Multi-objective planning of electrical distribution systems using particle swarm optimization. In *International Conference on Electric Power and Energy Conversion Systems*, pages 1–6, Sharjah.
- Ganguly, S., Sahoo, N. C., and Das, D. (2011). Mono-and multi- objective planning of electrical distribution networks using particle swarm optimization. *Applied Soft Computing*, 11(2):2391–2405.
- Goldberg, D. E. (1989). *Genetic Algorithms in Search, Optimization and Machine Learning*. Addison-Wesley.

- Goldberg, D. E. and Deb, K. (1991). A comparison of selection schemes used in genetic algorithms. *Foundations of Genetic Algorithms*, pages 69–93.
- Goméz, J., Khodr, H., Oliveira, P., Ocque, L., Yusta, J., Villasana, R., and Urdaneta, A. (2004). Ant colony system algorithms for the planning of primary distribution circuits. 19(2):996–1004.
- Haghifam, M. R. and Hadian, A. (2010). Distribution system adequacy assessment with consideration of stochastic distributed generation. In *IEEE 11th International Conference on Probabilistic Methods Applied to Power Systems*, pages 553–557.
- Hancock, P. J. B. (1994). An empirical comparison of selection methods in evolutionary algorithms. In *Proceeding of Selected Papers from AISB Workshop on Evolutionary Computing*, pages 80–94.
- IBGE (2010). Sinopse do censo demográfico 2010. [<http://www.censo2010.ibge.gov.br/sinopse/>; acessado 19-julho-2012].
- Jensen, M. T. (2003). Reducing the run-time complexity of multiobjective EAs: The NSGA-II and other algorithms. *IEEE Transactions on Evolutionary Computation*, 7(5):503–515.
- Kennedy, J. and Eberhart, R. C. (1995). Particle swarm optimization. In *IEEE International Conference on Neural Networks*, Perth, WA, Australia.
- Kirkpatrick, S., Gelett, C. D., and Vecchi, M. P. (1983). Optimization by simulated annealing. *Science*, 220(4598):621–630.
- Knowles, J. and Corne, D. (1999). The pareto archived evolution strategy. *Proceedings of the 1999 Congress on Evolutionary Computation*, pages 98–105.
- Lima, E. L. (1995). *Curso de Análise*. Projeto Euclides, Rio de Janeiro.
- Manno, I. (1999). *Introduction to the Monte-Carlo method*. Hungary: Akademiai Kiado, Budapest.
- Martins, V. F. and Borges, C. L. T. (2011). Active distribution network integrated planning incorporating distributed generation and load response uncertainties. *IEEE Transactions on Power Systems*, 26(4):2164–2172.
- Mendoza, F., Bernal-Agustín, J. L., and Domínguez-Navarro, J. A. (2006). NSGA and SPEA applied to multiobjective design of power distribution systems. *IEEE Transactions on Power Systems*, 21(4):1938–1945.
- Ministério de Minas e Energia (2012). Programa luz para todos. [<http://luzparatodos.mme.gov.br/luzparatodos/asp/>; acessado 19-julho-2012].

- Ministério de Minas e Energia (2013). Balanço energético nacional 2013. [<https://ben.epe.gov.br/>; acessado 06-junho-2014].
- Miranda, V., Ranito, J. V., and Proença, L. M. (1994). Genetic algorithms in optimal multistage distribution network planning. *IEEE Transactions on Power Systems*, 9(4):1927–1933.
- Mori, H. and Yoshida, T. (2009). An efficient multi-objective memetic algorithm for uncertainties in distribution network expansion planning. *Power & Energy Society General Meeting*.
- Morsi, D. M., Abbasy, N. H., and Abul Ella, M. S. (1994). A hybrid expert system assisting decision making for distribution system load forecasting. In *Proceedings of 7th Mediterranean Electrotechnical Conference*, pages 893–896, Antalya.
- Nahman, J. and Peric, D. (2003). Distribution system performance evaluation accounting for data uncertainty. *IEEE Transactions on Power Delivery*, 18(3):694–700.
- Narsingh, D. (1984). *Graph Theory with Applications to Engineering and Computer Science*. Prentice Hall, New Delhi, India.
- Panda, S. and Yegireddy, N. K. (2013). Automatic generation control of multi-area power system using multi-objective non-dominated sorting genetic algorithm-ii. *International Journal of Electrical Power & Energy Systems*, 53:54–63.
- Parada, V., Ferland, J. A., and Daniels, M. A. K. (2004). Optimization of electrical distribution feeders using simulated annealing. 19(3):1135–1141.
- Penmaraju, S. and Skiena, S. (2003). *Computational discrete mathematics: combinatorics and graph theory with mathematica*. Cambridge University Press.
- Ramírez-Rosado, I. J. and Bernal-Agustín, J. L. (1998). Genetic algorithms applied to the design of large power distribution systems. *IEEE Transactions on Power Systems*, 13(3):696–702.
- Ramírez-Rosado, I. J. and Domínguez-Navarro, J. A. (2004). Possibilistic model based on fuzzy sets for the multiobjective optimal planning of electric power distribution networks. *IEEE Transactions on Power Systems*, 19(4):1801–1810.
- Ramírez-Rosado, I. J. and Domínguez-Navarro, J. A. (2006). New multiobjective tabu search algorithm for fuzzy optimal planning of power distribution systems. *IEEE Transactions on Power Systems*, 21(1):224–233.
- Rao, B. S. and Vaisakh, K. (2013). Multi-objective adaptive clonal selection algorithm for solving environmental/economic dispatch and opf problems with load uncertainty. *International Journal of Electrical Power & Energy Systems*, 53:390–408.

- Reeves, C. R. (1993). *Heuristic Modern Techniques for Combinatorial Problems*. New York: Wiley.
- Ren-jun, Z. and Xian-zhong, D. (2002). Optimal combined load forecast based on the improved analytic hierarchy process. In *Proceedings of the International Conference on Power System Technology*, volume 2, pages 1096–1100.
- Rivas-Dávalos, F., Moreno-Goytia, E., Gutiérrez-Alacaraz, G., and Tovar-Hernandez, J. (2007). Evolutionary multi-objective optimization in power systems: State-of-the-art. *Proceedings of IEEE Lausanne Powertech*, pages 2093–2098.
- Rothlauf, F. (2006). *Representations for Genetic and Evolutionary Algorithms*. Springer, Berlin, 2 edition.
- Schaffer, J. D. (1984). *Some experiments in machine learning using vector evaluated genetic algorithms*. PhD thesis, Vanderbilt University, Nashville, USA.
- Silva, I. J., Rider, M. J., Romero, R., and Murari, C. A. F. (2006). Transmission network expansion planning considering uncertainty in demand. *IEEE Transactions on Power Systems*, 21(4):1565–1573.
- Singh, D., Singh, D., and Verma, K. S. (2009). Multiobjective optimization for DG planning with load models. *IEEE Transactions on Power Systems*, 24(1):427–436.
- Souza, B. B. (2007). Projeto de redes de distribuição de energia com incertezas na evolução de carga utilizando algoritmos meméticos. Master's thesis, Universidade Federal de Minas Gerais.
- Souza, B. B., Carrano, E. G., Neto, O. M., and Takahashi, R. H. C. (2011). Immune system memetic algorithm for power distribution network design with load evolution uncertainty. *Electric Power Systems Research*, 81(2):527–537.
- Srinivas, N. (1994). Multiobjective optimization using nondominated sorting in genetic algorithms. Master's thesis, Indian Institute of Technology, Kanpur, India.
- Srinivas, N. and Deb, K. (Fall 1994). Multi-objective optimization using non-dominated sorting in genetic algorithms. *Evolutionary Computation*, 2(3):221–248.
- Su, C. T. and Lii, G. R. (2002). Reliability design of distribution systems using modified genetic algorithms. *Electric Power Systems Research*, 60(3):201–206.
- Tarôco, C. G., Carrano, E. G., and Neto, O. M. (2010). Robust design of power distribution systems using an enhanced multi-objective genetic algorithm. *International Journal of Natural Computing Research*, 1(2):92–112.
- Teng, J.-R. (2003). A direct approach for distribution system load flow solutions. *IEEE Transactions on Power Delivery*, 18(3):882–887.

- Vanderbei, R. J. (2001). *Linear Programming: Foundations and Extensions*. Springer.
- Wang, D. T. C., Ochoa, L. F., and Harrison, G. P. (2011). Modified ga and data envelopment analysis for multistage distribution network expansion planning under uncertainty. *IEEE Transactions on Power Systems*, 26(2):897–904.
- Wanner, E. F. (2006). *Operadores para Algoritmos Genéticos baseados em aproximações quadráticas de funções de variáveis contínuas*. PhD thesis, Universidade Federal de Minas Gerais, Belo Horizonte, Brasil.
- Welch, B. L. (1938). The significance of the difference between two means when the population variances are unequal. *Biometrika*, 29:350–362.
- Willis, H. L. and Northcode-Green, J. E. D. (1983). Spatial electric load forecasting: A tutorial review. *Proceedings of the IEEE*, 71(2):232–253.
- Willis, H. L., Tram, H., Engel, M. V., and Finley, L. (1996). Selecting and applying distribution optimization methods. *IEEE Computer Applications in Power*, 9(1):12–17.
- Wilson, R. J. (1996). *Introduction to Graph Theory*. Prentice Hall, 4th edition.
- Zimmerman, R. D., Murillo-Sánchez, C. E., and Thomas, R. J. (2011). Matpower: Steady-state operations, planning and analysis tools for power systems research and education. *IEEE Transactions on Power Systems*, 26(1):12–19.
- Zitzler, E., Laumanns, M., and Thiele, L. (2001). SPEA2: Improving the strength pareto evolutionary algorithm. Technical Report 103, Computer Engineering and Networks Laboratory (TIK), Swiss Federal Institute of Technology (ETH) Zurich.
- Zitzler, E. and Thiele, L. (1999). Multiobjective evolutionary algorithms: a comparative case study and the strength pareto approach. *IEEE Transactions on Evolutionary Computation*, 3(4):257–271.