



Centro de Tecnologia e Urbanismo
Departamento de Engenharia Elétrica

Karina Yamashita

Alocação e dimensionamento ótimo de geração distribuída para sistemas de distribuição de energia elétrica considerando diferentes níveis de carga

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Estadual de Londrina para obtenção do Título de Mestre em Engenharia Elétrica.

Londrina, PR
2017



Karina Yamashita

**Alocação e dimensionamento ótimo de
geração distribuída para sistemas de
distribuição de energia elétrica
considerando diferentes níveis de carga**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Estadual de Londrina para obtenção do Título de Mestre em Engenharia Elétrica.

Área: Sistemas de Potência

Orientador:

Prof. Dr. Luis Alfonso Gallego Pareja

Londrina, PR
2017

Ficha Catalográfica

Yamashita, Karina

Alocação e dimensionamento ótimo de geração distribuída para sistemas de distribuição de energia elétrica considerando diferentes níveis de carga. Londrina, PR, 2017. 109 p.

Dissertação (Mestrado) – Universidade Estadual de Londrina, PR. Departamento de Engenharia Elétrica

1 Alocação e Dimensionamento de Geração Distribuída 2 Algoritmo Genético Melhorado 3 Sistemas de Distribuição Radiais 4 Redução de Perdas de Energia 5 Programação não linear inteiro misto Departamento de Engenharia Elétrica

Karina Yamashita

Alocação e dimensionamento ótimo de geração distribuída para sistemas de distribuição de energia elétrica considerando diferentes níveis de carga

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Estadual de Londrina para obtenção do Título de Mestre em Engenharia Elétrica.

Área: Sistemas de Potência

Comissão Examinadora

Prof. Dr. Luis Alfonso Gallego Pareja
Depto. de Engenharia Elétrica
Universidade Estadual de Londrina
Orientador

Prof. Dr. Sérgio Augusto Oliveira da Silva
Depto. de Engenharia Elétrica
Universidade Tecnológica Federal do Paraná

Prof. Dr. Rodrigo A. Fernandes Pereira
Depto. de Engenharia Elétrica - COEL
Universidade Tecnológica Federal do Paraná

11 de setembro de 2017

*Dedico este trabalho a minha família e principalmente a minha filha, Livia, e
minha avó, Hisae.*

Agradecimentos

Agradeço a Deus por estar presente em minha vida e me permitir realizar este trabalho. Aos meus pais, Adélia e Mário, e irmãos, Alberto e Frederick, pelo apoio em todos os momentos necessários. Agradeço minha filha, Livia, por seu amor incondicional e paciência em momentos de ausência em sua vida. Ao meu cônjuge, David, pelo apoio, auxílio, paciência e compreensão nos momentos de necessidade. Ao meu orientador Dr. Luis Alfonso Gallego Pareja, pela oportunidade dada e pela orientação e conselhos dados ao longo do mestrado. Aos meus amigos que de alguma forma me auxiliaram no trabalho, principalmente o Alexandre Akira Kida pelas horas gastas em discussões sobre o trabalho ou pormenores da vida. A UEL e o MEEL, que proporcionaram a estrutura para a execução do trabalho e minha formação. Por fim, agradeço as agências de fomento CAPES e CNPq pelo apoio financeiro.

"I never did anything by accident, nor did any of my inventions come by accident; they came by work."(Thomas Edison)

Resumo

Neste trabalho é apresentada uma metodologia, baseada na meta-heurística do algoritmo genético especializado, para solucionar o problema de alocação e dimensionamento da geração distribuída (GD) em redes de distribuição radiais. O problema é formulado como um problema de programação não linear inteiro misto, visto que apresenta variáveis inteiras, que indicam a posição a ser alocada a GD, e as contínuas associadas às restrições elétricas (tensões, correntes, fluxos de potência e perdas de potência ativa e reativa). Foram realizados testes, objetivando a melhoria do tempo de processamento e a avaliação da complexidade computacional verificando o número de fluxos de potência calculados. A função objetivo visa minimizar os custos de instalação e manutenção da GD e os custos de operação da rede (perdas de potência); sendo penalizada se não respeitar os limites de tensão de barra e corrente de linha. Para o cálculo do ponto de operação do sistema utilizou-se o algoritmo *Backward-Forward Sweep*. A metodologia adotada considera a instalação de GD com potência fixa para diferentes níveis de carga e também pode definir o despacho da GD para cada um dos níveis de carga. Os resultados obtidos com o algoritmo implementado indicam a redução das perdas elétricas e melhoraram o perfil de tensão do sistema. A metodologia proposta foi implementada em linguagem C++ e testada em quatro sistemas presentes na literatura: o de 70, 136, 400 e 1080 barras. A partir dos resultados foi verificado que a metodologia apresentou um bom desempenho.

Abstract

This work presents a methodology, based on the meta-heuristic Specialized Genetic Algorithm, to solve the allocation and sizing problem of distributed generation (DG) in radial distribution networks. The problem is formulated as a matter of non-linear mixed-integer programming, since it presents integer variables, which indicate the position where the DG will be allocated, and the continuous variables, associated with electrical constraints (voltage, current, power flow, active power losses and reactive). Several tests were made, with the goal at improving processing time and the method convergence, also evaluating the computational complexity through the number of required power flows to achieve convergence. The employed objective function seeks minimization of the operation costs, losses, infrastructure investments, implementation costs and maintenance costs. If any bus voltage or line current constrain is violated, a penalization is applied to the objective function. The backward-forward sweep algorithm was used to calculate the system operating point. The methodology considers the DG facility with a fixed power for different load levels and can also set the power dispatched from the DG for each load level. The results obtained with the implemented algorithm reduced electrical losses and improved the system voltage profile. The proposed methodology was implemented in C++ language and tested with four systems that are present in the literature: the 70, 136, 400 and 1080 buses. From the results, it was verified that the methodology presented a good performance.

Sumário

Lista de Figuras	xxi
Lista de Tabelas	xxiii
Lista de Abreviaturas	xxvi
Lista de Símbolos	xxvii
1 Introdução	1
1.1 Motivação e Justificativa	2
1.2 Objetivos	3
1.2.1 Objetivo Principal	3
1.2.2 Objetivo Específicos	3
1.3 Organização do Trabalho	4
2 Estado da Arte	5
2.1 A Geração Distribuída	5
2.1.1 Vantagens da Aplicação da Geração Distribuída	6
2.1.2 Desvantagens da Aplicação da Geração Distribuída	7
2.1.3 Tecnologias de Geração Distribuída	7
2.1.4 O Estado Regulatório da Geração Distribuída no Brasil	15
2.2 Revisão Bibliográfica	17
2.2.1 Métodos Analíticos	17
2.2.2 Métodos Numéricos	19
2.2.3 Métodos Heurísticos	20
2.2.4 Métodos Meta-heurísticos	21

2.3	Considerações Finais do Capítulo	25
3	Formulação do Problema	26
3.1	Modelamento Matemático	26
3.1.1	Modelamento Matemático para Alocação e Dimensionamento da Geração Distribuída	26
3.2	Considerações Finais do Capítulo	32
4	Algoritmo Genético	33
4.1	Introdução	33
4.2	Codificação	36
4.2.1	Codificação considerando alocação da GD	36
4.2.2	Codificação considerando alocação e dimensionamento da GD	36
4.3	Função Objetivo	37
4.4	População Inicial	38
4.4.1	Índice de sensibilidade de perdas I	38
4.4.2	Índice de sensibilidade de perdas II	39
4.4.3	Índice de estabilidade da tensão	39
4.5	Seleção	39
4.6	Recombinação	40
4.6.1	Recombinação considerando apenas alocação da GD	40
4.6.2	Recombinação considerando alocação e dimensionamento da GD	41
4.7	Mutação	41
4.7.1	Mutação considerando apenas alocação da GD	42
4.7.2	Mutação considerando alocação e dimensionamento da GD	42
4.8	Melhoria Local	43
4.8.1	Eliminação	43
4.8.2	Busca de vizinhança	43

4.8.3	Ajuste da potência	44
4.9	Substituição	44
4.10	Parâmetros de Controle	45
4.11	Critério de Parada	45
4.12	Cálculo do Fluxo de Potência	45
4.13	Considerações Finais do Capítulo	48
5	Resultados e Discussões	49
5.1	Sistema 70 barras	50
5.1.1	Alocação de GD fixa	51
5.1.2	Alocação e dimensionamento de GD	54
5.1.3	Discussões	57
5.2	Sistema 136 barras	58
5.2.1	Alocação de GD fixa	59
5.2.2	Alocação e dimensionamento de GD	62
5.3	Sistema 400 barras	63
5.3.1	Alocação de GD fixa	63
5.3.2	Alocação e dimensionamento de GD	66
5.4	Sistema 1080 barras	67
5.4.1	Alocação de GD fixa	68
5.4.2	Alocação e dimensionamento de GD	71
5.5	Discussões e Considerações finais	72
6	Conclusão	73
6.1	Trabalhos Futuros	74
	Referências	75
	Apêndice A – Parâmetros do Algoritmo Genético Especializado	83
	Apêndice B – Comparação do Desempenho dos Índices de Sensibi-	

lidade

87

Apêndice C - Publicações

88

Lista de Figuras

2.1	Consumo Total de Energia Mundial por Fonte (2013).	8
2.2	Oferta Interna de Energia Elétrica por Fonte em 2014.	8
2.3	Diagrama dos processos de conversão energética da biomassa. . .	10
2.4	Diagrama esquemático de uma turbina eólica.	13
3.1	Curva dos níveis de carga.	27
3.2	Representação simplificada do sistema.	29
3.3	Esquemático da abordagem para a solução do problema de alocação e dimensionamento da GD.	31
4.1	Fluxograma do AGE.	35
4.2	Exemplo da codificação de um indivíduo.	36
4.3	Exemplo da codificação de um indivíduo, para alocação e dimensionamento.	37
4.4	Exemplo da etapa de recombinação.	40
4.5	Exemplo da etapa de recombinação.	41
4.6	Exemplo da etapa de mutação.	42
4.7	Exemplo da etapa de mutação.	42
4.8	Exemplo da etapa de busca em vizinhança.	44
4.9	Sistema de 14 barras sem ordenação e renumeração das barras. . .	48
4.10	Sistema de 14 barras com ordenação e renumeração das barras. . .	48
5.1	Diagrama sistema de 70 barras.	50
5.2	Magnitude de tensão do sistema de 70 barras para cada Nível de Demanda, com e sem GDs, considerando as possibilidades de alocação da GD.	52
5.3	Magnitude de tensão do sistema de 70 barras, antes e depois da alocação e dimensionamento das possibilidades de grupos da GD.	56

5.4	Diagrama sistema de 136 barras.	58
5.5	Magnitude de tensão do sistema de 136 barras para cada Nível de Demanda, com e sem GDs, considerando as possibilidades de alocação da GD.	60
5.6	Magnitude de tensão do sistema de 400 barras para cada Nível de Demanda, com e sem GDs, considerando as possibilidades de alocação da GD.	65
5.7	Magnitude de tensão do sistema de 1080 barras para cada Nível de Demanda, com e sem GDs, considerando as possibilidades de alocação da GD.	69
A.1	Comportamento da Fo do sistema de distribuição de 70 barras em relação à variação do parâmetro TPI, considerando $TM = 1\%$. . .	84
A.2	Comportamento da Fo do sistema de distribuição de 70 barras em relação à variação do parâmetro TM, considerando $TPI = 50$. . .	84

Lista de Tabelas

5.1	Solução para o sistema 70 barras considerando alocação de até três GDs, com potência fixa em 1000 kW e fator de potência 0,95 (indutivo).	51
5.2	Somatório das perdas para cada caso e percentual de redução dos custos totais e das perdas.	51
5.3	Parâmetros iniciais empregados no AGE.	53
5.4	Comparação de desempenho entre os AGE e o AGE-IET	53
5.5	Comparação dos resultados da alocação e dimensionamento da GD, para o sistema 70 barras considerando apenas um nível de carga. .	54
5.6	Tabela de comparação de desempenho das diferentes metodologias para o sistema 70 barras.	55
5.7	Resultados para os testes de alocação e dimensionamento da GD, considerando os níveis de carga no sistema dos 70 barras.	57
5.8	Tabela de comparação do desempenho das metodologias propostas para o sistema 70 barras, considerando os níveis de carga.	57
5.9	Solução para o sistema 136 barras considerando alocação de até quatro GDs, com potência fixa em 2000 kW e fator de potência 0,95 (indutivo).	59
5.10	Comparação do somatório das perdas de potência ativa totais e do percentual de redução dos custos totais e do somatório de perdas, para o sistema 136 barras considerando o número de GD a ser alocado.	59
5.11	Parâmetros iniciais empregados no AGE.	61
5.12	Comparação de desempenho entre os AGE e o AGE-IET	61
5.13	Resultados para os testes de alocação e dimensionamento da GD, considerando os níveis de carga no sistema dos 136 barras.	62

5.14	Tabela de comparação do desempenho das metodologias propostas para o sistema 136 barras, considerando os níveis de carga.	63
5.15	Solução para o sistema 400 barras considerando a alocação de GDs com despacho fixo em 1000 kW com fator de 0,95 (indutivo).	64
5.16	Comparação dos custos e perdas totais para o sistema 400 barras, com seus respectivos percentuais de redução.	64
5.17	Parâmetros do AGE.	66
5.18	Comparação de desempenho entre os AGE e do AGE-IET.	66
5.19	Resultados para os testes de alocação e dimensionamento da GD, considerando os níveis de carga no sistema dos 400barras.	67
5.20	Tabela de comparação do desempenho das metodologias propostas para o sistema 400 barras, considerando os níveis de carga.	67
5.21	Solução para o sistema 1080 barras considerando alocação de até três GDs, com potência fixa em 180,0 kW com fator de potência 0,95 (indutivo).	68
5.22	Comparação do somatório das perdas de potência ativa totais e do percentual de redução dos custos totais e do somatório de perdas, para o sistema 1080 barras considerando o número de GD a ser alocado.	68
5.23	Parâmetros iniciais empregados no AGE.	70
5.24	Comparação de desempenho entre os AGE e o AGE-IET	70
5.25	Resultados para os testes de alocação e dimensionamento da GD, considerando os níveis de carga no sistema dos 1080barras.	71
5.26	Tabela de comparação do desempenho das metodologias propostas para o sistema 1080 barras, considerando os níveis de carga.	72
A.1	Parâmetros do algoritmo genético para o sistema de distribuição de 70 barras.	85
A.2	Parâmetros do algoritmo genético para o sistema de distribuição de 135 barras.	85
A.3	Parâmetros do algoritmo genético para o sistema de distribuição de 400 barras.	85

A.4	Parâmetros do algoritmo genético para o sistema de distribuição de 1080 barras.	86
B.1	Comparação da performance dos diferentes índices de sensibilidade para a geração da população inicial.	87

Lista de Abreviaturas

GD Geração distribuída

PCH Pequena Central Hidrelétrica

AGE Algoritmo Genético Especializado

OEP Otimização de enxame de partícula

INEE Instituto Nacional de Eficiência Energética

ANEEL Agência Nacional de Energia Elétrica

CONFAZ Conselho Nacional de Política Fazendária

ICMS Imposto sobre circulação de mercadorias e serviços

AG Algoritmo Genético

FO Função Objetivo

ISP Índice de Sensibilidade de Perdas

IET Índice de Estabilidade de Tensão

AGE-IET Algoritmo Genético Especializado Empregando Índice de Estabilidade de Tensão

PCH Pequena Central Hidroelétrica

LAPSEE Laboratório de Planejamento de Sistemas de Energia Elétrica(UNESP)

Lista de Símbolos

Conjuntos:

Ω_b Conjunto de barras.

Ω_l Conjunto de ramos.

Ω_d Conjunto de demanda.

Constantes:

c_k Constante que representa o custo de instalação.

T_d é o período de tempo para o perfil de carga.

T é o período total utilizado pelo sistema.

P_i^S Potência ativa injetadas pela subestação no sistema.

Q_i^S Potência reativa injetadas pela subestação no sistema

$P_{i,d}^D$ Potência ativa absorvida pela barra i no nível de carga d .

$Q_{i,d}^D$ Potência reativa absorvida pela barra i no nível de carga d .

V_{ref} Tensão na barra de referência.

\underline{V} Limite mínimo do módulo da tensão nas barras do sistema.

\overline{V} Limite máximo do módulo da tensão nas barras do sistema.

\underline{I}_{ij} Fluxo máximo de corrente pelo ramo ij .

\overline{I}_{ij} Fluxo mínimo de corrente pelo ramo ij .

$\overline{n^{gd}}$ Constante que representa o número máximo de GDs instalados no sistema.

$\overline{P_i^S}$ Valor máximo aceitável para a potência ativa inserida pela subestação para todo o conjunto de barras (Ω_b).

$\overline{Q_i^{gd}}$ Valor máximo aceitável para a potência reativa inserida pela subestação para todo o conjunto de barras (Ω_b).

\overline{P}_i^{gd} Valor máximo aceitável para a potência ativa inserida pela GD para todo o conjunto de barras (Ω_b).

\overline{Q}_i^s Valor máximo aceitável para a potência reativa inserida pela GD para todo o conjunto de barras (Ω_b).

R_{ij} Resistência no ramo ij .

X_{ij} Reatância no ramo ij .

Z_{ij} Impedância no ramo ij .

Variáveis Contínuas:

k_c Fator de recuperação da geração distribuída.

k_e^i Parâmetro de custo de energia, para cada nível de carga.

r_k Constante que representa o custo de manutenção da GD.

$P_{ij,d}$ Fluxo de potência ativa no ramo ij , no nível de demanda d .

$Q_{ij,d}$ Fluxo de potência reativa no ramo ij , no nível de demanda d .

P_i^{gd} Potência ativa instalada pela GD na barra i .

Q_i^{gd} Potência reativa instalada pela GD na barra i .

P_d^{perdas} Perdas de potência ativa totais para cada período.

$V_{i,d}$ Tensão na barra i para o nível de carga d .

Variáveis Binárias:

n_k^{gd} vetor preenchido de valores binários, que indicam a existência ou a ausência de GD.

1 Introdução

O setor energético vem sofrendo grandes modificações, sendo um dos agentes transformadores a geração distribuída (GD). A GD apresenta um modelo descentralizado para o sistema energético, aproximando os sistemas de geração às cargas e trazendo benefícios ao sistema, visto que possibilita a redução das perdas e a melhoria do perfil de tensão nos alimentadores; e conseqüentemente permite que as empresas posterguem investimentos em infra-estrutura (SEVERINO; MARQUES; CAMARGO, 2008).

Apesar do conceito da GD existir a mais de um século, as discussões recentes sobre o tema produziram várias definições para este tipo de geração, como demonstrado por Severino, Marques e Camargo (2008). O INEE (2016) estabeleceu em 2002 que a GD pode ser definida como qualquer fonte geradora com produção destinada, em sua maior parte, a cargas locais ou próximas, sem a necessidade de longas linhas de transmissão ou distribuição.

O uso da GD é uma alternativa para o modelo de geração centralizada (GC), uma vez que apresenta formas de produção de energia de menor dimensão e por englobar várias formas de produção de energia elétrica, sejam elas renováveis ou não-renováveis.

Com o aumento da demanda de energia elétrica e a limitação dos recursos para sua geração, está ocorrendo um aumento dos incentivos por parte dos governos para utilização de fontes renováveis de energia, conseqüentemente impulsionando a alocação da GD.

Diante desse novo cenário, as empresas concessionárias, da rede de distribuição, vem se equipando de ferramentas capazes de analisar o impacto da GD conectada à rede. Verificando como estas afetam a confiabilidade, a qualidade do perfil de tensão e a estabilidade de operação, pois muitas dessas fontes são não despacháveis, portanto, suas operações são variáveis e estão sujeitas à variação do suprimento de energia primária.

1.1 Motivação e Justificativa

A partir da crise petrolífera da década de 70, a co-geração surge como uma alternativa, sendo uma forma de produção de energia próxima ao local, portanto uma forma da GD. Na década de 90, com o aumento da concorrência no mercado de energia elétrica surge a necessidade de que os participantes apresentem custos competitivos. Com essa transformação no mercado e novas tecnologias sendo desenvolvidas, a GD se torna atraente (SANTOS; SANTOS, 2008).

Ao final do século XX, com o setor elétrico estruturado, a questão ambiental atrai a atenção pelo fato de mais de 80% da produção de energia elétrica do mundo ser originária de combustíveis fósseis ou nuclear (IEA, 2015). Outro fator que atraiu a atenção para a GD neste período foi o interesse por fontes renováveis e de maior eficiência energética.

A GD pode ser vista como uma alternativa ou complementação para suprir a demanda crescente por energia elétrica, sendo necessário estudar detalhadamente a melhor forma de implantá-la. De modo geral, a inserção da GD reduz as perdas de potência totais do sistema de distribuição radial a qual é inserida (SEVERINO; MARQUES; CAMARGO, 2008), uma vez que, a GD insere potência em possíveis pontos de deficiência da geração centralizada.

As GDs possuem um elevado custo de implementação e necessitam de manutenção constantemente, sendo necessário realizar uma averiguação se a redução do custo de perdas de potência é maior do que o custo de implementação e manutenção somados ao longo de um determinado período (WOTTRICH, 2010).

A geração próxima às cargas pode trazer uma série de benefícios a rede, como a redução das perdas de potência, o aumento nos índices de confiabilidade, maior estabilidade e a melhora no perfil de tensão. A alocação da GD em pontos inadequados pode acarretar no aumento das perdas de potência e dos custos, assim ocasionando um efeito contrário ao esperado (ALINEJAD-BEROMI et al., 2008). Porém, sua alocação se compromete caso a redução dos custos de perdas de potência não estiverem proporcionais ao custo de implementação e manutenção da GD.

Nos últimos anos o problema de alocação e dimensionamento da GD recebeu destaque, devido aos seus benefícios ao sistema e ao surgimento das redes inteligentes (*smart grid*).

Porém, o problema de alocação e dimensionamento da GD não se trata de um problema simples, conseqüentemente para encontrar uma solução de qualidade

deve-se escolher uma técnica adequada.

A decisão para a escolha da técnica de otimização empregada, baseada no algoritmo genético especializado (CHU; BEASLEY, 1997), foi despertada devido aos bons resultados apresentados pela técnica para problemas similares Guimarães e Castro (2011) (reconfiguração e alocação e dimensionamento de banco de capacitores), Garces e Romero (2009) (planejamento da rede), Gallego et al. (2009) (planejamento de expansão da rede), Camargo, Lavorato e Romero (2013) (planejamento da rede), Souza et al. (2015) (reconfiguração considerando diferentes níveis de carga), bem como por apresentar resultados competitivos em relação a outras metodologias encontradas na literatura especializada, para o problema de alocação e dimensionamento da GD, como a metodologia analítica (ACHARYA; MAHAT; MITHULANANTHAN, 2006), (GÖZEL; HOCAOGLU, 2009), o enxame de partículas (DIAS et al., 2012), o algoritmo genético tradicional (PISICA; BULAC; EREMI, 2009) (SINGH; GOSWAMI, 2010), dentre outras metodologias adotadas.

1.2 **Objetivos**

A seguir são apresentados os objetivos desta dissertação de mestrado.

1.2.1 **Objetivo Principal**

Este trabalho tem como objetivo propor uma metodologia para solucionar o problema de alocação e dimensionamento de geração distribuída em sistemas de distribuição radiais.

1.2.2 **Objetivo Específicos**

- Demonstrar a formulação do problema de alocação e dimensionamento da GD como um problema de otimização matemática, sendo composto de função objetivo (FO) e suas restrições;
- Propor uma metodologia capaz de considerar o dimensionamento da GD como discreto;
- Comparar diferentes índices de sensibilidade para o melhoramento da população inicial;

- Implementar uma busca em vizinhança na etapa de melhoria local do algoritmo genético especializado (AGE).
- Minimizar as perdas de potência ativa e reativa, totais, assim reduzindo os custos relacionadas as perdas e contribuir para melhora dos níveis de tensão nos sistemas de distribuição radiais.
- Investigar o desempenho computacional da técnica implementada.
- Empregar a metodologia proposta para realizar testes com sistemas reais de grande porte.

1.3 Organização do Trabalho

O presente trabalho foi dividido em seis capítulos. No capítulo 1 é exposto uma introdução ao problema da alocação de geradores distribuídos em sistemas de distribuição radiais e os objetivos desta dissertação. No capítulo 2 é descrita a teoria e a legislação da GD e o estado da arte dos métodos de solução do problema de alocação ótima de GD em sistemas de distribuição radiais. No capítulo 3 é apresentada a formulação matemática do problema de alocação e dimensionamento da GD. A formulação para este problema é constituída de uma função objetivo (FO) e seu conjunto de restrições. No capítulo 4 é abordado a teoria do algoritmo genético, enfatizando as características do algoritmo genético especializado. No capítulo 5 são apresentados os principais resultados obtidos empregando a metodologia proposta e sua validação. No capítulo 6 são expostas as principais conclusões obtidas com a aplicação da metodologia proposta.

No Apêndice A apresenta-se a metodologia e os resultados para a calibração do algoritmo genético especializado. No Apêndice B é exposto a metodologia e o resultado para a escolha do índice de sensibilidade empregado na população inicial. No Apêndice C são apresentados os trabalhos publicados durante o período de desenvolvimento desta dissertação de mestrado.

2 Estado da Arte

Neste capítulo serão apresentados o conceito de GD, bem como as vantagens e desvantagens de sua instalação em sistemas de distribuição, os diferentes tipos de geração distribuída mais empregadas no mercado de energia e a legislação que regula sua implementação no Brasil. Este capítulo ainda abrange a revisão bibliográfica das diferentes técnicas empregadas para a alocação e dimensionamento da GD.

2.1 A Geração Distribuída

Segundo Ackermann, Andersson e Söder (2001) a GD pode ser definida como a energia elétrica produzida por geradores de pequeno porte localizados dentro do sistema de distribuição ou próximo aos consumidores. A geração distribuída pode ser classificada em função da sua potência como:

- Geração Distribuída Micro: até 5 kW;
- Geração Distribuída Pequena: de 5 kW a 5 MW;
- Geração Distribuída Média: de 5 MW a 50 MW;
- Geração Distribuída Grande: de 50 MW a 300 MW.

Ainda Ackermann, Andersson e Söder (2001) consideram que a GD é responsável por fornecer potência ativa para a rede. Portanto, não necessariamente será injetada potência reativa (SANTOS; SANTOS, 2008).

A definição da GD no Brasil pode ser encontrada no Decreto nº 5163 de 30 de julho de 2004, publicado pela ANEEL, no capítulo *II*, seção *I*.

”Art. 14. Para os fins deste Decreto, considera-se geração distribuída a produção de energia elétrica proveniente de empreendimentos de agentes concessionários, permissionários ou autorizados, incluindo aqueles tratados pelo art. 8o da Lei no 9.074, de 1995, conectados diretamente no sistema elétrico de distribuição do comprador, exceto aquela proveniente de empreendimento.

I - hidrelétrico com capacidade instalada superior a 30 MW; e

II - termelétrico, inclusive de cogeração, com eficiência energética inferior a setenta e cinco por cento, conforme regulação da ANEEL, a ser estabelecida até dezembro de 2004.

Parágrafo único. Os empreendimentos termelétricos que utilizem biomassa ou resíduos de processo como combustível não estarão limitados ao percentual de eficiência energética prevista no inciso II do caput.”

2.1.1 Vantagens da Aplicação da Geração Distribuída

Se a alocação da GD se der de maneira correta esta pode trazer muitos benefícios, técnico e econômicos, ao sistema de distribuição, na qual foi instalado. Alguns desses benefícios são expostos a seguir.

1. Redução das perdas, um dos objetivos mais buscados na literatura, é uma consequência da redução do fluxo de potência nas linhas do sistema de distribuição devido a inserção da GD. Porém, se a GD for alocada erroneamente as perdas podem aumentar a níveis proibitivos (CHIRADEJA; RAMAKUMAR, 2004).
2. Melhoria na confiabilidade, pois pode suprir parcialmente a potência de algumas cargas (SANTOS; SANTOS, 2008).
3. Redução da emissão de poluentes, gases de efeito estufa ou outros, quando comparada às tecnologias convencionais de produção de energia, usinas termoelétricas e nucleares.
4. Posterga a necessidade de investimentos para ampliação da rede, sendo esta característica reconhecida por órgãos reguladores e pelas concessionárias. Sua possibilidade de instalação próxima as cargas retarda a necessidade de troca de condutores sobrecarregados principalmente nos momentos de pico, devido a redução do fluxo de potência nas linhas.
5. Baixo impacto ambiental, devido a utilização de combustíveis menos poluentes, o melhor emprego dos combustíveis tradicionais e permite a eliminação de resíduos industriais poluentes, usando a cogeração (SANTOS; SANTOS, 2008).
6. Diversificação da matriz energética, por possuir várias tecnologias de geração (

eólica, solar, biomassa, microturbinas, células a combustível). Sendo um incentivo ao emprego de energias renováveis.

7. Necessita de um menor tempo de implementação e possuem flexibilidade de localização, devido seu pequeno porte e a fácil instalação.

2.1.2 Desvantagens da Aplicação da Geração Distribuída

Segundo Celli et al. (2005) com a inserção da GD a rede de distribuição passa a ser ativa. Assim, a rede perde sua característica de fluxo energético unidirecional, passando a ser bidirecional. Trazendo impactos negativos à rede.

1. O fluxo bidirecional aumenta a complexidade da operação da rede de distribuição;
2. São requeridas mudanças nos procedimentos das concessionárias para operação, controle e proteção das redes;
3. Necessita de controle dos níveis de tensão da rede no período de carga leve, altera os níveis de curto-circuito e aumenta as distorções harmônicas;
4. Dificuldade para a previsão de disponibilidade de combustíveis renováveis, ocasionando uma alta taxa de falhas dos equipamentos e intermitência na produção de energia;
5. Apresenta um alto custo de implementação para alguns tipos da GD;
6. O tempo para o retorno financeiro é elevado.

2.1.3 Tecnologias de Geração Distribuída

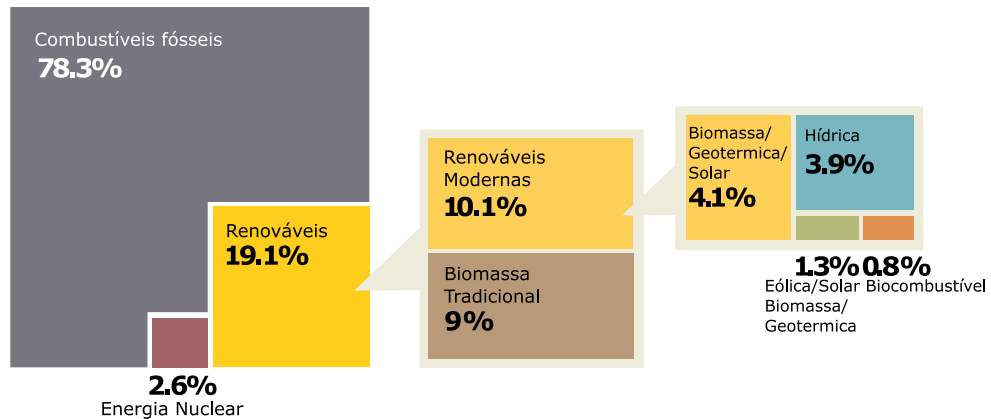
A GD não está correlacionada a nenhuma forma específica de geração de energia, porém no cenário mundial há um grande fomento às fontes alternativas de energia, conhecidas como fontes de "energia limpa" ou "energia verde".

Segundo Chiradeja e Ramakumar (2004) alguns tipos de GD são capazes de produzir energia elétrica de modo tão eficiente quanto grandes centrais de geração de energia e apresentar custos competitivos com as grandes centrais de geração de energia elétrica, possuindo menores impactos ambientais e flexibilidade na implantação.

A GD pode ser classificada em dois tipos: renováveis e não-renováveis. A energia renovável é a energia provinda de recursos que possuem a capacidade de se regenerar naturalmente, teoricamente fontes inesgotáveis, alguns exemplos são: a energia solar, energia hidráulica, energia eólica, biomassa, geotérmica e maremotriz. Em 2013 estima-se que 19,1% da energia consumida mundialmente teve origem em fontes renováveis (REN21, 2015). Como pode ser observado na Figura 2.1, 10,1% da energia provem de

fontes renováveis modernas (biomassa, geotérmica, solar, eólica, hidrelétrica, biocombustíveis,) e os 9,0% restantes podem ser representados pela biomassa tradicional, que é empregada primariamente para cozinhar e aquecer em áreas remotas ou rurais de países em desenvolvimento. A energia provida de hidrelétricas representam aproximadamente 3,9% da energia final consumida mundialmente, mas a capacidade hídrica está chegando ao seu limite. As outras formas de produção de energia de forma renovável estão crescendo rapidamente em países desenvolvidos ou em desenvolvimento.


Figura 2.1: Consumo Total de Energia Mundial por Fonte (2013).



Fonte: Relatório Mundial de Energias Renováveis (2015).

No Brasil a matriz elétrica é originalmente renovável, com predominância da geração hidráulica, corresponde a 63,24% da oferta interna. As fontes renováveis constituem cerca de 74,6% da oferta interna de eletricidade no Brasil. Na Figura 2.2 é possível ver a distribuição das fontes de energia elétrica. (EPE, 2015).

Figura 2.2: Oferta Interna de Energia Elétrica por Fonte em 2014.



Fonte: Empresa de Pesquisa Energética (2015).

A energia não-renovável é a energia provida de fontes naturais, na qual sua regeneração ocorre de forma lenta, podendo levar milhões de anos, como ocorre com

os combustíveis fósseis. Mas como pode ser visto na Figura 2.1, este tipo de fonte representa cerca de 78,3% do consumo final da energia em 2013 no mundo.

A seguir são expostas algumas tecnologias da GD, renováveis e não renováveis.

2.1.3.1 Hidráulica

A energia provinda de fonte hidráulica foi uma das primeiras formas de energia mecânica a ser empregada para a substituição do trabalho animal, inicialmente para bombeamento de água e moagem de grãos. Aspectos que favorecem o seu uso são: disponibilidade de recursos, facilidade de aproveitamento e seu caráter renovável. Diferente das demais fontes renováveis representa uma parcela significativa da matriz energética mundial (ANEEL, 2005)

Para a conversão da energia hidráulica para energia elétrica são empregadas turbinas hidráulicas, que são acopladas a um gerador. Sua eficiência pode atingir até 90%, atualmente as turbinas hidráulicas são as formas mais eficientes para a conversão de energia primária em secundária (ANEEL, 2005).

São consideradas GD pequenas centrais hidrelétricas (PCH), que são usinas hidrelétricas de pequeno porte com intervalo de potência de instalação na faixa de 100 *kW* à 100 *MW* (ADEFARATI; BANSAL, 2016).

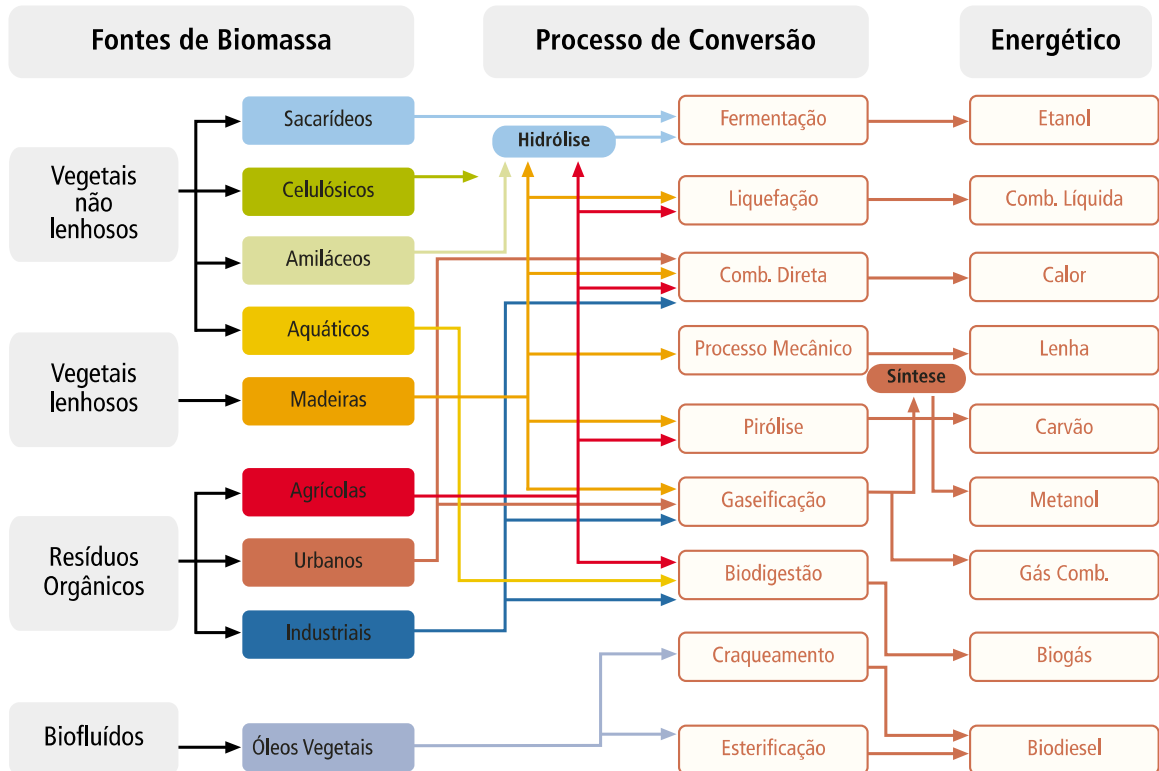
As PCHs são instaladas principalmente em rios de pequeno e médio porte que apresentem desníveis significativos em seu percurso, assim gerando potência hidráulica suficiente para ser convertido em energia elétrica através da turbina (PRADO, 2013).

Segundo levantamento do Banco de Informações de Geração da Aneel em setembro de 2017, no Brasil estavam operando 433, com potência outorgada de 4.979.583 *kW*.

2.1.3.2 Biomassa

A biomassa é definida como todo recurso renovável provindo de matéria orgânica, de origem vegetal ou animal, o qual é empregado na produção de energia, podendo ser mecânica, térmica ou elétrica. Pode ser considerada uma forma indireta de energia solar, uma vez que, através da fotossíntese a energia solar é convertida em energia química nos vegetais (ANEEL, 2005).

Como pode ser visto na Figura 2.3 existem muitas possibilidades de processos de conversão de biomassa em energia. A biomassa pode ser transformada através da combustão direta, com ou sem processos físicos de secagem, classificação, compressão, corte/quebra etc.; processos termoquímicos, gaseificação, pirólise, liquefação e transesterificação; ou processos biológicos, digestão anaeróbia e fermentação)

Figura 2.3: Diagrama dos processos de conversão energética da biomassa.

Fonte: Agência Nacional de Energia Elétrica (2005).

O processo de combustão direta pode ser utilizada para produção de eletricidade ou calor, já nos processos termoquímicos e biológicos a biomassa é convertida em combustíveis sólidos, gasosos ou líquidos por meio de tecnologias de conversão. Alguns exemplos de aplicações dessas técnicas são: a fermentação, empregada para produzir álcoois; a digestão bacteriana, para fornecer biogás; e a gaseificação, para produzir um substituto do gás natural. Os resíduos agrícolas, florestais e industriais são fontes de biomassa que podem ser utilizadas, como é o caso dos resíduos das árvores e da cana-de-açúcar (ANEEL, 2005).

A conversão da biomassa é utilizada principalmente na indústria de papel e celulose (empregada para gerar energia), no setor sucroalcooleiro (na produção de combustível, álcool, ou para gerar energia elétrica, bagaço da cana) e na indústria siderúrgica (utilizado como agente térmico, carvão vegetal) (ANEEL, 2005).

A biomassa é considerada uma das principais alternativas para a diversificação da matriz energética, sendo uma opção para substituição dos combustíveis fósseis. Sua utilização para a produção de energia elétrica é crescente no Brasil, principalmente na forma de cogeração, o que possibilita a obtenção de energia térmica e elétrica; nos setores industriais e de serviços. Outra aplicação que se destaca é a produção de biocombustíveis, como o biodiesel e o etanol, uma opção de substituição aos derivados de petróleo como o óleo diesel e a gasolina (ANEEL, 2005).

Os benefícios, ambientais e sociais quando compara-se o uso da biomassa com os combustíveis fósseis, são apresentados por Callé e Rothman (2005). Que são:

- redução dos níveis de emissão de gás carbônico;
- melhor manuseio da terra;
- gera novos empregos;
- uso de áreas agrícolas excedentes nos países industrializados;
- fornecimento de vetores energéticos modernos às comunidades rurais nos países em desenvolvimento;
- controle de resíduos;
- reciclagem de nutrientes.

2.1.3.3 Energia Fotovoltaica

A conversão da energia solar em energia elétrica se dá devido aos efeitos da radiação, calor e luz, sobre materiais semicondutores. Os principais são os efeitos termoelétricos e fotovoltaico. Sendo caracterizados pelo surgimento de uma diferença de potencial, ocasionado pela junção de dois metais, em condições específicas, onde os fótons contidos na luz solar são convertidos em energia elétrica, utilizando células solares, respectivamente (ANEEL, 2005). Um equipamento acessório importante para o conjunto é o inversor, este é responsável pela conversão desta energia, gerada em tensão contínua, para tensão alternada com níveis da rede.

Em 2014 fez 60 anos que ocorreu a primeira demonstração pública do painel solar (REN21, 2015). Segundo (REN21, 2015) houve um crescimento de 4783,78% na potência fotovoltaica instalada no Mundo no período de 2004 à 2014.

O maior empecilho para sua utilização de forma comercial é o alto custo destes painéis. Porém, nos últimos anos as células fotovoltaicas vem sendo cada vez mais empregas devido aos incentivos fiscais.

Os benefícios da utilização de sistemas fotovoltaica ligados à rede para o sistema de distribuição são (LORA, 2006):

- reduzir as perda elétricas, uma vez que a geração está próxima ao consumidor e na tensão de consumo, fatores que dependem da carga e do nível de geração;
- posterga investimentos em geração, transmissão e distribuição;
- elimina a necessidade de instalação de capacidade ociosa, devido aos curtos prazos de instalação.

No Brasil a potência instalada total de usinas fotovoltaicas é de 27,761 kW, sendo fornecidos por 44 usinas. Estes dados não consideram os sistemas fotovoltaicos residenciais (ANEEL, 2017). Assim, esta fonte representa 0,01% da oferta interna de energia elétrica por fonte (EPE, 2015). As usinas fotovoltaicas ainda são pouco instaladas devido a seu alto custo de instalação, quando considerado em grande escala.

2.1.3.4 Energia Eólica

Uma das formas de energia mais antigas utilizadas pelo homem, por exemplo para mover navegações, girar moinhos para moer grãos ou bombear água, porém somente no século XX que começa a ser empregada na produção de energia elétrica (ANEEL, 2005). O processo de geração ocorre transformando a energia eólica em energia cinética que será convertida em energia elétrica. O custo de implementação e manutenção elevados foram um barreira para sua utilização, porém em meados de 2006 ocorreu o incentivo dado à geração a partir de fontes renováveis (LORA, 2006).


Para a geração de energia elétrica são empregadas turbina eólicas (aerogeradores), que é uma máquina elétrica, gerador, onde integrada a um eixo conectado as pás, as quais convertem a energia cinética do vento em energia elétrica. A forma mais difundida dos aerogeradores é a turbina com eixo horizontal e com três pás, como visto na Figura 2.4, mas existem diferentes formas de turbinas. Os aerogeradores evoluíram em suas tecnologias, em suas características operacionais e em seus custos (ANEEL, 2005).

As turbinas eólicas podem ser classificadas de acordo com sua capacidade de geração sendo de pequeno porte as que possuem potência nominal inferior a 500 kW, de médio com potência nominal na faixa de 500 kW à 1000 kW e de grande porte com potência nominal superior a 1 MW (ANEEL, 2005).

As vantagens da geração eólica são:

- gera energia limpa e renovável;
- não produz resíduos, tóxicos ou radioativos, ou emite gases poluentes;
- sua fonte primária é inesgotável e gratuita;
- seus custos são reduzidos ao longo do tempo;
- baixo custo de manutenção;
- não necessita de longos períodos de tempo para a sua instalação e operação.

As desvantagens dos geradores eólicos são: apresenta impactos ambientais (incluindo morte de pássaros), o ruído, a interferência com recepção de rádio e televisão e impacto visual. Ao longo dos anos estas desvantagens estão sendo minimizadas.

Figura 2.4: Diagrama esquemático de uma turbina eólica.

Fonte: Agência Nacional de Energia Elétrica (2005).

As turbinas podem ser conectadas à rede elétrica diretamente ou destinadas ao abastecimento de energia elétrica a comunidades ou sistemas isolados (ANEEL, 2005).

No Brasil a potência instalada já chega a aproximadamente 11GW, assim representando 7,2 % da potência total gerada no Brasil, distribuídos em 443 parques eólicos. Os estados brasileiros que apresentam maior número de parque eólico são: Bahia, Rio Grande do Norte e Ceará (EÓLICA, 2017). Assim, demonstrando o crescimento deste setor no Brasil quando compara-se este dado com o percentual apresentado na Figura 2.2.

2.1.3.5 Micro turbinas

Micro turbinas são compostas por um compressor, uma câmara de combustão, uma turbina e um gerador, que é acoplado ao eixo da turbina. O combustível mais utilizado nas turbinas é o gás natural, mas também pode ser alimentado com gás propano, gás natural, biogás ou combustíveis líquidos, como diesel ou querosene, se conservando uma energia limpa, uma vez que possui uma combustão limpa e com baixas emissões de partículas (WOTTRICH, 2010).

A potência produzida pela micro turbina varia no intervalo de 20 kW e 500 kW, sendo adequadas para aplicações comerciais. As vantagens das micro turbinas são (WOTTRICH, 2010):

- possui baixo nível de emissões de poluentes, de ruído e de vibração;
- flexibilidade quanto ao combustível empregado, podendo ser gás natural, diesel, propano, biogás;
- apresenta dimensões reduzidas e simples instalação;
- Pequena necessidade de manutenção;
- sua eficiência geral, quando utilizada em cogeração, pode atingir 85%, considerando a eficiência elétrica e térmica (LORA, 2006);
- pode operar em paralelo com a rede ou em sistemas isolados;
- alta confiabilidade.

2.1.3.6 Células a Combustível

As células a combustível possibilitam a conversão de energia química em energia elétrica, como o uso de eletrólito polimérico, metanol direto, ácido fosfórico, carbono fundido, óxido sólido ou hidrogênio. É constituída por três componentes ativos: um eletrodo combustível, um oxidante e uma membrana eletrolítica.

A faixa de potência produzida varia de 5 kW a 200 kW, no Brasil, sendo empregadas para abastecer cargas essenciais ou críticas, que são consumidores os quais necessitam de um alto grau de confiabilidade no suprimento de energia fornecida (DENIS, 2003).

Os benefícios de sua utilização segundo LORA (2006):

- podem ser usados em residências e edifícios, por possuir baixo ruído e vibrações;
- apresenta alta confiabilidade e disponibilidade;
- sistemas compactos;
- reduzida emissões resíduos;
- alta eficiência (40-60%);
- baixos custos de manutenção.

2.1.4 O Estado Regulatório da Geração Distribuída no Brasil

Em uma tentativa de regulamentar a GD no Brasil o Instituto Nacional de Eficiência Energética(INEE) propôs modificações na Resolução 28199, da ANEEL, porém estas não foram incorporadas. Somente com o Decreto nº 5163 de 30 de julho de 2004 (ANEEL, 2004), publicado pela ANEEL, no capítulo *II*, seção *I*, artigo 15 foi regularizado a comercialização da energia produzida pela GD.

”Art. 15. A contratação de energia elétrica proveniente de empreendimentos de geração distribuída será precedida de chamada pública promovida diretamente pelo agente de distribuição, de forma a garantir publicidade, transparência e igualdade de acesso aos interessados. §1º O montante total da energia elétrica contratada proveniente de empreendimentos de geração distribuída não poderá exceder a dez por cento da carga do agente de distribuição.

(...)

§6º O lastro para a venda da energia elétrica proveniente dos empreendimentos de geração distribuída será definido conforme o estabelecido nos §§1º e 2º do art. 2º.”

O decreto nº 5163 apenas descreve e regulariza a GD sem apresentar nenhum tipo de incentivo a sua utilização por parte da distribuidora, uma vez que qualquer forma de ganho deveria ser repassada ao consumidor final.

Em meados de 2006 ocorre a publicação da Resolução normativa ANEEL nº 235 (ANEEL, 2006), a qual estabelece as condições para qualificar termelétricas cogeneradoras. Assim, originou-se o conceito de cogeração qualificada, combinando a produção de calor útil e eletricidade com eficiência.

Com a publicação da Resolução Normativa ANEEL nº 482 de 17 de abril de 2012 (ANEEL, 2012), que foi modificada pela Resolução Normativa ANEEL 687 em 24 de novembro de 2015 (ANEEL, 2015), há um incentivo ao uso da GD, mas desta vez destinado a compensação de energia (*net-metering*).

”Art. 1º Estabelecer as condições gerais para o acesso de microgeração e minigeração distribuídas aos sistemas de distribuição de energia elétrica e o sistema de compensação de energia elétrica.

Art. 2º Para efeitos desta Resolução, ficam adotadas as seguintes definições:

I - microgeração distribuída: central geradora de energia elétrica, com potência instalada menor ou igual a 75 kW e que utilize cogeração qualificada, conforme regulamentação da ANEEL, ou fontes renováveis de energia elétrica, conectada na rede de distribuição por

”meio de instalações de unidades consumidoras;

II - minigeração distribuída: central geradora de energia elétrica, com potência instalada superior a 75 kW e menor ou igual a 3 MW para fontes hídricas ou menor ou igual a 5 MW para cogeração qualificada, conforme regulamentação da ANEEL, ou para as demais fontes renováveis de energia elétrica, conectada na rede de distribuição por meio de instalações de unidades consumidoras;

III - sistema de compensação de energia elétrica: sistema no qual a energia ativa injetada por unidade consumidora com microgeração ou minigeração distribuída é cedida, por meio de empréstimo gratuito, à distribuidora local e posteriormente compensada com o consumo de energia elétrica ativa;

(...)

VII - geração compartilhada: caracterizada pela reunião de consumidores, dentro da mesma área de concessão ou permissão, por meio de consórcio ou cooperativa, composta por pessoa física ou jurídica, que possua unidade consumidora com microgeração ou minigeração distribuída em local diferente das unidades consumidoras nas quais a energia excedente será compensada;

VIII - autoconsumo remoto: caracterizado por unidades consumidoras de titularidade de uma mesma Pessoa Jurídica, incluídas matriz e filial, ou Pessoa Física que possua unidade consumidora com microgeração ou minigeração distribuída em local diferente das unidades consumidoras, dentro da mesma área de concessão ou permissão, nas quais a energia excedente será compensada.”

Porém, a Resolução Normativa ANEEL n^o 482 também estabelece limites para a injeção de potência na rede, sendo uma barreira a implantação da GD.

§1^o A potência instalada da microgeração e da minigeração distribuída fica limitada à potência disponibilizada para a unidade consumidora onde a central geradora será conectada, nos termos do inciso LX, art. 2^o da Resolução Normativa n^o 414, de 9 de setembro de 2010.

§2^o Caso o consumidor deseje instalar central geradora com potência superior ao limite estabelecido no §1^o, deve solicitar o aumento da potência disponibilizada, nos termos do art. 27 da Resolução Normativa n^o 414, de 9 de setembro de 2010, sendo dispensado o aumento da carga instalada.

§3^o É vedada a divisão de central geradora em unidades de menor porte para se enquadrar nos limites de potência para microgeração ou minigeração distribuída, devendo a distribuidora identificar esses casos, solicitar a readequação da instalação e, caso não atendido, negar a adesão ao Sistema de Compensação de Energia Elétrica.”

O Conselho Nacional de Política Fazendária (CONFAZ), estabeleceu em 2013 através do Convênio ICMS nº 6, que o ICMS deveria ser cobrado sobre o montante total de energia transacionado com a distribuidora e não apenas sobre o consumo líquido. Sendo um empecilho à disseminação da GD no Brasil, uma vez que, alonga o prazo de retorno financeiro. Mas em 2015 este convênio foi revogado e no Convênio ICMS 16 fica estabelecido que os governos dos Estados autorizem a isenção do ICMS.

Outro ponto que deve ser ressaltado é que de acordo com as Lei nº 9.074/1995 (REPÚBLICA, 1995), a ANEEL precisa autorizar a exploração de centrais termelétricas, eólicas e de outras fontes alternativas de energia com potência acima de 5 MW e as centrais hidrelétricas com potência acima de 3 MW. No caso das potências serem inferiores as indicadas, basta o registro neste órgão regulador, o que facilita a implantação deste tipo de GD.

2.2 Revisão Bibliográfica

O objetivo desta seção é expor um estudo bibliográfico detalhado, assim possibilitando um maior entendimento das principais metodologias de soluções para o problema de alocação e dimensionamento da GD.

O problema de alocação e dimensionamento da GD ganhou destaque à aproximadamente vinte anos (GEORGILAKIS; MEMBER; HATZIARGYRIOU, 2013), sendo abundante a literatura publicada descrevendo os algoritmos de alocação e dimensionamento ou algoritmos que realizam apenas um desses procedimentos.

Os métodos analisados neste tópico consistem em: métodos analíticos, métodos numéricos, métodos heurísticos e métodos meta-heurísticos.

2.2.1 Métodos Analíticos

A seguir são apresentados os métodos analíticos utilizados por alguns autores para a alocação e dimensionamento da GD. Esta metodologia se caracteriza por expor respostas ótimas globais.

Em Acharya, Mahat e Mithulananthan (2006) é proposto uma metodologia analítica para alocar e dimensionar a GD de forma ótima, com a finalidade de minimizar as perdas de potência totais em sistemas de distribuição radiais, sem considerar a restrição da tensão. A metodologia apresenta uma expressão analítica para dimensionar a GD, com fator de potência unitário. Empregando um fator de sensibilidade de perdas, o qual é calculado realizando a derivada das perdas de potência exatas em relação a potência injetada pela GD. Está técnica foi testada e validada em três sistemas de teste de distribuição com diferentes tamanhos e complexidade.

Kashem et al. (2006) emprega um índice de sensibilidade para indicar a variação das perdas de potência ativa no ramo em relação a corrente injetada pela GD no mesmo, considerando magnitude e fase da potência. Este trabalho tinha a finalidade de minimizar as perdas e fornecer o ponto de alocação da GD, seu dimensionamento e seu ponto de operação.

Gözel e Hocaoglu (2009) baseia no índice de sensibilidade de perdas na injeção de corrente, com o propósito de alocar e dimensionar a GD de forma ótima e minimizar as perdas totais de energia. Utiliza apenas um cálculo de fluxo de carga para encontrar a solução, sem a necessidade de usar a matriz impedância, admitância ou a matriz Jacobiana.

Em Hung e Mithulananthan (2013) sua metodologia emprega um índice de sensibilidade de perda associado ao fluxo de carga exaustivo para a alocação e dimensionamento da GD, considerando quatro diferentes tipos de GD, que: somente injetam potência reativa, somente injetam potência ativa, com fator de potência dimensionável e o pico de carga. Também é capaz de fornecer o fator de potência ótimo para a potência injetada pela GD.

Hung, Mithulananthan e Lee (2014) apresentam uma metodologia analítica, baseada na equação de perdas exatas, que dimensionam a potência e o fator de potência da GD simultaneamente. Esses valores são testados para cada barra do sistema, a fim de minimizar as perdas de energia. Essas expressões são adaptadas para localizar e dimensionar diferentes unidades GD renováveis e calcular o fator de potência ótimo para cada unidade para minimizar as perdas de energia, considerando simultaneamente as características variáveis no tempo da demanda e da geração. Além disso, neste trabalho, propõe-se uma combinação de unidades de GD renováveis despacháveis e não despacháveis.

Viral e Khatod (2015) apresentam uma metodologia analítica que baseia-se na minimização da perda associadas a componentes ativo e reativo das correntes de derivação colocando o GD em vários locais. Assim, determina a localização ideal e dimensiona a GD em rede de distribuição radial equilibrada para minimizar as perdas de potência do sistema. Este método primeiro identifica uma sequência de barras onde a GD pode ser alocada, sendo necessário dimensionar a GD para verificar a economia das perdas para cada barra. Para descobrir o melhor local para a alocação GD, um método computacional também é desenvolvido.

No trabalho de Murty e Kumar (2015) é proposto um índice de estabilidade de tensão para a alocação ótima da GD em sistemas de distribuição radial. Após a identificação da barra candidata para a alocação da GD, a técnica de busca é usada para dimensionar a GD, afim de minimizar a perda de potência total e melhorar os níveis de tensão. Considera-se a alocação de apenas uma GD sendo capaz de indicar o fator

de potência ótimo.

Tah e Das (2016) propõe uma metodologia analítica para alocar e dimensionar a GD, baseada nas perdas de potência ativa, sem a necessidade do cálculo da matriz impedância, assim se diferenciando da literatura. Isto é possível por ser empregado valores aproximados para o cálculo das perdas e para dimensionar a GD para cada barramento. Inicialmente a GD é dimensionada para cada barramento, de posse desses valores é possível calcular os valores aproximados das perdas de potência totais do sistema. Com estes valores cria-se uma lista decrescente, sendo possível estimar a configuração que tem as melhores características. Posteriormente as perdas exatas são calculadas. A metodologia foi testado para o sistema 33 e 69 barras.

2.2.2 Métodos Numéricos

Os métodos numéricos empregados para alocação e dimensionamento da GD são: método do gradiente, programação binível, programação linear, programação quadrática sequencial, programação não-linear, programação dinâmica, otimização ordinal e busca exaustiva. A seguir serão expostos alguns trabalhos utilizando algumas dessas técnicas.

Keane e O'Malley (2005) emprega a programação linear associada ao fluxo de potência, buscando maximizar a capacidade da GD instalada, sujeita a restrições técnicas e operacionais. Os autores visavam alocar e dimensionar múltiplas GD no sistema de distribuição, considerando apenas um nível de carga. Esta técnica foi testada utilizando uma amostra do sistema de distribuição da Irlanda.

Rueda-Medina et al. (2013) expõem a formulação de um problema linear inteiro misto para alocar, dimensionar e determinar o tipo da GD em sistemas de distribuição radiais. Seu objetivo é minimizar o custo total de investimentos e operação, respeitando as restrições operacionais e físicas. Foram utilizadas linearizações para representar o sistema de distribuição radial operando em regime permanente, em diferentes níveis de carga. Os diferentes tipos da GD são apresentados como curvas de capacidade. Para implementação da formulação foi utilizado um *solver* de otimização comercial CPLEX.

Em Khalesi, Rezaei e Haghifam (2011) a programação dinâmica é utilizada para a alocação e dimensionamento ótima de GD no sistema de distribuição. Sua função multi-objetivo, possui a finalidade de minimizar as perdas de energia, aumentar a indicadores de confiabilidade dos sistemas e melhorar o perfil de tensão. Os diferentes níveis de carga são considerados para se obter resultados mais realistas. A função objectivo utilizada pelos autores é dividido em duas partes. A primeira reúne um conjunto de somas que descrevem os benefícios da GD para o sistema e o segundo conjunto de somatórios considera os custos de investimento, manutenção e os custos operacionais. Cálculos são feitos para maximizar os benefícios e minimizar os custos.

Lopez-Lezama et al. (2011) consideram uma programação binível com objetivo de otimizar o preço dos contratos para instalação da GD, onde o proprietário da GD tem o lucro maximizado com o melhor contrato e a concessionária minimiza os custos das perdas de potência do sistema. Baseia-se em uma aproximação não linear para o fluxo de potência.

A busca em gradiente é empregada por Rau e Wan (1994) e Vovos e Bialek (2005), para alocação da GD são consideradas redes malhadas e as falhas da rede, respectivamente. Em Rau e Wan (1994) é considerado a minimização das perdas de potência para alocação de múltiplas GDs, já em Vovos e Bialek (2005) o objetivo é maximizar os lucros e levando em conta a variação dos níveis de carga.

A programação não linear mista é uma combinação de programação linear, não-linear e mista inteira. Esta técnica é aplicável tanto para variáveis discretas como contínuas e funções não-lineares, uma vez que as formulações de fluxo de energia são de natureza não linear. Além disso, o método baseado em programação não linear mista é capaz de fornecer soluções precisas, eficientes e confiáveis para formulações multi-objetivas implementadas em: El-Khattam, Hegazy e Salama (2005), Kaur, Kumbhar e Sharma (2014), El-saadany (2010), Kumar e Gao (2010).

A otimização ordinal é uma ferramenta que é empregada para reduzir a complexidade computacional em problemas de otimização baseados em simulação. O método é bem adequado para encontrar um ótimo dimensionamento e localização da GD em um sistema de distribuição para atender os objetivos, tais como perdas de potência, custo ou ajuste entre a minimização de perdas e a capacidade de GDs sugerida em: Mohandas, Balamurugan e Lakshminarasimman (2015), Jabr e Pal (2009).

A busca exaustiva é utilizada em: Ochoa, Padilha-Feltrin e Harrison (2008), empregando índice de desempenho multi-objetivo considerando a variação do tempo, o comportamento da demanda e geração, para indicar a posição da GD; Zhu et al. (2006), com o objetivo é maximizar a confiabilidade e minimizar as perdas do sistema, tendo como resultado a localização da GD, sendo aplicado para variação de tempo; e Khan e Choudhry (2010), considera o número, a alocação e o dimensionamento da GD, emprega apenas um nível de carga e visa minimizar as perdas.

2.2.3 Métodos Heurísticos

Os métodos heurísticos são metodologias de menor complexidade para a aplicação quando comparados com métodos analíticos e de programação numérica. Porém seus resultados são ótimos locais, e não possuem nenhuma garantia de serem ótimos globais. A seguir serão apresentados alguns trabalhos que empregam heurísticas.

Hedayati, Nabaviniaki e Akbarimajd (2006) utilizam um algoritmo iterativo, no

qual a modelagem escolhida pelos autores baseia-se no fluxo de potência contínuo. O objetivo do algoritmo é reduzir as perdas de potência, melhorar a transferência de potência e aumentar a estabilidade do perfil de tensão. O algoritmo determina a barra na qual há uma maior probabilidade de colapso de tensão ou onde está a máxima carga e a GD é alocada como forma de compensar estes problemas.

Em Banerjee e Islam (2011) opta-se por melhorar a confiabilidade dos sistemas de distribuição, assim como também reduzir as perdas de potência totais. Sua abordagem é probabilística e o sistema foi modelado com o processo de Markov. A localização ideal para a GD neste caso ocorre no local que forneça o máximo acesso aos clientes, em termos de números de clientes. O tipo de geração afeta os índices de sensibilidade da confiabilidade, porém não interfere no posicionamento.

Hamedi e Gandomkar (2012) propõem uma metodologia baseada na classificação da energia não fornecida e na perdas de potência nos ramos do sistema. Seu objetivo é melhorar os índices de confiabilidade, reduzir as perdas de potência e melhorar a qualidade de energia. Empregou-se o *software* CYMEDIST, para os cálculos. Para poder avaliar os vários níveis de carga foi utilizado do modelo de Markov, para carga base e pico. As harmônicas também são observadas através do índice de distorção harmônica total.

Em Tamimi, Pahwa e Starrett (2012) incorporou-se a análise modal associada a análise da curva Q-V, método tradicional empregado para verificação da estabilidade das tensões. Foi utilizado para o dimensionamento de parques eólicos com base em instabilidade de tensão.

Abu-Mouti e El-Hawary (2011) empregam o algoritmo de otimização baseado na privação sensorial, que tem a função de alocar de forma ótima à GD, e seu fator de potência. Para o cálculo das perdas para as possíveis configurações da GD é utilizado o fluxo de potência para sistemas de distribuição radiais incluindo GD, exposto em Abu-Mouti e El-Hawary (2007).

2.2.4 Métodos Meta-heurísticos

Os métodos meta-heurísticos atualmente são os mais utilizados para a alocação da GD. Porém, apresentam respostas que são ótimos locais. A seguir serão apresentados alguns trabalhos que empregam métodos meta-heurísticas:

Kyu-Ho Kim et al. (2002) propõem uma formulação com o objetivo de reduzir os custos das perdas do sistema de distribuição e respeitando as restrições do número e do despacho da GD. Esta formulação é convertida em uma multi-objetivo empregando a técnica *fuzzy* assim reduzindo a complexidade do problema sem a necessidade de linearização. Para solucionar esta formulação é empregado o algoritmo genético (AG)

tradicional.

Celli et al. (2005) empregam a metodologia do AG para encontrar a melhor solução, de uma função multi-objetivo, entre custos de melhoria da rede, custos de perdas de energia, custos de energia não suprida e custos da energia requerida pelos clientes atendidos. O algoritmo empregado define o despacho da GD dentro de um grupo de dimensionamento pré-definidos: 200, 400, 600 kW e é capaz de definir a posição a ser alocada a GD.

Pisica, Bulac e Eremia (2009) comparam o AG tradicional com a otimização não linear para alocar e dimensionar unidades da GD. Tem como objetivo reduzir as perdas de potência e os custos de investimentos. Através dos resultados obtidos é possível observar que o algoritmo de otimização não linear, quando comparado ao AG, não é capaz de superar a complexidade do problema quando considera-se a alocação de mais de duas GDs.

Em Singh e Goswami (2010) o AG é empregado com a finalidade de alocar e dimensionar a GD, para maximizar os lucros da concessionária, assim como reduzir as perdas e melhorar os níveis de tensão. Esta abordagem proposta é baseada em um mecanismo de preços encontrado nos sistemas de transmissão.

No trabalho de López-Lezama, Contreras e Padilha-Feltrin (2012) o AG especializado, de Chu-Beasley, é empregado para maximizar o lucro do proprietário da GD, indicando a melhor posição da GD com despacho pré-definidos e minimizar os custos para as companhias de distribuição; sua formulação é bi-nível, onde cada um dos níveis corresponde a um agente com sua função objetivo e sujeito a restrições específicas, onde cada um dos agentes representam o interesse do proprietário e da companhia de distribuição, respectivamente.

Dias et al. (2012) emprega o algoritmo otimização de enxame de partícula (OEP) em conjunto com o fluxo de potência ótimo não linear para alocação e dimensionamento da GD. As barras mais sensíveis à injeção de potência são listadas, assim reduzindo o espaço de busca do problema. A meta-heurística é utilizada para definir as melhores barras a serem alocadas a GD e o fluxo ótimo dimensiona a GD respeitando os limites das tensões e o fator de potência é livre.

Shaaban, Atwa e El-Saadany (2013) propõem uma abordagem multi-objetivo, baseada no AG, para a alocação ótima de diferentes tipos da GD no sistema de distribuição. Seus principais objetivos são: reduzir o custo de investimento de modificações no sistema, custo das perdas anuais de energia e custo de interrupção. Neste trabalho é apresentado uma nova abordagem para avaliar os requisitos de melhoria na presença das GDs renováveis nos sistemas de distribuição, onde um novo fator é introduzido para representar o risco de sobrecarga de linhas do sistema.

Ravikumar Pandi, Zeineldin e Xiao (2013) empregam a OEP para encontrar o tipo, localização e dimensionar a GD, considerando limites padrões das harmônicos e restrições de coordenação da proteção. Seu objetivo é maximizar a penetração da GD, sendo considerados dois tipos de GD. Se utiliza no fluxo de potência de Newton-Raphson para encontrar a tensão da fundamental e o balanço de potência.

No trabalho de Ugranli e Karatepe (2013) é proposto a alocação de múltiplas GDs, com a finalidade de minimizar as perdas considerando a incerteza de diferentes níveis de penetração da GD, portanto considerando níveis de carga, e a potência reativa inserida. Redes neurais foram utilizadas para encontrar a solução, assim contornando a não-linearidade do problema.

Em Coelho (2013) é empregado o algoritmo bioinspirado na ecolocalização de morcegos modificado e combinado com o fluxo de potência ótimo, considerando a carga constante. Seus resultados comparam a alocação de potência ativa e reativa, separadas e associadas, e seu impacto sobre o sistema.

Mohamed e Kowsalya (2014) empregam o algoritmo de otimização de alimentação bacteriana para alocar e dimensionar múltiplas GD no sistema de distribuição, sendo capaz de determinar o fator de potência ótimo. A alocação da GD é encontrada utilizando índice de sensibilidade de perdas e o dimensionamento é realizado pelo algoritmo proposto. Visa reduzir as perdas de potência considerando diferentes níveis de carga.

Devi e Geethanjali (2014) utilizam o algoritmo de otimização de alimentação bacteriana modificada para a alocação e dimensionamento da GD ideal. Com o objetivo de reduzir a perda e melhorar o perfil de tensão em sistemas de distribuição radiais. O algoritmo é implementado no MatLab ®.

Jain, Singh e Srivastava (2014) OEP modificado para alocação de múltiplas GDs, eólicas, e capacitores, empregando o método de Monte Carlo para calcular o fluxo de potência probabilístico, o qual considera a incerteza da demanda de carga e da geração eólica. Para o dimensionamento da GD e dos capacitores foi empregado um índice de sensibilidade

Grisales et al. (2015) emprega o AG melhorado que aloca a GD, em conjunto com o OEP, o qual dimensiona as GDs, renováveis, considerando as características geográficas no local no qual a GD será instalada. Possui como objetivo reduzir as perdas de potência, melhorar os níveis de tensão e reduzir o custo de instalação da GD, considerando a inserção da GD: eólica, solar e PCH.

Bohre, Agnihotri e Dubey (2016) propõem uma formulação multi-objetivo, visando minimizar as perdas de potência ativa e reativa, melhorar o perfil de tensão e o índice de confiabilidade, considerando diferentes pesos para cada um dos objetivos. Emprega o GA e OEP para solucionar a formulação, sendo capaz de alocar e dimensionar a GD.

Sultana e Roy (2016) emprega o algoritmo de rebanho do krill em conjunto com o conceito da base de aprendizagem oposta, o que permite uma maior velocidade de convergência e melhorá a qualidade das solução obtidas. Este algoritmo foi implementado com o objetivo de alocar e dimensionar diferentes tipos de GD, renováveis, em sistema de distribuição radiais, com a finalidade de minimizar as perdas de potência anual.

Dahal e Salehfar (2016) empregam o algoritmo OEP em conjunto com o fluxo de potência ótimo trifásico para alocar e dimensionar múltiplas GDs de diferentes tipos, em sistemas trifásicos desequilibrados. Seus objetivos são reduzir o percentual de perdas de potência e melhor os níveis de tensão. Para isto são empregas duas ferramentas distintas: o Matlab®, para o desenvolvimento do OEP, e o OpenDSS para o cálculo do fluxo de potência, assim aumentando a complexidade para sua implementação.

Kansal, Kumar e Tyagi (2016) emprega uma combinação de uma metodologia analítica capaz de alocar múltiplas GDs de múltiplos tipos, que é utilizada para dimensionar a GD, e o algoritmo OEP é empregado para encontrar a posição ótima. A técnica proposta pode ser implementada para encontrar a combinação de diferentes tipos de GD. A técnica proposta permitiu concluir que a alocação ideal de múltiplas GDs não apenas reduz as perdas de linha, mas também minimiza os tamanhos das GDs com a satisfação dos limites de tensão permitidos.

Hosseini e Abbasi (2016) propõem uma abordagem multi-objetivo, baseada no AG, onde se trata a reconfiguração do sistema de distribuição simultaneamente com a alocação e dimensionamento da GD, considerando a presença de baterias e o cálculo do índice de não suprimento de energia. Sendo seu objetivo a redução das perdas e do índice de não suprimento de energia. Neste trabalho também são avaliados o custo de implementação e manutenção da GD, fotovoltaica. Estes objetivos são avaliados simultaneamente, porém de modo separado assim sendo diferente do modo convencional, somente ao fim são avaliados em conjunto.

Khanbabapour e Hamedani Golshan (2016) apresentam um modelo para o planejamento da alocação e dimensionamento da GD síncrona simultaneamente com o melhoramento das malhas da rede de distribuição, econômica e tecnicamente, e dois sistemas de proteção, sobre corrente e a performa dos relés para anti-ilhamento. Assim, sendo uma formulação multi-objetivo, a técnica empregada para a solução desse modelo foi a busca tabu.

Vatani et al. (2016) emprega o AG para alocar e dimensionar o fator de potência da GD, a potência despachada é dimensionada usando uma metodologia analítica, baseada em um conjunto de equações obtidas a partir do método Lagrangeano relaxado. Apresenta soluções para o sistema 33 e 69 barras.

Pereira et al. (2016) emprega um algoritmo híbrido, no qual combina a busca Tabu e o AG especializado, para alocar e dimensionar a GD em conjunto com bancos

de capacitores considerando a característica estocástica da GD. A busca Tabu é a metodologia principal responsável por encontrar a localização dos bancos de capacitores e da GD e o GA é encarregado de solucionar o fluxo de potência ótimo. Seus principais objetivos são minimizar os custos operacionais e investimento.

Neste trabalho propõem-se uma metodologia para solucionar o problema de alocação e dimensionamento da GD em sistemas de distribuição radiais. Para isto é exposto um modelamento matemático e emprega-se o AGE, assim buscando soluções de qualidade.

2.3 Considerações Finais do Capítulo

Neste capítulo foram apresentados os diferentes conceitos aceitos para a GD, as vantagens e desvantagens de sua alocação para sistemas de distribuição radiais, as diferentes tecnologias da GD, sendo a principal fonte empregada no Brasil a hidroelétrica, que é uma fonte renovável. Também, é exposto o estado regulatório da GD no Brasil, que nos últimos anos vem incentivando sua instalação.

A revisão bibliográfica apresenta as diferentes metodologias utilizadas para alocação da GD como: analíticas, numéricas, heurísticas e meta-heurísticas, sendo as principais técnicas empregadas as heurísticas e meta-heurísticas por possuírem soluções de melhor qualidade e por conseguirem contornar a complexidade do problema apresentando tempos computacionais de qualidade. Nota-se uma tendência às metodologias híbridas onde ocorre uma combinação entre as técnicas mencionadas anteriormente.

Como visto na revisão bibliográfica o problema de alocação e dimensionamento da GD pode ser formulada de diferentes formas, dependendo do objetivo a ser atingido pelo autor.

Outro ponto a ser destacado é o emprego de meta-heurísticas combinada com outras técnicas nos trabalhos mais recentes para obtenção de resultados com boa qualidade.

Neste trabalho o principal objetivo da formulação visa minimizar os custos de implementação e manutenção da GD e os custos de operação da rede (perdas de potência ativa).

3 Formulação do Problema

Neste capítulo é apresentada a formulação do problema de alocação e dimensionamento da GD em sistema de distribuição de energia elétrica radiais, que é formulado como um problema não linear inteiro misto.

3.1 Modelamento Matemático

3.1.1 Modelamento Matemático para Alocação e Dimensionamento da Geração Distribuída


A alocação e dimensionamento das GDs é formulada como um problema de otimização matemática, que possui como objetivo minimizar os custos de instalação e manutenção da GD e os custos de operação da rede (perdas de potência). Esse problema está sujeito a restrições operacionais da rede – o balanço de cargas; a potência injetada pela subestação ou pela GD; as tensões e correntes, mínimas e máximas; permitidas nas barras e linhas, respectivamente – e o número de GD inseridos na rede.

O problema da alocação e dimensionamento das GDs é um problema não linear inteiro misto, devido à presença de variáveis inteiras, que indicam a posição a serem alocadas às GDs, e as contínuas associadas às variáveis elétricas do sistema elétrico (tensões correntes, fluxos de potência, perdas de potência ativa e reativa e a potência a ser injetada por cada GD).

Para solucionar este problema algumas hipóteses foram consideradas:

- as variações de carga serão aproximadas para níveis discretos com período de T_i ;
- as cargas variam em um mesmo padrão;
- a potência da carga é modelada sendo constante.

Na Figura 3.1 é apresentada a curva de níveis de carga $S(t)$ em relação a um período de tempo determinado T_i , assim considerando que todas as cargas do intervalo serão multiplicadas pelo fator S_i para este intervalo de tempo.

Figura 3.1: Curva dos níveis de carga.

Fonte: Próprio autor (2016).

Os níveis de carga representam a demanda do sistema por período de tempo T_i . Neste trabalho são considerados três perfis de carga.

A seguir o modelamento proposto é apresentado.

$$\text{Min. } f_o = k_c \cdot \sum_{i \in \Omega_b} n_i^{gd} \cdot (c_i * P_{i,d} + \sum_{d \in \Omega_d} r_k \cdot T_d \cdot P_{i,d}^{gd}) + \sum_{d \in \Omega_d} k_e^d \cdot T_d \cdot P_d^{perdas} \quad (3.1)$$

sujeito a:

$$\sum_{i \in \Omega_b} P_i^S - \sum_{i \in \Omega_b} P_{i,d}^D - \sum_{ij \in \Omega_l} (P_{ij,d} + I_{ij,d}^2 \cdot R_{ij}) + \sum_{i \in \Omega_b} P_{i,d}^{gd} \cdot n_i^{gd} = 0 \quad \forall i \in \Omega_b, \forall d \in \Omega_d \quad (3.2)$$

$$\sum_{i \in \Omega_b} Q_i^S - \sum_{i=1}^{nb} Q_{i,d}^D - \sum_{ij \in \Omega_L} (Q_{ij,d} + I_{ij,d}^2 \cdot X_{ij}) + \sum_{i=1}^{nb} Q_{i,d}^{gd} \cdot n_i^{gd} = 0 \quad \forall i \in \Omega_b, \forall d \in \Omega_d \quad (3.3)$$

$$V_{i,d}^2 - 2(R_{i,j} \cdot P_{ij,d} + X_{i,j} \cdot Q_{ij,d}) - Z_{ij}^2 \cdot I_{ij,d}^2 - V_{j,d}^2 = 0 \quad \forall ij \in \Omega_l, \forall d \in \Omega_d \quad (3.4)$$

$$V_{i,d}^2 \cdot I_{ij,d}^2 = P_{ij,d}^2 + Q_{ij,d}^2 \quad \forall ij \in \Omega_l, \forall d \in \Omega_d \quad (3.5)$$

$$0 \leq P_i^S \leq \overline{P_i^S} \quad \forall i \in \Omega_b \quad (3.6)$$

$$0 \leq Q_i^S \leq \overline{Q_i^S} \quad \forall i \in \Omega_b \quad (3.7)$$

$$0 \leq P_i^{gd} \leq \overline{P_{i,d}^{gd}} \quad \forall i \in \Omega_b \quad (3.8)$$

$$0 \leq Q_i^{gd} \leq \overline{Q_{i,d}^{gd}} \quad \forall i \in \Omega_b \quad (3.9)$$

$$\underline{V}^2 \leq V_{i,d}^2 \leq \overline{V}^2 \quad \forall i \in \Omega_b \quad (3.10)$$

$$0 \leq I_{ij,d}^2 \leq \overline{I_{ij}^2} \quad \forall ij \in \Omega_l \quad (3.11)$$

$$\sum_{k=1}^{nb} n_k^{dg} \leq \overline{n^{dg}} \quad (3.12)$$

$$n_k^{dg} \in \{1, 0\} \quad (3.13)$$

sendo nb o número de barras; c_k é a constante que representa o custo de instalação; n_k^{gd} vetor preenchido de valores binários, que indicam a existência ou a ausência de GD; T é o período total utilizado pelo sistema; r_k é a constante que representa o custo de manutenção da GD; k_e^i é o parâmetro de custo de energia, para cada nível de carga; nt é o número de perfis de carga do sistema; P_k^{gd} é a potência ativa instalada pela GD; T_d é o período de tempo para o perfil de carga; $P_d^{perdas} = I_{ij,d}^2 \cdot R_{ij}$ são as perdas de potência ativa totais para cada período; P_i^S e Q_i^S são, respectivamente, a potência ativa e reativa injetadas pela subestação; $P_{i,d}^D$ e $Q_{i,d}^D$ são a potência ativa e reativa, respectivamente, demandas pela barra i no nível de carga d ; $P_{ij,d}$ e $Q_{ij,d}$ são o fluxo de potência ativa e reativa, respectivamente; $I_{ij,d}^2 R_{ij}$ e $I_{ij,d}^2 X_{ij}$ são as perdas ativas e reativas no ramo ij , respectivamente, sendo representadas na figura 3.2 por $I_{ij,d}^2 \vec{Z}_{ij}$ (impedância), R_{ij} e X_{ij} são a resistência e a reatância do ramo ij ; P_{ki}^{gd} e Q_{ki}^{gd} são as potências ativas e reativas inseridas pela geração distribuída; \overline{P}_i^S e \overline{Q}_i^S são os valores máximos aceitáveis para a potência ativa e reativa inseridas pela subestação, respectivamente, para todo o conjunto de barras (Ω_b); \overline{P}_i^{gd} e \overline{Q}_i^{gd} são os valores máximos aceitáveis para a potência ativa e reativa inseridas pela GD, respectivamente, para o Ω_b ; $V_{i,d}$ tensão na barra i para o nível de carga d ; \underline{V} e \overline{V} são os valores mínimos e máximos aceitáveis para o Ω_b , respectivamente; \underline{I}_{ij} e \overline{I}_{ij} são os valores mínimos e máximos aceitáveis para a corrente em todo o conjunto de linhas (Ω_l); $\overline{n^{gd}}$ é constante que representa o número máximo de GDs instalados no sistema.

As equações (3.2)-(3.5) simbolizam o estado de operação do regime permanente de um sistema de distribuição de energia elétrica e as outras equações consideram a presença da geração distribuída e diferentes níveis de demanda.

A seguir é apresentado a descrição de cada uma das restrições do modelamento matemático não linear inteiro misto.


A função objetivo, equação 3.1, representa o custo total, a qual é dividida em dois somatórios. O primeiro somatório expõe o custo de investimento, que é dividida em custo de instalação da GD, de acordo com a potência a ser instalada, e o custo de manutenção ao longo de um período determinado, que é representado por uma somatório cujo o intervalo de varredura é determinado pelo número de níveis de demanda. O segundo somatório o custo de perdas de potência de acordo com um período determinado.

Na restrição 3.2, o balanço de carga para a potência ativa, primeira lei de Krichhoff, para cada barra i , no nível de demanda d , como visto na Figura 3.2. Analisando esta nota-se que a equação é constituída da injeção de potência pela subestação na barra i subtraindo a potência demandada pela barra i e as perdas de potência no ramo ij e a soma da potência ativa inserida pela GD. Como é possível notar os três primeiros somatórios representam o balanço de carga, para potência ativa convencional, portanto

o quarto somatório apresenta a inserção da potência ativa da GD, este valor é obtido através do AGE, o qual fornece a potência ativa que deve ser despachada pela GD.

Na restrição 3.3, o balanço de carga para a potência reativa, primeira lei de Kirchhoff, para cada barra i , no nível de demanda d , como visto na Figura 3.2. Analisando esta nota-se que a equação é constituída da injeção de potência pela subestação na barra i subtraindo a potência demandada pela barra i e as perdas de potência no ramo ij e a soma da potência reativa inserida pela GD. Como é possível notar os três primeiros somatórios representam o balanço de carga, para potência reativa convencional, portanto o quarto somatório apresenta a inserção da potência reativa da GD. Este valor é obtido através do AGE, o qual fornece a potência reativa que deve ser despachada pela GD.

Figura 3.2: Representação simplificada do sistema.



Fonte: Próprio autor (2016).

Para o cálculo das perdas de potência, $P_i^{perdas} = I_{ij,d}^2 \cdot R_{ij}$ e $Q_i^{perdas} = I_{ij,d}^2 \cdot X_{ij}$, é utilizado o método de solução de fluxo de potência *Backward-Forward Sweep*, apresentado em Shirmohammadi et al. (1988), o qual possibilita calcular as perdas para cada um dos níveis de carga.

O fluxo de potência no ramo ij do sistema, observado na Figura 3.2, pode ser representada pelas equações 3.14 e 3.15, as quais são o fluxo de potência ativa e reativa, respectivamente. Estas representam a formulação adotada para o modelo de rede.

$$P_{ij,d} = V_{i,d}^2 \cdot g_{ij,d} - V_{i,d} \cdot V_{j,d} \cdot g_{ij,d} \cdot \cos(\theta_i - \theta_j) - V_{i,d} \cdot V_{j,d} \cdot b_{ij,d} \cdot \sin(\theta_i - \theta_j) \quad \forall ij \in \Omega_l, \forall d \in \Omega_d \quad (3.14)$$

$$Q_{ij,d} = -V_{i,d}^2 \cdot b_{ij,d} - V_{i,d} \cdot V_{j,d} \cdot b_{ij,d} \cdot \cos(\theta_i - \theta_j) - V_{i,d} \cdot V_{j,d} \cdot g_{ij,d} \cdot \sin(\theta_i - \theta_j) \quad \forall ij \in \Omega_l, \forall d \in \Omega_d \quad (3.15)$$

Como é possível notar as equações do fluxo de potência, as quais são necessárias para calcular o balanço de carga, não são lineares, assim ocasionando a não linearidade

do modelamento adotado.

A condutância e a susceptância do sistema para o ramo i, j são apresentados nas equações 3.16 e 3.17, respectivamente. Estes valores são necessários para o cálculo do fluxo de potência do ramo ij .

$$g_{ij,d} = \frac{R_{ij,d}}{R_{ij,d}^2 + X_{ij,d}^2} \quad \forall ij \in \Omega_l, \forall ij \in \Omega_l, \forall d \in \Omega_d \quad (3.16)$$

$$b_{ij,d} = \frac{X_{ij,d}}{R_{ij,d}^2 + X_{ij,d}^2} \quad \forall ij \in \Omega_l, \forall ij \in \Omega_l, \forall d \in \Omega_d \quad (3.17)$$

A restrição 3.4 evidencia a queda de tensão, onde a magnitude de tensão da barra final ($V_{j,d}^2$), é calculada empregando a magnitude da tensão na barra inicial ($V_{i,d}^2$), subtraindo o valor de demanda em um ponto de operação no sistema e as perdas de potência ativa e reativa no circuito ij ($Z_{ij}^2 I_{ij}^2$).

A restrição 3.5, que representa o cálculo da magnitude do fluxo de corrente, é não linear devido ao produto da magnitude de tensão pela corrente e ao quadrado dos fluxos de potência ativa e reativa, assim sendo outra característica que ocasiona não linearidade do modelamento adotado.

A restrição 3.6 expressa o limite da potência ativa que pode ser inserido pela subestação na barra i do sistema, sendo o limite inferior zero e o superior $\overline{P_i^S}$.

A restrição 3.7 expressa o limite da potência reativa que pode ser inserido pela subestação na barra i do sistema, sendo o limite inferior zero e o superior $\overline{Q_i^S}$.

A restrição 3.8 apresenta o limite da potência ativa que pode ser inserido pela GD na barra i do sistema, sendo o limite inferior zero e o superior $\overline{P_i^{gd}}$. O valor de P_i^{gd} é fornecido pelo AGE.

A restrição 3.9 apresenta o limite da potência reativa que pode ser inserido pela GD na barra i do sistema, sendo o limite inferior zero e o superior $\overline{Q_i^{gd}}$. O valor de Q_i^{gd} é fornecido pelo AGE.

A restrição 3.10 refere-se aos limites de magnitude de tensão ao quadrado na barra i para o nível de demanda d , delimitado por \underline{V}^2 e \overline{V}^2 , que são os, respectivamente, limites inferior e o superior.

A restrição 3.11 expressa os limites do fluxo de corrente no circuito ij , para o nível de demanda d que neste caso é delimitado por zero e pelo valor máximo da corrente.

A restrição 3.12 apresenta o limite máximo de geradores distribuídos serão instalados no sistema, $\overline{n^{gd}}$.

A restrição 3.13 refere-se ao tipo de dados contidos no vetor n_k^{gd} , sendo utilizado 1


para indicar a existência de uma GD em uma determinada barra e 0 para a ausência da GD.

A metodologia proposta aplica uma penalização na função objetivo, função inapetível, quando ocorre a violação da tensão e da corrente, a equação é apresentada a seguir:

$$f'_o = \tau \left(\sum_{d \in \Omega_d} \gamma_d T_d P_d^{perdas} + \gamma_d k_c \sum_{k \in \Omega_b} n_k^{dg} (c_i * P_{i,d} + r_k T P_k^{gd}) \right) \quad (3.18)$$

O modelo apresentado anteriormente é um problema de alta complexidade matemática, já que apresenta o fenômeno de explosão combinatorial, isto é, a medida que o tamanho do sistema elétrico cresce o número de potenciais soluções se incrementa exponencialmente, assim elevando o grau de dificuldade para encontrar a solução ótima global do problema. Esta característica acarreta elevados tempos computacionais nas técnicas exatas e em muitos casos este tempo torna-se proibitivo. Dessa forma técnicas meta-heurísticas são empregadas, uma vez que, para este tipo de problema as meta-heurísticas encontram soluções de altíssima qualidade (ótimos locais) em tempos computacionais inferiores quando compara-se com uma técnica analítica. O problema pode ser dividido em dois, como pode ser visto na Figura 3.3, ou seja, um mestre, o qual será solucionado empregando um algoritmo genético especializado, e um escravo que será solucionado através de um fluxo de potência. Dessa forma, almeja-se encontrar soluções de altíssima qualidade para redes de distribuição da literatura especializada e para sistemas reais a serem testados.

Figura 3.3: Esquemático da abordagem para a solução do problema de alocação e dimensionamento da GD.



Fonte: Próprio autor (2016).

Na Figura 3.3, nota-se que o AGE, mestre, fornece a alocação e o dimensionamento da GD para o fluxo de potência, escravo, o qual retorna ao AGE os valores da tensão nas barras, a corrente nos ramos, as perdas do sistema e o fluxo de potência. Estes valores serão utilizados pelo programa mestre para avaliar a qualidade da configuração proposta.

3.2 Considerações Finais do Capítulo

No presente capítulo, apresentou-se a formulação matemática empregada para o problema de alocação e dimensionamento das unidades da GD nos sistemas de distribuição radial, as considerações realizadas para sua solução e o modelo de rede adotado. Este capítulo também expôs a abordagem para o problema, as quais serão apresentadas em detalhes no próximo capítulo.

4 Algoritmo Genético

4.1 Introdução

Este capítulo apresenta o algoritmo genético especializado (problema mestre) técnica empregada para solucionar a modelamento proposto. Também traz, o diferencial quando compara-se o AGE com o AG tradicional e descreve cada uma das etapas desenvolvidas para a implementação do AGE. Também expõem a metodologia empregada para a solução do fluxo de potência, problema escravo.

O AG foi proposto inicialmente por Holland (1975) na década de 70, como uma técnica que buscava através de mudanças nas configurações a melhor resposta, baseado em mecanismos da evolução e da genética. O AG é uma técnica meta-heurística para solução de problemas não lineares de altíssima complexidade matemática.

Os AG são classificados com técnicas evolutivas, as quais possuem com estrutura básica: reprodução, variações aleatórias na espécie, a competição e a seleção dos melhores indivíduos da população. Ao passo que processos computacionais ou naturais que apresentem as etapas citadas anteriormente são considerados evolutivos. O algoritmo genético (AG) é a mimetização do comportamento da evolução genética e seleção biológica dos indivíduos no formato de programação computacional. Onde o ambiente natural é simbolizado pelo problema de otimização e os indivíduos da população são as possíveis soluções do problema. Portanto, quanto mais adaptado ao ambiente o indivíduo estiver melhor será a solução (GOLDBERG, 1989).

O AG tem sido aplicado em várias áreas como: ciências naturais, engenharia, biologia, ciências da computação, dentre outras. Sua vantagem é possibilitar resolver problemas através da descrição matemática, assim não sendo necessário aplicar técnicas específicas, portanto, encontrando soluções para problemas de otimização complexos (GOLDBERG, 1989).

No AG o conjunto de configurações dos problemas combinatórios é representado por uma população formada por indivíduos, onde cada um dos indivíduos representa uma configuração. O AG, para qualquer problema, deve apresentar os seguintes procedimentos (RENDÓN, 1997):

1. A caracterização do problema deve ser feita de maneira adequada;
2. A função objetivo ou seu equivalente necessita ser avaliada de forma correta, função aptidão;
3. Elaborar um estratégia de seleção dos indivíduos, possibilitando sua participação na formação dos indivíduos da nova população;
4. O algoritmo precisa possuir um mecanismo que permita realizar a recombinação, um dos operadores genéticos;
5. Outro operador genético que deve ser implementado é a mutação. Era considerada como um operador secundário, porém, nos últimos anos demonstrou-se importante.
6. O número de indivíduos a ser considerado deve ser delimitado através da especificação do tamanho da população.

O algoritmo genético especializado (AGE) baseado nas ideias de Chu e Beasley (1997) apresenta algumas modificações em relação ao AG tradicional, como segue (GALLEGO et al., 2009):

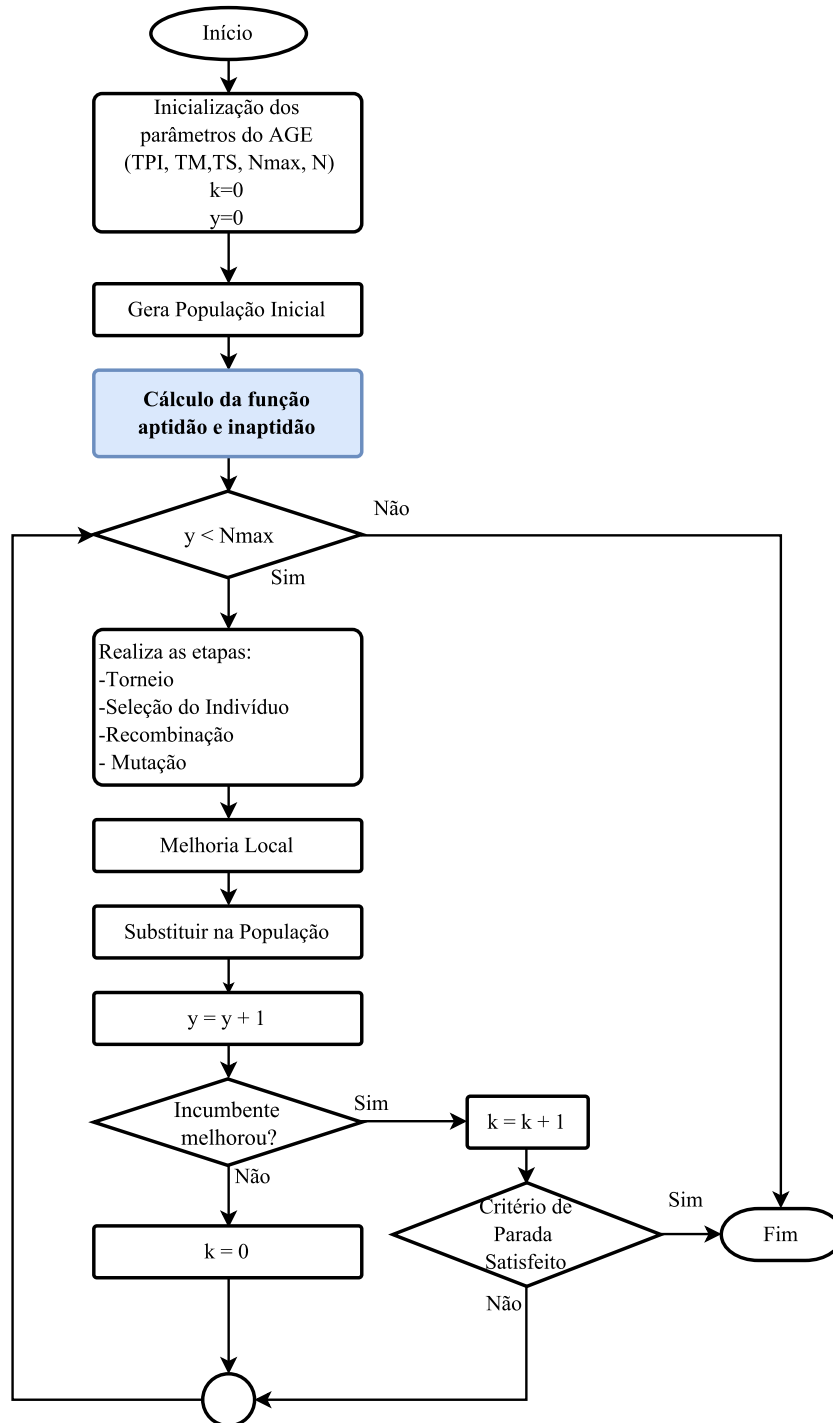
- no AGE é empregada uma função de aptidão e outra de inaptidão, onde são utilizadas para identificar o valor da função objetivo e quantificar a inviabilidade da solução testada. Já no AG tradicional a inaptidão não é tratada.
- a substituição não é mais geracional, enquanto no AG tradicional a população é totalmente ou parcialmente substituída, no AGE apenas um indivíduo na população em cada iteração é substituído.
- somente um indivíduo é gerado em cada iteração, que é modificado pelos operadores genéticos. Sendo este submetido a uma estratégia de melhoramento local.
- para que o indivíduo gerado nas etapas anteriores entre na população atual, deve ser diferente de todos os elementos da população atual e ser melhor que o pior indivíduo desta. Esta etapa é conhecida como substituição, a qual é muito importante, uma vez que, a cada iteração a população irá apresentar mais elementos factíveis e diferentes.

Neste trabalho é empregado o AGE para solucionar o problema de alocação e dimensionamento de GD.

No fluxograma, Figura 4.1, são apresentados os procedimentos. Uma breve descrição das etapas do AGE são: inicialização dos parâmetros de controle – tamanho da população inicial (TPI), taxa de mutação (TM), o número máximo de gerações a

serem empregadas no processo (N_{max}) e o critério de parada (N) –; implementação da codificação e criação da população inicial; execução da seleção para a escolha de apenas dois indivíduos geradores; efetua a recombinação e a manutenção de apenas um indivíduo; realiza a mutação do indivíduo preservado; implementa a fase de melhoria local; verifica se o descendente melhorado irá substituir um elemento da população atual; e avalia se o critério de parada foi atingido.

Figura 4.1: Fluxograma do AGE.



Fonte: Próprio autor(2017).

As etapas de geração da população inicial, torneio e seleção ocorrem da mesma forma para o problema que apenas aloca a GD quanto para o problema que aloca e dimensiona a GD.

Este fluxograma foi implantado para o modelamento. As etapas do fluxograma são descritas nas próximas seções:

4.2 Codificação

É uma das etapas mais importantes para a estrutura do AG, por ser responsável pela representação do indivíduo candidato a solução, assim influenciando na qualidade das soluções encontradas pelo AG (GOLDBERG, 1989).

Para o problema de alocação e dimensionamento da geração distribuída o indivíduo é representado por um vetor de tamanho igual ao número de barras do sistema, onde cada posição do vetor representa uma barra do sistema, assim todas as barras estão presentes no conjunto de possíveis locais para alocação das GDs. Cada vetor de codificação refere-se a uma configuração testada. A forma de representar a GD dentro destes vetores será exposto a seguir, considerando as diferentes configurações do problema: codificação para a solução dos problemas de apenas alocação da GD e de alocação e dimensionamento da GD são apresentadas.

4.2.1 Codificação considerando alocação da GD

Para o problema que considera apenas a alocação da geração distribuída, a codificação do indivíduo ocorre através do preenchimento do vetor de forma binária, onde o 1 representa o ponto de alocação e zero a ausência da GD. Este vetor é preenchido de forma aleatória respeitando o limite do número de GD a ser instalado no sistema. Na Figura 4.2 é possível observar a representação da codificação neste caso.

Figura 4.2: Exemplo da codificação de um indivíduo.

1	2	3		nb
0	1	0	...	0

Fonte: Próprio autor(2017).

4.2.2 Codificação considerando alocação e dimensionamento da GD

Para o problema de alocação e dimensionamento da geração distribuída a codificação do indivíduo ocorre através do preenchimento do vetor com valores inteiros,

onde zero representa a ausência da GD e os valores inteiros representam a potência a ser instalada. Este vetor é preenchido de forma aleatória respeitando o limite do número de GD a ser instalado no sistema. Na Figura 4.3 é possível observar a representação da codificação neste caso.

Figura 4.3: Exemplo da codificação de um indivíduo, para alocação e dimensionamento.

1	2	3	...	nb
0	5	0	...	3

Fonte: Próprio autor(2017).

Para encontrar o limite máximo para o valor inteiro, que representa a potência, emprega-se a equação 4.1.

$$Num_{passo}^{max} = \frac{\overline{P_i^{gd}} - \underline{P_i^{gd}}}{T_{passo}} + 1 \quad (4.1)$$

onde: Num_{passo}^{max} é o número máximo de inteiros que representam a potência; $\overline{P_i^{gd}}$ é o limite máximo de potência a ser despachada; $\underline{P_i^{gd}}$ é o limite mínimo de potência a ser despachada; T_{passo} é o tamanho do passo escolhido.

Quando os níveis de carga são considerados, o indivíduo é representado por um vetor, como descrito anteriormente, para cada nível de carga. Assim, sendo determinado o despacho para cada nível de carga.

4.3 Função Objetivo

A função objetivo (aptidão), equação 4.2, pode ser calculada facilmente, sendo o somatório dos custos de implementação, manutenção e de operação (perdas para cada nível de carga) após a instalação da GD em diferentes barras do sistema.

$$Min. f_o = k_c \cdot \sum_{i \in \Omega_b} n_i^{gd} \cdot (c_i * P_{i,d} + \sum_{d \in \Omega_d} r_k \cdot T_d \cdot P_{i,d}^{gd}) + \sum_{d \in \Omega_d} k_e^d \cdot T_d \cdot P_d^{perdas} \quad (4.2)$$

A função inaptidão, equação 4.3, utilizada no AGE, pode ser calculada penalizando a função objetivo quando alguma das restrições do problema não for respeitada.

$$f'_o = \tau \left(\sum_{d \in \Omega_d} \gamma_d T_d P_d^{perdas} + \gamma_d k_c \sum_{k \in \Omega_b} n_k^{dg} (c_i * P_{i,d} + r_k T P_k^{gd}) \right) \quad (4.3)$$

A função objetivo é empregada como critério de escolha na seleção e na substituição de um indivíduo na população quando todos os elementos da mesma são factíveis. A infactibilidade facilita a substituição, por gerar indivíduos ruins.

4.4 População Inicial

A população inicial é representada por uma matriz $TMI \times nb$.

Os indivíduos da população inicial podem ser gerados de forma aleatório, porém este formato funciona melhor para sistemas de pequeno porte. Para sistemas de grande porte torna-se necessário o emprego de técnicas analíticas ou heurísticas para melhorar a qualidade da população inicial, assim melhorando a performance da metodologia (GOLDBERG, 1989).

Para gerar uma população inicial de melhor qualidade é empregado o uso de índices de sensibilidade. Neste trabalho, testa-se três índices de sensibilidade para a geração da população inicial.

A população inicial gerada empregando o índice de sensibilidade é formada de $\overline{n^{gd}}$, número máximo de GDs a ser inserido no sistema, prioritários na lista de sensibilidade e é acrescentado uma GD aleatoriamente em cada indivíduo da população inicial para garantir a diversidade da população inicial.

A seguir serão apresentados os índices testados.

4.4.1 Índice de sensibilidade de perdas I

Descrito em Elgerd (1971), este índice avalia as perdas de potência ativa em relação a potência ativa demandada. Para o calculo deste índice emprega-se o modelamento da rede como o apresentado na Figura 3.2. O índice é descrito na equação 4.4.

$$ISP_{i,d}^1 = 2 \cdot \sum_{j \in \Omega_b} (\alpha_{i,j} \cdot P_j - \beta_{i,j} \cdot Q_j) \quad (4.4)$$

onde

$$\alpha_{i,j} = \frac{R_{ij,d}}{V_i \cdot V_j} \cdot \cos(\delta_i - \delta_j) \quad (4.5)$$

e

$$\beta_{i,j} = \frac{R_{ij,d}}{V_i \cdot V_j} \cdot \sen(\delta_i - \delta_j) \quad (4.6)$$

O valor de $R_{ij,d}$ provem da matriz impedância, de linha, do sistema.

O fator de sensibilidade de perdas é calculado para cada uma das barras do sistema, utilizando os valores obtidos do fluxo de potência do caso base. As barras são ordenadas de maneira decrescente de acordo com o valor do índice de sensibilidade, criando uma

lista de prioridade.

4.4.2 Índice de sensibilidade de perdas II

Este índice de sensibilidade, mais simplificado, é empregado na literatura para alocação de banco de capacitores, problema semelhante a alocação de GD diferenciando-se pelo tipo de potência injetada. Este índice foi descrito por El-Ela et al. (2016). Para o problema de alocação e dimensionamento da GD realiza-se a substituição da potência reativa pela ativa demandada, assim adequando o índice para o problema considerado neste trabalho. Também adota o modelamento da rede como o adotado neste trabalho.

$$ISP_{j,d}^2 = \frac{\partial P_{perdas}}{\partial P_{j,d}} = \frac{2 \cdot P_{j,d} \cdot R_j}{V_{j,d}} \quad (4.7)$$

A barra que apresentar o maior valor do índice de sensibilidade, para a Equação 4.7, é considerada candidata a alocação da GD e está barra estará no topo da lista de prioridade do índice de sensibilidade.

Para o cálculo deste índice não é necessário o emprego da matriz impedância do sistema sendo simples computacionalmente.

4.4.3 Índice de estabilidade da tensão

Este índice é empregado na literatura para indicar a alocação da GD, é descrito por Murty e Kumar (2015). Baseia-se na segunda lei de Kirchhoff, a forma de calcular-se este índice é descrito na equação 4.8.

$$IET_j = \frac{4 \cdot X_j}{V_{j,d}^2} \cdot \left(\frac{P_{j,d}^2}{Q_{j,d}} + Q_{j,d} \right) \quad (4.8)$$

Em condições normais de funcionamento, o valor de IET_j deve ser inferior a um. Se o valor de IET_j estiver mais próximo de zero, então o sistema será mais estável. A barra com o valor de IET_j mais alto será sensível, portanto é selecionada para a alocação da DG.

4.5 Seleção

A seleção é o operador genético que atua na escolha dos indivíduos da população atual que irão participar da geração do novo indivíduo.

O método adotado foi o torneio, onde são gerados dois grupos de possíveis pais, cada grupo será formado de k indivíduos escolhidos aleatoriamente dentro da população

atual. De cada grupo é escolhido o melhor indivíduo, o que possui a melhor função objetivo. No final do processo são encontrados dois indivíduos, nomeados de pais, que são empregados na etapa de recombinação (GALLEGO et al., 2009).

4.6 Recombinação

Os indivíduos escolhidos na etapa de seleção devem ser submetidos ao operador da recombinação. A recombinação se trata da troca de parcelas entre os dois indivíduos escolhidos na etapa de seleção, assim formando dois novos indivíduos.

Este processo garante a diversidade da população atual, uma vez que, combina indivíduos existentes e cria novos, os quais possivelmente não pertençam a população corrente.

A seguir será apresentado como ocorre a codificação para a solução do problema de apenas alocação da GD e de alocação e dimensionamento da GD.

O método de recombinação empregado é o corte em um único ponto, escolhido de forma aleatória. Este ponto será o mesmo para cada um dos vetores que representam o indivíduo em cada um dos níveis de carga. Ainda, pode-se notar que cada filho herda características da topologia de ambos os pais.

4.6.1 Recombinação considerando apenas alocação da GD

Na Figura 4.4 apresenta-se o processo de recombinação adotado considerando apenas a alocação da GD, onde ocorre a quebra em um único ponto. Como é possível notar a característica binária do indivíduo é mantida para ambos os filhos.

Figura 4.4: Exemplo da etapa de recombinação.

		Ponto de quebra					
		0	1	2	↓ 3	4	5
Pai 1		0	1	0	1	0	1
Pai 2		0	0	1	0	1	1
		0	1	2	3	4	5
Filho 1		0	1	0	0	1	1
Filho 2		0	0	1	1	0	1

Fonte: Próprio autor(2017).

4.6.2 Recombinação considerando alocação e dimensionamento da GD

Na Figura 4.5 é apresentado o procedimento adotado para a recombinação considerando a alocação e dimensionamento da GD, ocorrendo a quebra em um ponto único e os filhos gerados recebem características de ambos pais.

Figura 4.5: Exemplo da etapa de recombinação.

		Ponto de quebra					
		0	1	2	↓ 3	4	5
Pai 1		0	2	0	4	0	3
Pai 2		0	0	5	0	4	1
		0	1	2	3	4	5
Filho 1		0	2	0	0	4	1
Filho 2		0	0	5	4	0	3

Fonte: Próprio autor(2017).

Quando são considerados os níveis de carga, o processo que é apresentado na Figura 4.5 se repete para cada um dos vetores que representam o indivíduo em cada um dos níveis de carga, ressaltando que o ponto de quebra é o mesmo para cada um dos vetores do indivíduo.

Para ambos os processos no AGE proposto somente um dos filhos prosseguirá para a próxima etapa. O escolhido é o que possuir a função objetivo de melhor qualidade, o outro será eliminado. No AG tradicional existe a possibilidade de ambos os filhos entrarem na população.

4.7 Mutação

A mutação é importante, uma vez que realiza a manutenção da diversidade genética na população e permite que a estrutura do indivíduo seja modificada gerando novos elementos para a população. A mutação é de crucial importância para este algoritmo, por permitir que indivíduos com características inadequadas fossem adequados, mesmo que de forma aleatória.

A seguir será apresentado como ocorre a codificação para a solução do problema de apenas alocação da GD e de alocação e dimensionamento da GD.

4.7.1 Mutação considerando apenas alocação da GD

Este processo ocorre da seguinte forma: de acordo com a taxa de mutação são escolhidos pontos do indivíduo aleatoriamente, como é visto na Figura 4.6, para as modificações do seu estado.

Figura 4.6: Exemplo da etapa de mutação.

Melhor Filho	0	0	1	1	0	1
Mutante	0	1	1	1	0	1

Fonte: Próprio autor(2017).

Neste processo ocorre uma verificação se na posição selecionada encontra-se zero ou um efetuando uma mudança de estado. A posição é a mesma para todos os níveis de carga, sendo realizada a verificação para cada um dos níveis.

4.7.2 Mutação considerando alocação e dimensionamento da GD

Este procedimento ocorre da seguinte forma: de acordo com a taxa de mutação são escolhidos pontos do indivíduo aleatoriamente, como é visto na Figura 4.7, para as modificações do seu estado.

Figura 4.7: Exemplo da etapa de mutação.

Melhor Filho	5	2	1	3	0	0
Mutante	5	4	1	3	0	0

Fonte: Próprio autor(2017).

Nesta metodologia ocorre uma verificação se na posição selecionada o valor que se encontra alocado é diferente do valor aleatório selecionado. Se forem iguais realiza-se um novo sorteio para o valor a ser alocado na posição selecionada. Este processo é realizado para todos os níveis de carga, sendo mantido a mesma posição para todas as níveis de carga. É importante ressaltar que este procedimento permite variar a potência inserida na barra de forma aleatória, assim garantindo a diversidade.

4.8 Melhoria Local

A etapa de melhoria local é uma das principais contribuições do AGE, uma vez que, permite pequenas modificações no indivíduo, as quais podem ter um grande impacto na solução final. Neste trabalho esta etapa é dividida em três fases:

- eliminação das GDs alocadas em excesso no indivíduo;
- uma busca em vizinhança e;
- variação da potência injetada.

A última etapa é empregada apenas quando se considerada o dimensionamento da GD.

4.8.1 Eliminação

O indivíduo gerado nas etapas anteriores é avaliado quanto ao número de GDs alocados. Para isto é realizada uma verificação deste número, caso este infrinja o número máximo de GDs alocados, o excesso é eliminado. Esse processo é feito para todas as possibilidades de combinação de alocação das GDs, dentro do limite, e a formatação que possuir a melhor resposta para a função objetivo será utilizada.


4.8.2 Busca de vizinhança

Nesta etapa é empregada uma metodologia baseado na metaheurística de busca em vizinhança variável (VNS), proposto por Mladenović e Hansen (1997). Nesta metodologia o espaço de solução é explorado através de uma busca local, que realiza a troca das estruturas de vizinhança, permitindo encontrar soluções melhores do que a solução corrente.

Este processo consiste em uma busca nas barras vizinhas ao ponto de alocação da GD, com objetivo de melhorar a resposta a função objetivo, como pode ser visto na Figura 4.8. Sendo alcançado este objetivo o indivíduo é modificado, caso contrário a GD permanece na barra original.

Deve-se utilizar um raio de busca dentro da vizinhança, sendo que o raio de busca empregado foi fixado em três vizinhanças. Para que este processo ocorra de maneira mais eficiente é empregada uma variável auxiliar que indica se a melhoria do indivíduo ocorre quando a GD é deslocada à jusante ou à montante da barra original, assim realizando a busca apenas em um dos sentidos até atingir o limite do raio.

Como pode ser visto na Figura 4.8, quanto mais se distância da barra original maior se torna o espaço de busca, assim aumentando o tempo computacional desta etapa.

Figura 4.8: Exemplo da etapa de busca em vizinhança.

Fonte: Próprio autor(2017).

4.8.3 Ajuste da potência

Nesta fase inicialmente é realizada a ordenação das potências instaladas para cada um dos níveis de carga em cada uma das barras que foi alocada a GD. Com estes valores realiza-se o cálculo da função objetivo. Ocorrendo uma melhoria, esta modificação é mantida, porém se isso não ocorrer o indivíduo retornará a configuração da etapa anterior.

Em seguida é realizada uma varredura para cada nível de carga na potência instalada. Isto ocorre da seguinte forma: a potência de uma determinada barra em um determinado nível de carga irá variar de acordo com um raio de 5% do número máximos de passos da potência, sendo que na primeira vez que esta variação ocorre será realizado o acréscimo e o decréscimo de potência e a função objetivo será calculada para ambos os casos. Os resultados obtidos serão comparados ao valor original, o que apresentar a melhor resposta setará uma variável auxiliar, sendo 0 para o valor original, 1 para incremento e 2 para o decremento da potência a ser instalada. Quando o valor original for o melhor para todos os níveis de carga esta etapa termina. Porém, se isso não ocorrer o processo irá prosseguir até atingir o limite do raio, de forma a decrescer ou incrementar a potência de acordo com o setado na variável auxiliar.

4.9 Substituição

Após a etapa de melhoria local, o indivíduo gerado entra na população atual caso satisfaça as seguintes condições: não estar contido dentro na população atual e possuir

melhor função objetivo do que o pior indivíduo da população atual. Caso contrário, o indivíduo será descartado, assim mantendo a diversidade da população inicial.

4.10 Parâmetros de Controle

A definição dos parâmetros de controle, as escolhas da população inicial e do critério de parada adotado, por exemplo, determinam as características básicas do AGE, assim como a eficiência do mesmo. Na formulação do AGE, os parâmetros de controle são: o tamanho da população, a taxa de seleção e taxa de mutação. Logo, os parâmetros de controle em conjunto com o mecanismo de geração de população inicial e o critério de parada definem a qualidade do AGE.

Os valores típicos dos parâmetros de controle empregados na literatura especializada são: tamanho de população entre 30 e 300 e taxa de mutação entre 0,001 e 0,050 (RENDÓN, 1997).

4.11 Critério de Parada

Para o problema da alocação e dimensionamento da GD foram adotados dois critérios de parada como pode ser visto na Figura 4.1, sendo um para quando o algoritmo converge, ou seja, mantém o valor da melhor solução em um intervalo de N iterações, assim expondo o melhor indivíduo da população atual. Caso o algoritmo não convirja, isto é não atingir o critério de parada anterior, em um intervalo de N_{max} iterações, o programa irá parar, acionando o segundo critério de parada e a solução não terá sua qualidade garantida.

4.12 Cálculo do Fluxo de Potência

Para o cálculo do fluxo de potência em redes de transmissão existem várias metodologias. As mais aplicadas são Newton-Raphson e suas versões desacoplados. Porém, essas metodologias apresentam desempenho inadequado para redes de distribuição radiais. Esse comportamento ocorre devido as impedâncias de valores relativamente baixas associadas a impedâncias de valores relativamente altos e a baixa relação reatância por resistência dos parâmetros dos alimentadores, afetando a característica de convergência dos métodos, exigindo um grande número de iterações ou até mesmo causando a divergência no processo de resolução (SHIRMOHAMMADI et al., 1988).

A metodologia escolhida para ser utilizada neste trabalho foi o *Backward-Forward Sweep*, o qual consegue contornar os problemas citados anteriormente.

Algumas hipóteses são empregadas com o propósito de representar o funcionamento

no regime permanente do sistema de distribuição de energia elétrica, que são:

- a barra i está mais próxima da subestação que a barra j no ramo ij ;
- o sistema é representado pelo seu equivalente monofásico, uma vez que, são empregados sistemas trifásicos balanceados.

Esse método, foi proposto por (SHIRMOHAMMADI et al., 1988) para sistemas monofásicos e posteriormente adaptado para o uso em redes trifásicas (CHENG; SHIRMOHAMMADI, 1995). O algoritmo consiste em duas varreduras, denominadas *Backward sweep* e *Forward sweep*, sendo uma à montante e outra à jusante, respectivamente. Na varredura a montante ocorre o cálculo do valor da corrente nos ramos e na varredura a jusante é calculado o valor da tensão nas barras. A execução do algoritmo segue os passos a seguir:

1. Primeiro, é determinar o valor inicial das tensão para todas as barras, geralmente defini-se como sendo a mesma tensão da subestação.
2. O próximo passo é determinar os valores das correntes de carga nas barras através da equação 4.9

$$I_{ia}^{(k)} = \left(\frac{S_{ia}}{V_{ia}^{(k-1)}} \right)^* - Y_{ia}^* \cdot V_{ia}^{(k-1)}, \quad (4.9)$$

sendo I_{ia} a corrente injetada na barra i , S_{ia} a potência injetada na barra i , V_{ia} a tensão na barra i , Y_{ia}^* conjugado da admitância do elemento *shunt* conectados a barra i e k o número da iteração.

3. Em seguida, é iniciada a operação à montante (*Backward sweep*), onde, partindo dos ramos finais até a subestação, é calculada o valor da corrente nos ramos, através do somatório das correntes de carga, com a equação 4.10,

$$J_{la}^{(k)} = -I_{ia}^{(k)} + \sum_{m \in M} J_{ma}^{(k)} \quad (4.10)$$

onde J_{la} é o valor da corrente no ramo l e J_{ma} é a corrente no ramo m , sendo m o conjunto de ramos que encontram-se à jusante da barra i .

4. Após o cálculo dos valores das correntes dos ramos, é executada a operação à jusante (*Forward sweep*), onde, partindo da subestação e empregando o valor da corrente dos ramos, novos valores de tensão serão encontrados, utilizando a equação 4.11,

$$V_{ja}^{(k)} = V_{ia}^{(k)} - Z_{ij} \cdot J_{la}^{(k)}. \quad (4.11)$$

5. Esse processo irá se repetir até o critério de convergência seja satisfeito ou algum critério de parada seja atingido. O critério de convergência empregado é determinado a partir da variação do valor da potência nas barras (equação 4.12). Se a parte real (P) ou a parte imaginária (Q) de qualquer uma das variações de potência (ΔS_i) na equação 4.12 for maior que o fator de tolerância ϵ , os passos de 2, 3 e 4 são executados novamente, até que se obtenha a convergência ou que atinga um número máximo de iterações.

$$\Delta S_{ia}^{(k)} = V_{ia}^{(k)} \cdot (I_{ia}^*)^{(k)} - Y_{ia}^* (|V_{ia}|^2)^{(k)} - S_{ia} \quad (4.12)$$

A tolerância empregada no critério de convergência deve ter um valor predefinido, o utilizado neste trabalho foi de 10^{-6} , caso este valor não seja atingido dentro do número máximo de iterações, 50 iterações, é apresentado uma mensagem de erro, uma vez que o fluxo de potência não convergiu.

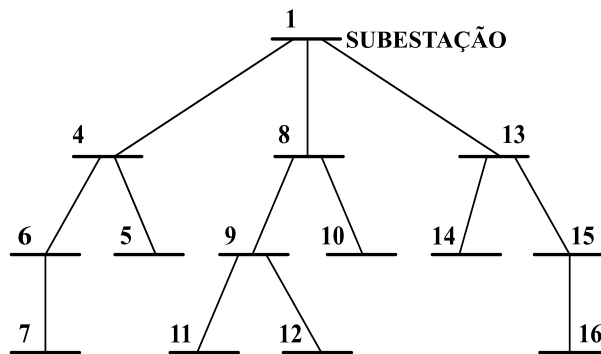
A estrutura final do algoritmo do cálculo do fluxo de potência, utilizado neste trabalho, possui os seguintes passos:

1. leitura dos dados de entrada do sistema;
2. realizar a ordenação dos ramos do sistema, com a finalidade de identificar o sentido dos fluxos de potência no sistema, para uma representação adequada do sistema, permitindo uma execução correta do algoritmo esta ordenação aplica a renumeração das barras;
3. calcular na seguinte ordem os valores: das correntes de carga, das correntes dos ramos (etapa *Backward sweep*) e das tensões (etapa *Forward sweep*), utilizando as equações dadas anteriormente;
4. verificação do critério de parada, se ainda não foi satisfeito voltar a passo 3, porém se já foi satisfeito parar.

No método anteriormente descrito, (Shirmohammadi et al. (1988)), como foi ressaltada na etapa 2 é necessário realizar a renumeração das barras e a ordenação dos ramos do sistema em forma de camadas, onde cada uma das barras da camada é renumerada antes de iniciar a renumeração da próxima camada como pode ser visto comparando a Figura 4.9 com a Figura 4.10. Como pode ser visto na Figura 4.10 a ordenação e renumeração das barras considera a subestação como ponto de início, portanto a primeira camada é formada das barras que se encontram a jusante da mesma. Para permitir o acesso de modo rápido as barras sem a necessidade da varredura da lista, é utilizada a estrutura do tipo *Hash Table* (CORMEN; AL., 2009), que permite buscar o endereço da barra, a partir do seu número, ou o endereço do ramo, de acordo com o dado de barra inicial e final.


O método *Hash Table* consiste em uma metodologia de busca em lista a qual não necessita realizar uma varredura da lista para se encontrar um determinado dado.

Figura 4.9: Sistema de 14 barras sem ordenação e renumeração das barras.



Fonte: Próprio autor (2017).

Figura 4.10: Sistema de 14 barras com ordenação e renumeração das barras.



Fonte: Próprio autor (2017).

4.13 Considerações Finais do Capítulo

No presente capítulo foram abordadas as principais características do AGE e sua diferenças em relação ao AG tradicional. Apresentou-se todas as etapas necessárias para o seu correto funcionamento, bem como a metodologia utilizada para o cálculo do fluxo de potência do sistema, processo que fornece parâmetros usados para solucionar o modelamento.

Com a abordagem para o programa descrita neste capítulo serão realizados testes para sistemas da literatura e sistemas reais, os quais podem ser encontrados no capítulo a seguir.

5 Resultados e Discussões

Este capítulo refere-se aos resultados e discussões decorrentes das simulações efetuadas empregando a metodologia proposta para alocação e dimensionamento da GD em sistemas de distribuição radiais. O método foi validado utilizando quatro sistemas de distribuição radiais difundidos na literatura especializada.

A função objetivo, utilizada nas simulações, verifica a minimização dos custos das perdas de potência ativa e os custos de implementação e manutenção da GD. Para tal, a metodologia proposta faz uso do algoritmo genético especializado para determinação da alocação e do dimensionamento do despacho de potência da GD. Além do fator econômico, os critérios técnicos, como perfil de tensão nas barras e as perdas de potência totais, também foram considerados para a avaliação da metodologia estudada. Esta foi implementada em C++ e as simulações foram feitas utilizando um computador com as seguintes características: processador *Intel® Core i5-3210M* de 2,5 GHz e 4 GB de RAM. As simulações foram realizadas empregando-se quatro sistemas de distribuição radial disponíveis na literatura. Os quatro sistemas utilizados serão descritos nesta seção como sistema de 70, 135, 400 e 1080 barras. Os resultados obtidos são apresentados no formato de gráficos e tabelas. Para o sistema de 70 barras encontram-se comparações entre os resultados obtidos pela metodologia proposta e outras publicações encontradas na literatura, assim validando a metodologia para os outros sistemas empregados.

Os custos de implementação e manutenção da GD são encontrados em Adefarati e Bansal (2016), sendo adotado com 30 US\$/kW e 0,045 US\$/MVAh, respectivamente, considerando a alocação de PCH, a qual apresenta os menores custos como visto no trabalho citado. O fator de recuperação da geração distribuída empregado foi um para todos os casos.

O algoritmo é executado por 100 vezes para cada um dos sistemas empregados. Assim, apresenta-se as configurações de alocação e dimensionamento da GD que ofereçam o melhor valor para a função objetivo. No Apêndice A, são fornecidos os parâmetro e a metologia empregada para adoção dos valores de população inicial (TPI), taxa de mutação (TM) para o AGE. O critério de parada é escolhido de maneira que apresente uma baixa taxa de dispersão das soluções obtidas, sendo exposto para cada um dos sistemas nas suas descrições.


Para escolha da metodologia adotada para a melhoria da geração da população inicial é empregada o teste descrito no Apêndice B. Como pode ser visto neste, o AGE empregando o índice de estabilidade de tensão (AGE-IET) apresentou os melhores resultados.

Os resultados serão apresentados para cada sistema a seguir.

5.1 Sistema 70 barras

Na Figura 5.1 apresenta-se o sistema de 70 barras (BARAN; WU, 1989). Este sistema de distribuição radial que emprega como tensão referência 12,66 kV, e uma subestação de capacidade de 10 MVA. Adotou-se o percentual do fator de multiplicação das cargas como: 100 % para o nível pesado; 80 % para o médio e 50 % para o leve. Foram adotados períodos de 1000 h, 6760 h e 1000 h para cada um dos níveis respectivamente, considerando a vida útil da GD como sendo de 20 anos. Os custos considerados para as perdas, para cada nível de carga, foram de 0,7 US\$/kWh para o nível pesado, 1,78 US\$/kWh para o nível médio e 2,95 US\$/kWh para o nível leve (HUANG; YANG; HUANG, 1996).

Figura 5.1: Diagrama sistema de 70 barras.



Fonte: Próprio autor (2017).

Com o propósito de validar o AGE proposto e avaliar o impacto da implementação de várias GDs foram realizados testes. Primeiramente, instalando GDs com a potência fixa em 1000 kW com fator de potência de 0,95, indutivo, e posteriormente realizou-se o dimensionamento da geração empregando fator de potência unitário.

5.1.1 Alocação de GD fixa

Na Tabela 5.1 é possível observar a comparação entre os custos, totais, perdas e implementação, entre as perdas de potência ativa e a amplitude mínima de tensão mínima para cada um dos níveis de carga.

Tabela 5.1: Solução para o sistema 70 barras considerando alocação de até três GDs, com potência fixa em 1000 kW e fator de potência 0,95 (indutivo).

Num. GDs	Custo Total (US\$)	Custo de Perdas (US\$)	Custo de Investimento (US\$)	Barra	Perdas(kW)			Tensão Mínima (pu)		
					Nível de Carga			Nível de Carga		
					1	2	3	1	2	3
Sem GD	39.625.968,00	39.625.968,00	-	-	225,02	138,91	51,61	0,909	0,929	0,956
1 GD	26.369.936,00	26.272.052,00	97.884,00	50	149,18	90,86	39,29	0,942	0,960	0,983
2 GD	26.453.028,00	13.034.361,00	195.768,00	7- 50	142,45	89,65	45,57	0,946	0,964	0,956
3 GD	26.557.666,00	26.264.014,00	293.652,00	7 -35 - 50	142,44	89,66	45,62	0,947	0,965	0,988

Fonte: Próprio autor (2017).

Na Tabela 5.2 é encontrado a comparação entre o somatório das perdas de potência ativa e o percentual de redução dos custos totais e da somatória das perdas, considerando os níveis de carga, para cada uma das possibilidades da alocação da GD.

Tabela 5.2: Somatório das perdas para cada caso e percentual de redução dos custos totais e das perdas.


Num GD	Perdas Totais (kW)	Redução (%)	
		Custos totais	Perdas de Potência Totais
Sem GD	415,54	-	-
1GD	279,33	33,10	32,77
2GD	277,67	32,48	33,17
3GD	277,72	31,92	33,16

Fonte: Próprio autor (2017).


Analisando os dados das Tabelas 5.1 e 5.2, é possível notar que a alocação da GD permitiu redução nos custos totais para todas as configurações, e a configuração que possibilitou a maior redução de custos para o sistema foi a alocação de uma GD.

Na Figura 5.2 é observado o perfil de tensão do sistema 70 barras, considerando os níveis de carga e a alocação de até três GDs.

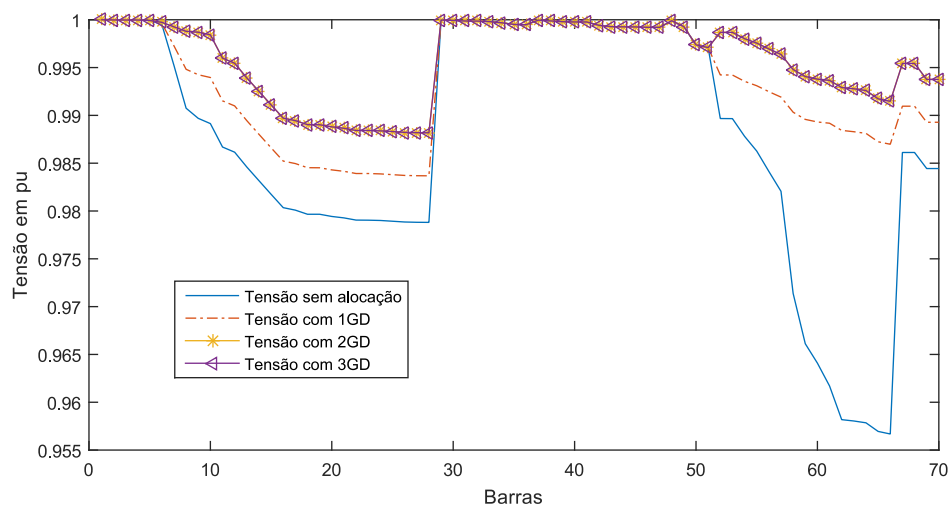
Figura 5.2: Magnitude de tensão do sistema de 70 barras para cada Nível de Demanda, com e sem GDs, considerando as possibilidades de alocação da GD.



(a) Nível de Demanda Pesada.



(b) Nível de Demanda Média.



(c) Nível de Demanda Leve.

Fonte: Próprio autor (2017).

Verificando os gráficos da Figura 5.2 nota-se que todas as configurações de alocação da GD permitem uma melhoria nos níveis de tensão, mesmo este não sendo o objetivo principal da alocação da GD.

Os parâmetros do AGE são escolhidos de acordo com a metodologia e os resultados apresentados no Apêndice A. A Tabela 5.4 expõem os valores considerados para os parâmetros utilizados no sistema 70 barras.

Tabela 5.3: Parâmetros iniciais empregados no AGE.

Característica	Valores utilizado
População Inicial	50 indivíduos
Taxa de Mutação	0,01
Taxa de Sorteio	3
Número Máximo de Gerações	10000

Fonte: Próprio autor (2017).

Na Tabela 5.4 é apresentado uma comparação entre os resultados obtidos pelo AGE e pelo AGE-IET, bem como uma comparação entre o número de FO calculadas, número de fluxos de potências calculados, o tempo e o número de iterações necessárias para convergir. Para realizar a implementação do AGE-IET são empregados os parâmetros da Tabela 5.3.

Tabela 5.4: Comparação de desempenho entre os AGE e o AGE-IET

Num GDs	AGE					AGE-IET			
	FO (US\$)	Nº de FO Calc.	Nº de Fluxos de Potência Calc.	Tempo (s)	Iterações	Nº de FO Calc.	Fluxos de Potência Calc.	Tempo (s)	Iterações
1 GD	26.369.936,00	6.708	20.124	1,44	700	3.295	9.885	0,86	200
2 GD	26.453.028,00	9.678	29.034	2,19	710	5.078	15.234	1,19	229
3 GD	26.557.666,00	13.357	40.071	3,08	794	4431	13.293	0,92	260

Fonte: Próprio autor (2017).

As soluções encontradas pelos algoritmos foram as mesmas. Por este motivo, essa é exposta apenas uma vez na Tabela 5.4.

Como é possível observar na Tabela 5.4 o emprego de um índice de sensibilidade permite encontrar a solução em tempos computacionais inferiores quando comparado ao AGE, assim reduzindo o número de iterações necessárias para o critério de parada.

Nota-se ainda na Tabela 5.4 que o número de GDs alocados não interfere no aumento da complexidade do problema quando é empregado o índice de sensibilidade na população inicial.

5.1.2 Alocação e dimensionamento de GD

Nessa sessão apresenta-se os resultados obtidos para alocação e dimensionamento da GD empregando fator de potência unitário.

Com a finalidade de comparar os resultados obtidos com os da literatura, para alocação e dimensionamento da GD, realizou-se a implementação do algoritmo para apenas um nível de carga, portanto o período é de 8760h. Para esta configuração o custo das perdas foi adotado com um valor de 0,06 US\$/kWh e os parâmetros do AGE foram mantidos, como visto na Tabela 5.3. Assim, foi permitido verificar a qualidade dos resultados obtidos e da eficiência da metodologia proposta.

Os resultados obtidos pelo AGE e AGE-IET, propostos, são comparados com (PISICA; BULAC; EREMI, 2009), que usa o AG tradicional, para determinar a melhor solução e compara com (DIAS et al., 2012) que usa o algoritmo OEP para determinar o despacho e a posição da GD. Os resultados obtidos pelas metodologias propostas foram os mesmos, por isso estes resultados aparecem apenas como metodologia proposta, na Tabela 5.5, que apresenta a comparação dos resultados obtidos com AG tradicional e o OEP.

Tabela 5.5: Comparação dos resultados da alocação e dimensionamento da GD, para o sistema 70 barras considerando apenas um nível de carga.

Num. GD	Proposto em:	Barra	Potência Despachada (kW)	Perdas de Potência Total (kW)	Magnitude da Tensão Mínima (pu)	Redução de Perdas(%)
Sem GD	Neste Trabalho ¹	-	-	225,02	0,909	-
	AG(PISICA; BULAC; EREMI, 2009)	-	-	225,00	0,909	-
	OEP(DIAS et al., 2012)	-	-	225,00	-	-
1 GD	Neste Trabalho ¹	50	1870,70	83,22	0,968	63,01
	AG(PISICA; BULAC; EREMI, 2009)	50	1500	88,21	-	60,80
	OEP(DIAS et al., 2012)	50	1872,7	83,22	-	63,01
2 GD	Neste Trabalho ¹	16	536,10	71,68	0,979	68,14
		50	1783,60			
	AG(PISICA; BULAC; EREMI, 2009)	50	886	83,91	-	62,70
		51	861			
	OEP(DIAS et al., 2012)	16	531,5	71,68	-	68,14
		50	1781,5			
3 GD	Neste Trabalho ¹	10	510,60	69,43	0,9788	69,14
		17	378,10			
		50	1723,30			
	AG(PISICA; BULAC; EREMI, 2009)	17	519	73,76	-	67,21
		50	809			
		51	737			
OEP(DIAS et al., 2012)	11	526,8	69,43	-	69,14	
	17	380,4				
	50	1719				

Fonte: Próprio autor (2017).

Analisando os dados da Tabela 5.5 é possível notar que o método proposto se

¹Expõem a solução obtida pelo AGE e pelo AGE-IET.

mostra competitivo em relação ao AG tradicional (PISICA; BULAC; EREMI, 2009) e OEP (DIAS et al., 2012), uma vez que apresentou resultados melhores que o AG tradicional e semelhantes aos obtidos por OEP, quando verifica-se o somatório das perdas de potência ativa totais e a percentagem de redução das perdas. Como as metaheurísticas encontram ótimos locais, que são soluções de boa qualidade, assim justificando os valores de despacho e as barras de alocação não idênticas, mesmo obtendo perdas totais iguais. Este processo fica evidente na alocação e dimensionamento de três GDs, o qual possui um espaço de busca maior que as possibilidades anteriores.

Outro ponto a se observar na Tabela 5.5 é o incremento da magnitude de tensão mínima, o qual se adequa aos valores exigidos pela norma.

Na Tabela 5.6 é apresentado uma comparação entre o desempenho do AGE, AGE-IET, OEP(DIAS et al., 2012) e o AG tradicional(PISICA; BULAC; EREMI, 2009), expondo o valor da função objetivo calculada, os tempos computacionais, o número de iterações e o número de FO calculadas.

Tabela 5.6: Tabela de comparação de desempenho das diferentes metodologias para o sistema 70 barras.

Num. GD	Método	FO	Tempo	Iterações	Num. de FO Calc.
Sem GD	-	2.365.403,00	-	-	-
1 GD	AGE	1.025.870,69	5,04	200	20176
	AGE-IET	1.025.870,69	0,49	55	5714
	OEP	1.038.857,13	-	-	-
	AG	1.058.663,50	262,12	-	-
2 GD	AGE	1.054.709,62	12,54	268	117491
	AGE-IET	1.054.709,62	9,88	82	22879
	OEP	1.256.224,00	-	-	-
	AG	1.335.099,00	864,83	-	-
3 GD	AGE	1.181.334,12	77,59	296	1709842
	AGE-IET	1.181.334,12	28,59	82	44231
	OEP	1.410.989,50	-	-	-
	AG	1.406.259,13	1543,36	-	-

Fonte: Próprio autor (2017).

Na Tabela 5.6 é apresentado apenas o número de FO calculadas, pois o número de fluxos de potências calculados será idêntico a este valor, uma vez que é considerado apenas um nível de carga.

A metodologia proposta demonstrou sua eficácia para solucionar o problema de alocação e dimensionamento da GD. A qualidade das soluções obtidas pelo AGE-IET é melhor que o AGE e que outras metodologias apresentadas na literatura como o AG tradicional (PISICA; BULAC; EREMI, 2009) e o OEP (DIAS et al., 2012).


Comparando os tempos obtidos pelo AGE-IET e o GA é possível observar uma redução de 99,81%, para uma GD, 98,85%, para duas GDs, e 98,14%, para três GDs, para cada uma das possibilidades de alocação e dimensionamento da GD. Sendo uma

redução significativa, assim evidenciando a eficácia da metodologia proposta.

Comparando os valores da função objetivo obtidos pela metodologia proposta nota-se que a alocação de uma GD obtém o menor valor. Quando se considera a redução de perdas de potência ativa é possível observar que alocação e dimensionamento de três GDs apresenta a maior redução.

A seguir é apresentado o gráfico, na Figura 5.3, que compara o nível de tensão para o sistema de distribuição de 70 barras, considerando o caso de nenhuma GD alocada e os casos considerados anteriormente.

Figura 5.3: Magnitude de tensão do sistema de 70 barras, antes e depois da alocação e dimensionamento das possibilidades de grupos da GD.



Fonte: Próprio autor (2017).

Na Figura 5.3 verifica-se que todas as possibilidades permitiram uma melhora nos níveis de tensão do sistema 70 barras, sendo a alocação de duas e três GDs que mais beneficiam o sistema.

Apesar da possibilidade de alocação de três GDs possuir a menor redução de custos, esta ainda permite a maior minimização de perdas de potência ativa e melhor incremento para os níveis de tensão como pode ser visto na Figura 5.3 e na Tabela 5.5.

Para o caso de alocação e dimensionamento da GD considerando os níveis de carga, exposto na seção de apenas alocação da GD para o sistema 70 barras, é apresentado na Tabela 5.7.

Tabela 5.7: Resultados para os testes de alocação e dimensionamento da GD, considerando os níveis de carga no sistema dos 70 barras.

Num. GDs	Custo Total (US\$)	Geração Distribuída (kW)				Perdas de Potência (kW)			Tensão Mínima (pu)		
		Barra	Nível de Carga			Nível de Carga			Nível de Carga		
			1	2	3	1	2	3	1	2	3
Sem GD	39.625.968,00	-	-	-	-	225,02	138,91	51,61	0,909	0,929	0,9567
1 GD	15.055.929,00	50	1881,70	1490,50	9235,40	83,23	52,74	20,30	0,968	0,975	0,984
2 GD	13.034.361,00	16	536,20	423,20	400,10	71,69	45,51	18,29	0,979	0,983	0,989
		50	1784,70	1421,40	854,50						
3 GD	12.596.229,00	10	432,30	401,20	242,20	69,58	44,11	17,05	0,979	0,983	0,989
		17	449,50	307,20	193,70						
		50	1726,400	1370,40	850,10						

Fonte: Próprio Autor (2017).

Os percentuais de redução das perdas são: 62,40%, 67,39% e 68,54%, seguindo a ordem da Tabela 5.7. Como é possível notar a alocação de três GDs apresenta a maior redução das perdas para o sistema de 70 barras e como pode ser observado na Tabela 5.7 possui o menor custo total, assim sendo a melhor possibilidade a ser alocada.

Na Tabela 5.8 é apresentada a análise de desempenho da metodologia para alocação e dimensionamento da GD considerando diferentes níveis de carga.

Tabela 5.8: Tabela de comparação do desempenho das metodologias propostas para o sistema 70 barras, considerando os níveis de carga.

Num. GD	Método	Tempo	Iterações	FO Calc.
1 GD	AGE	131,31	746	259.274
	AGE-IET	5,77	114	11.153
2 GD	AGE	163,991	1.169	1.122.627
	AGE-IET	8,09	119	39.335
3 GD	AGE	360,37	1.497	3.093.253
	AGE-IET	76,429	272	104.997

Fonte: Próprio autor (2017).

Como é possível notar o AGE-ITE reduz o custo computacional quando comparado ao AGE, não importando a complexidade do espaço de busca da solução.

5.1.3 Discussões

Como é possível notar nesta seção a metodologia proposta encontra soluções de boa qualidade quando compara-se com os resultados obtidos pelo AG tradicional(PISICA; BULAC; EREMI, 2009) e OEP(DIAS et al., 2012), para a alocação e dimensionamento da GD, no sistema 70 barras. Assim, permitindo validar a metodologia proposta.

Como a possibilidade de dimensionamento para apenas um nível de carga é utilizado para comparar os resultados da metodologia proposta com os descritos na literatura,


esta hipótese não é considerada para os casos a serem apresentados a seguir.

Não sendo possível encontrar resultados para sistemas de grande porte na literatura para validar os resultados encontrados pela metodologia proposta para os outros sistemas teste. Assim, considera-se que os resultados obtidos para o sistema de 70 barras validam a metodologia proposta.

5.2 Sistema 136 barras

O sistema 136 barras corresponde à parte do sistema de distribuição da concessionária de energia elétrica ELEKTRO, localizado na cidade de Três Lagoas – MS. Na Figura 5.4 apresenta-se o sistema de 136 barras. Este sistema de distribuição radial que emprega como tensão referência 13,8 kV, e uma subestação de capacidade de 10 MVA. O percentual do fator de multiplicação das cargas foram de: 150 % para o nível pesado; 100 % para o médio e 60 % para o leve. Foram adotados períodos de 1000 h, 6760 h e 1000 h para cada um dos níveis respectivamente. Para o custo das perdas foi adotado o valor de 0,06 US\$/kWh em todos os níveis de demanda (SOUSA, 2015). Também, supõem-se que a vida útil da GD é de 20 anos.

Figura 5.4: Diagrama sistema de 136 barras.



Fonte: (SILVA, 2015).

Com o propósito de validar a metodologia proposta e avaliar o impacto da implementação de até quatro GDs são realizados testes. Primeiramente, instalando GDs com

a potência fixa em 2000 kW com fator de potência de 0,95, indutivo, e posteriormente realizou-se o dimensionamento da geração empregando fator de potência unitário.

5.2.1 Alocação de GD fixa

Na Tabela 5.9 é possível observar a comparação entre os custos, perdas e implementação, valores de perdas de potência ativa e o valor da tensão mínima para cada um dos níveis de carga.

Tabela 5.9: Solução para o sistema 136 barras considerando alocação de até quatro GDs, com potência fixa em 2000 kW e fator de potência 0,95 (indutivo).

Num. GDs	Custo de Total (US\$)	Custo de Perdas (US\$)	Custo de Investimento (US\$)	Barra	Perdas(kW)			Tensão Mínima (pu)		
					Nível de Carga			Nível de Carga		
					1	2	3	1	2	3
Sem GD	3.637.089,50	3.637.089,50	-	-	753,52	320,36	111,72	0,890	0,931	0,959
1 GD	3.298.628,75	2.973.428,75	325.200,00	155	626,00	259,67	96,50	0,900	0,937	0,965
2 GD	3.372.674,25	2.722.274,25	650.400,00	12-155	575,64	236,54	96,50	0,900	0,937	0,965
3 GD	3.517.755,25	2.542.155,25	975.600,00	12-56-155	540,39	219,91	91,52	0,900	0,937	0,965
4 GD	3.680.343,00	2.379.543,00	1.300.800,00	12-35-56-155	504,09	205,03	92,87	0,900	0,937	0,965

Fonte: Próprio autor (2017).

Como é possível notar na Tabela 5.9, a alocação da GD permitiu a redução nas perdas para todos os níveis de carga, como também aumentou os valores de tensão mínima, porém este valor é o mesmo para todas as possibilidades de alocação da GD, uma vez que, a inserção da potência reativa é o principal responsável pela melhoria nos níveis de tensão, que não é o foco do trabalho.

Na Tabela 5.10 é encontrado a comparação entre a somatória das perdas de potência ativa e o percentual de redução dos custos totais e da somatória das perdas, considerando os níveis de carga, para cada uma das possibilidades da alocação da GD.


Analisando os dados da Tabela 5.10, é possível notar que a alocação da GD permitiu redução nos custos totais para todas as configurações, porém a alocação de 1 GD apresenta maior redução dos custos totais, 9,30%, por apresentar um menor custo

Tabela 5.10: Comparação do somatório das perdas de potência ativa totais e do percentual de redução dos custos totais e do somatório de perdas, para o sistema 136 barras considerando o número de GD a ser alocado.


Num GD	Perdas Totais (kW)	Redução (%)	
		Custos totais	Perdas de Potência Totais
Sem GD	1.185,6	-	-
1GD	982,17	9,30	17,15
2GD	908,68	7,27	23,35
3GD	851,82	3,28	28,15
4GD	801,99	-1,18	32,35

Fonte: Próprio autor (2017).


Figura 5.5: Magnitude de tensão do sistema de 136 barras para cada Nível de Demanda, com e sem GDs, considerando as possibilidades de alocação da GD.



(a) Nível de Demanda Pesada.



(b) Nível de Demanda Média.



(c) Nível de Demanda Leve.

Fonte: Próprio autor (2017).

de implementação como visto na Tabela 5.9. Contudo, a alocação de quatro GDs proporciona uma maior redução das perdas de potência ativa, 32,35%, porém apresenta um acréscimo nos custos totais de 1,18%, sendo inviável economicamente.

Na Figura 5.5 é possível observar o comportamento da tensão para cada barra do sistema, considerando cada um dos níveis de carga, comparando as influências das diferentes configurações de alocação da GD entre si e com estado inicial do sistema.

Verificando os gráficos da Figura 5.5 nota-se que todas as configurações de alocação da GD permitem uma melhora nos níveis de tensão, principalmente nas barras vizinhas a barra em que a GD foi alocada, mesmo este não sendo o objetivo principal da alocação da GD. Observa-se também que a alocação da GD permitiu uma melhoria nos níveis de tensão principalmente em torno das barras que apresentavam os menores valores.

Os parâmetros do AGE são escolhidos de acordo com a metodologia e os resultados apresentados no Apêndice A. A Tabela 5.11 expõem os valores considerados para os parâmetros utilizados no sistema 136 barras.

Tabela 5.11: Parâmetros iniciais empregados no AGE.

Característica	Valores utilizado
População Inicial	100 indivíduos
Taxa de Mutação	0,005
Taxa de Sorteio	3
Número Máximo de Gerações	10000

Fonte: Próprio autor (2017).

Na Tabela 5.12 é apresentada uma comparação entre os resultados obtidos pelo AGE e pelo AGE-IET, bem como uma comparação entre o número de FO calculadas, número de fluxos de potências calculados, o tempo e o número de iterações necessárias para convergir. Para realizar a implementação do AGE-IET são empregados os parâmetros da Tabela 5.11.

As soluções encontradas pelos algoritmos foram as mesmas por este motivo essa é exposta apenas uma vez na Tabela 5.12, assim demonstrando que ambas as metodologias convergem para mesma solução.

Como é possível observar na Tabela 5.12 o emprego de um índice de sensibilidade permite ter soluções com tempos computacionais menores, assim reduzindo o número de iterações necessárias para o critério de parada. O número de fluxos de potência calculados para AGE-IET é 48,09% menor que o valor encontrada para o AGE, para o caso da alocação de quatro GDs, o qual apresenta a maior complexidade computacional neste caso.

Nota-se ainda na Tabela 5.12 que o número de GDs alocados não interfere no aumento da complexidade do problema quando é empregado o índice de sensibilidade

Tabela 5.12: Comparação de desempenho entre os AGE e o AGE-IET

Num GDs	AGE					AGE-IET			
	FO (US\$)	Nº de FO Calc.	Nº de Fluxos de Potência Calc.	Tempo (s)	Iterações	Nº de FO Calc.	Nº de Fluxos de Potência Calc.	Tempo (s)	Iterações
1 GD	3.298.628,75	7.805	23.415	2,91	801	4.598	13.794	1,58	301
2 GD	3.372.674,25	11.357	34.071	4,23	821	7.345	22.035	2,72	311
3 GD	3.517.755,25	18.074	54.222	6,48	970	12.780	38.340	4,55	412
4 GD	3.680.343,00	27.148	81.444	849	1233	14.093	42.279	5,56	374

Fonte: Próprio autor (2017).

na população inicial.

5.2.2 Alocação e dimensionamento de GD

Nessa sessão serão apresentados resultados obtidos para alocação e dimensionamento de até quatro GDs empregando fator de potência unitário. Os níveis de carga considerados são os mesmos que foram empregados no caso anterior, os parâmetros do algoritmo genético são mantidos, Tabela 5.11, e o período considerado é de 20 anos.

Na Tabela ?? encontra-se a solução comparativa entre as configurações adotadas para alocação e dimensionamento.

A Tabela 5.13 demonstra que a alocação de duas GDs permite a maior redução de custos para o sistema 136 barras, sendo a melhor possibilidade.

Comparando os dados da Tabela 5.13 com o custo inicial do sistema foi verificado uma redução de 16,93%, 18,11%, 17,09% e 15,73, respectivamente. Nota-se que a melhor configuração será a alocação de duas GDs, uma vez que proporciona a maior redução dos custos totais.

Na Tabela 5.14 é possível observar a comparação do desempenho do AGE e do AGE-IET.

Tabela 5.13: Resultados para os testes de alocação e dimensionamento da GD, considerando os níveis de carga no sistema dos 136 barras.

Num. GDs	FO (US\$)	Geração Distribuída (kW)				Perdas de Potência (kW)			Tensão Mínima (pu)		
		Barra	Nível de Carga			Nível de Carga			Nível de Carga		
			1	2	3	1	2	3	1	2	3
Sem GD	3.637.089,50	-	-	-	-	753,52	320,36	111,72	0,890	0,930	0,959
1 GD	3.021.275,25	156	2199,90	2199,90	1633,90	573,907	232,647	81,136	0,923	0,959	0,979
2 GD	2.978.356,25	17	1372,00	1623,40	1623,40	521,50	201,01	71,15	0,923	0,959	0,979
		156	2199,90	2199,80	1500,10						
3 GD	3.015.541,75	17	2168,70	1766,90	1468,90	464,34	178,62	63,44	0,923	0,958	0,975
		39	1370,40	1309,60	633,80						
		156	2126,80	2126,80	1306,10						
4 GD	3.064.934,50	17	2.130,40	1.368,60	1.215,90	413,82	157,86	54,31	0,923	0,958	0,983
		39	1.677,00	1494,50	1296,10						
		62	1771,30	1511,40	946,30						
		156	2.151,0	2.137,30	2.026,10						

Fonte: Próprio Autor (2017).

Tabela 5.14: Tabela de comparação do desempenho das metodologias propostas para o sistema 136 barras, considerando os níveis de carga.

Num. GD	Método	Tempo	Iterações	FO Calc.
1 GD	AGE	47,06	1.509	101114
	AGE-IET	14,13	600	38.659
2 GD	AGE	101,89	1.792	171.717
	AGE-IET	11,79	368	34.201
3 GD	AGE	109,28	1.733	190.726
	AGE-IET	48,69	374	131.148
4 GD	AGE	77,59	1.745	1.709.842
	AGE-IET	50,70	360	132.871

Fonte: Próprio autor (2017).

Como é possível notar o AGE-IET reduz o custo computacional quando comparado ao AGE, não importando a complexidade do espaço de busca da solução.

5.3 Sistema 400 barras

Para o sistema 400 barras, correspondem ao sistema de distribuição da concessionária Caiuá Distribuição de Energia S/A, localizado na cidade de Indiana - SP, e emprega uma tensão referência de 11,4 kV. Adota-se o percentual do fator de multiplicação das cargas como: 150 % para o nível pesado e 100 % para o médio. Foram adotados períodos de 1000 h e 7760 h para cada um dos níveis, respectivamente. Para o custo das perdas foi adotado o valor de 0,06 US\$/kWh em todos os níveis de demanda (SOUSA, 2015). Também, supõem-se que a vida útil da GD é de 20 anos.

Com o propósito de validar o AGE proposto e avaliar o impacto da implementação da GD, foram realizados testes. Primeiramente, instalando GDs com a potência fixa em 1000 kW com fator de potência de 0,95, indutivo, e posteriormente realizou-se o dimensionamento da geração empregando fator de potência unitário.

5.3.1 Alocação de GD fixa

Na Tabela 5.15 é possível observar a comparação entre os custos de perdas e implementação, valores de perdas de potência ativa e reativa e o valor da tensão mínima para cada um dos níveis de carga.

Tabela 5.15: Solução para o sistema 400 barras considerando a alocação de GDs com despacho fixo em 1000 kW com fator de 0,95 (indutivo).

Num. GDs	Custo			Barra	Perdas(kW)		Tensão Mínima (pu)	
	Total	Perdas	Investimento		Nível de Carga		Nível de Carga	
	(US \$)	(US\$)	(US\$)		1	2	1	2
Sem GD	1.821.399,75	607.133,25	-	-	356,73	149,63	0,896	0,933
1 GD	593.606,00	356.006,03	237.600,00	307	228,52	85,24	0,928	0,963
2 GD	754.680,12	279.480,15	475.200,00	139- 307	174,17	67,59	0,941	0,975
3 GD	988.694,50	275.894,53	712.800,00	60- 146- 325	153,52	69,10	0,949	0,983
4 GD	1.234.746,75	284.346,75	950.400,00	8- 60- 144- 325	150,93	72,16	0,951	0,985

Fonte: Próprio autor (2017).

Analisando os dados da Tabela 5.15 é possível verificar que todas as configurações de alocação da GD permitem melhorias no sistema, assim reduzindo as perdas de potência, ativa, e melhorando os níveis de tensão do sistema, uma vez que, eleva o valor da tensão mínima. Também, é observado que a alocação de uma GD proporciona a maior redução dos custos totais para o sistema.

Na Tabela 5.16 é encontrado a comparação entre o somatório das perdas de potência ativa e o percentual de redução dos custos totais e da somatória das perdas, considerando os níveis de carga, para cada uma das possibilidades da alocação da GD.

Tabela 5.16: Comparação dos custos e perdas totais para o sistema 400 barras, com seus respectivos percentuais de redução.

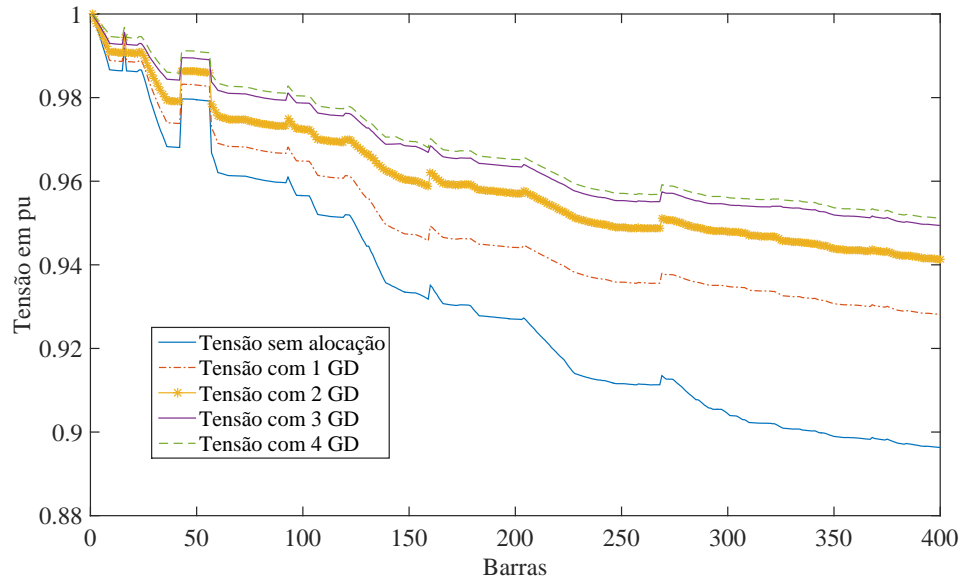
Num GD	Perdas Totais (kW)	Redução (%)	
		Custos totais	Perdas de Potência Totais
Sem GD	506,36	-	-
1GD	313,76	67,40	38,04
2GD	241,76	58,56	52,25
3GD	222,62	45,71	56,03
4GD	223,09	32,20	55,94

Fonte: Próprio autor (2017).

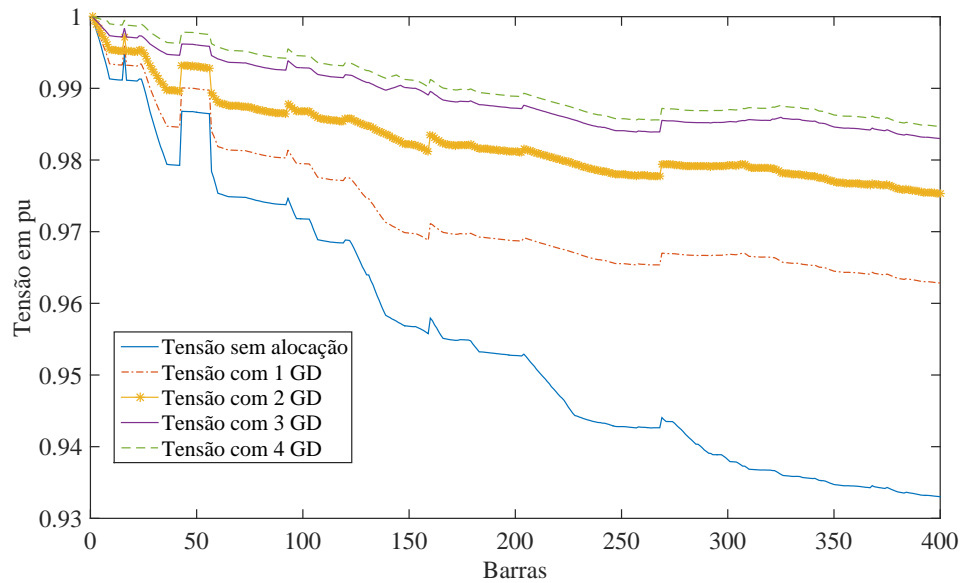
A opção viável economicamente será a alocação de uma GD, que permite uma redução de 67,41% dos custos totais para o sistema de distribuição de 400 barras.

Na Figura 5.6 é possível observar o comportamento da tensão para cada barra do sistema, considerando cada um dos níveis de carga, comparando as influências das diferentes configurações de alocação da GD entre si e com estado inicial do sistema.

Figura 5.6: Magnitude de tensão do sistema de 400 barras para cada Nível de Demanda, com e sem GDs, considerando as possibilidades de alocação da GD.



(a) Nível de Demanda Pesada.



(b) Nível de Demanda Média.

Fonte: Próprio autor (2017).

Verificando os gráficos da Figura 5.6 nota-se que todas as configurações de alocação da GD permitem uma melhoria nos níveis de tensão, mesmo este não sendo o objetivo principal da alocação da GD.

Realizando a averiguação do comportamento do algoritmo é possível obter os dados da Tabela 5.18. Os parâmetros do AGE, Tabela 5.17, foram escolhidos de acordo com a metodologia descrita no Anexo A.

Tabela 5.17: Parâmetros do AGE.

Característica	Valores utilizado
População Inicial	100 indivíduos
Taxa de Mutação	0,005
Taxa de Sorteio	3
Número Máximo de Gerações	10000

Fonte: Próprio autor (2017).

Na Tabela 5.18 é apresentado uma comparação entre os resultados obtidos pelo AGE e pelo AGE-IET, bem como uma comparação entre o número de FO calculadas, número de fluxos de potências calculados, o tempo e o número de iterações necessárias para convergir. Para realizar a implementação do AGE-IET são empregados os parâmetros da Tabela 5.17.

Tabela 5.18: Comparação de desempenho entre os AGE e do AGE-IET.

Num GD	AGE			AGE-IET		
	Iterações	FO Calc.	Tempo (s)	Iterações	FO Calc.	Tempo (s)
1GD	1.207	14.845	12,91	409	5.008	2,97
2GD	1.303	22.245	23,31	524	9.180	5,50
3GD	2.182	48.469	47,99	637	12.990	8,49

Fonte: Próprio autor (2017).

Como é possível observar na Tabela 5.18 a implementação de uma população inicial de melhor qualidade permite a redução dos tempos e esforços computacionais. Para o caso como maior espaço de busca, alocação de três GDs, ocorreu uma redução de 73,20% no número de fluxos de potência calculados, assim comprovando a redução da complexidade computacional.

Nota-se ainda na Tabela 5.18 que o número de GDs alocados não interfere no aumento da complexidade do problema quando é empregado o índice de sensibilidade na população inicial.

5.3.2 Alocação e dimensionamento de GD

Nessa sessão serão apresentados resultados obtidos para alocação e dimensionamento de múltiplas GDs empregando fator de potência unitário. Os níveis de carga considerados são os mesmos que foram empregados no caso anterior, os parâmetros do algoritmo genético são mantidos, Tabela 5.17, e o período considerado é de 20 anos.

Na Tabela 5.19 encontra-se o valor da FO para melhor solução, bem como a barra e o despacho de potência necessário para a cada uma dos valores das perdas e a magnitude da tensão mínima, para cada um dos níveis de carga.

Tabela 5.19: Resultados para os testes de alocação e dimensionamento da GD, considerando os níveis de carga no sistema dos 400barras.

Num. GDs	FO (US\$)	Geração Distribuída (kW)		Perdas de Potência (kW)		Tensão Mínima (pu)		
		Barra	Nível de Carga		Nível de Carga		Nível de Carga	
			1	2	1	2	1	2
Sem GD	607133,25	-	-	-	356,73	149,62	0,896	0,933
1 GD	347.364,27	280	1999,90	1896,00	127,01	46,57	0,9548	0,9828
2 GD	418.503,91	139	1999,90	1633,40	66,73	28,41	0,983	0,989
		326	1624,70	961,70				
3 GD	555.584,32	60	1450,00	984,90	57,16	25,17	0,985	0,990
		139	1676,80	1156,80				
		326	1471,90	954,90				

Fonte: Próprio Autor (2017)

A Tabela 5.19 demonstra que a alocação de duas GDs permite a maior redução dos custos totais para o sistema 400 barras, assim sendo a melhor configuração.

Na Tabela 5.20 encontra-se uma análise de desempenho do algoritmo para as possibilidades de alocação e dimensionamento da GD para o sistema 400 barras.

Tabela 5.20: Tabela de comparação do desempenho das metodologias propostas para o sistema 400 barras, considerando os níveis de carga.

Num. GD	Método	Tempo	Iterações	FO Calc.
1 GD	AGE	131,31	200	259.274
	AGE-IET	0,49	55	5714
2 GD	AGE	12,54	268	117491
	AGE-IET	9,88	82	22879
3 GD	AGE	77,59	296	1.709.842
	AGE-IET	28,59	82	44231

Fonte: Próprio autor (2017).

Como é possível notar o AGE-IET apresenta melhor desempenho computacional quando comparado ao AGE.

5.4 Sistema 1080 barras

Para o sistema 1080 barras, correspondem ao sistema de distribuição real, seus dados são encontrado na base de dados do LAPSEE. Os dados completos do sistema são encontrados em (LAPSEE, 2017), sendo que o percentual do fator de multiplicação das cargas são de: 150 % para o nível pesado e 100 % para o médio. Foram adotados períodos de 1000 h e 7760 h para cada um dos níveis respectivamente. O custo das perdas como sendo para cada nível de carga é de 1,78 US\$/kWh para o nível pesado, 2,95 US\$/kWh para o nível médio. Também, supõem-se que a vida útil da GD é de 20 anos.

Com o propósito de validar a metodologia proposto e avaliar o impacto da implementação de até três GDs, são realizados testes. Primeiramente, instalando GDs com a potência fixa em 180,0 kW com fator de potência de 0,95, indutivo, e posteriormente realizou-se o dimensionamento da geração empregando fator de potência unitário.

5.4.1 Alocação de GD fixa

Na Tabela 5.21 é possível observar a comparação entre os custos, perdas e implementação, valores de perdas de potência ativa e reativa e o valor da tensão mínima para cada um dos níveis de carga.

Tabela 5.21: Solução para o sistema 1080 barras considerando alocação de até três GDs, com potência fixa em 180,0 kW com fator de potência 0,95 (indutivo).

Num. GDs	Custo			Barra	Perdas(kW)		Tensão Mínima (pu)	
	Total	Perdas	Investimento		Nível de Carga		Nível de Carga	
	(US \$)	(US\$)	(US\$)		1	2	1	2
Sem GD	9.864.013,00	9.864.013,00	-	-	41,95	18,28	0,964	0,976
1 GD	7.927.090,50	7.761.322,50	165.768,00	736	35,09	14,22	0,965	0,977
2 GD	6.659.322,50	6.327.786,50	331.536,00	517- 721	29,94	11,492	0,968	0,980
3 GD	5.838.404,50	5.356.004,50	482.400,00	467- 624- 691	25,78	9,69	0,971	0,983

Fonte: Próprio autor (2017).

Como é possível notar na Tabela 5.21, a alocação da GD permitiu a redução nas perdas para todos os níveis de carga, como também aumentou os valores de tensão mínima. Na Tabela 5.22 é encontrado a comparação entre a somatória das perdas de potência ativa e o percentual de redução dos custos totais e da somatória das perdas, considerando os níveis de carga, para cada uma das possibilidades da alocação da GD.


Tabela 5.22: Comparação do somatório das perdas de potência ativa totais e do percentual de redução dos custos totais e do somatório de perdas, para o sistema 1080 barras considerando o número de GD a ser alocado.

Num GD	Perdas Totais (kW)	Redução (%)	
		Custos totais	Perdas de Potência Totais
Sem GD	60,23	-	-
1GD	48,32	19,63	18,11
2GD	41,47	32,48	31,15
3GD	35,47	40,81	41,11


Fonte: Próprio autor (2017).

Na Figura 5.7 é possível observar o comportamento da tensão para cada barra do sistema, considerando cada um dos níveis de carga, comparando as influências das diferentes configurações de alocação da GD entre si e com estado inicial do sistema.

Figura 5.7: Magnitude de tensão do sistema de 1080 barras para cada Nível de Demanda, com e sem GDs, considerando as possibilidades de alocação da GD.



(a) Nível de Demanda Pesada.



(b) Nível de Demanda Média.

Fonte: Próprio autor (2017).

Verificando os gráficos da Figura 5.7 nota-se que todas as configurações de alocação da GD permitem uma melhora nos níveis de tensão, mesmo este não sendo o objetivo principal da alocação da GD.

Analisando os dados das Tabelas 5.21 e 5.22, é possível notar que a alocação da GD permitiu a redução nos custos totais para todas as configurações, porém a configuração com a alocação de três GDs apresentou a maior redução dos custos totais, 40,81%

Os parâmetros do AGE são escolhidos de acordo com a metodologia e os resultados apresentados no Apêndice A. A Tabela 5.24 expõem os valores considerados para os parâmetros utilizados no sistema 1080 barras.

Tabela 5.23: Parâmetros iniciais empregados no AGE.

Característica	Valores utilizado
População Inicial	600 indivíduos
Taxa de Mutação	0,004
Taxa de Sorteio	3

Fonte: Próprio autor (2017).

Na Tabela 5.24 é apresentado uma comparação entre os resultados obtidos pelo AGE e pelo AGE-IET, bem como uma comparação entre o número de FO calculadas, número de fluxos de potências calculados, o tempo e o número de iterações necessárias para convergir. Para realizar a implementação do AGE-IET são empregados os parâmetros da Tabela 5.23.

Tabela 5.24: Comparação de desempenho entre os AGE e o AGE-IET

Num GDs	AGE					AGE-IET			
	FO (US\$)	Nº de FO Calc.	Nº de Fluxos de Potência Calc.	Tempo (s)	Iterações	Nº de FO Calc.	Fluxos de Potência Calc.	Tempo (s)	Iterações
1 GD	7.927.090,50	33.362	66.724	47,70	1.090	11.318	22.635	15,90	737
2 GD	6.659.322,50	79.779	159.557	109,19	1.597	24.195	48.390	37,25	1.167
3 GD	5.838.404,50	95.367	190.733	118,66	1.391	32.556	65.111	50,94	1.260

Fonte: Próprio autor (2017).

As soluções encontradas pelos algoritmos foram as mesmas por este motivo essa é exposta apenas uma vez na Tabela 5.24, assim demonstrando que ambas metodologias converge para mesma solução.

Como é possível observar na Tabela 5.24 empregando um índice de sensibilidade permite ter soluções com tempos computacionais inferiores, assim reduzindo o número de iterações necessárias para o critério de parada.

Nota-se ainda na Tabela 5.24 que o número de GDs alocados não interfere no aumento da complexidade do problema quando é empregado o índice de sensibilidade na população inicial.

5.4.2 Alocação e dimensionamento de GD

Nessa sessão serão apresentados resultados obtidos para alocação e dimensionamento de múltiplas GDs empregando fator de potência unitário. Os níveis de carga considerados são os mesmos que foram empregados no caso anterior, os parâmetros do algoritmo genético são mantidos, Tabela 5.23, e o período considerado é de 20 anos.

Na Tabela 5.25 encontra-se o valor da FO para melhor solução, bem como a barra e o despacho de potência necessário para a cada uma vos valores das perdas e a magnitude da tensão mínima, para cada um dos níveis de carga.

Tabela 5.25: Resultados para os testes de alocação e dimensionamento da GD, considerando os níveis de carga no sistema dos 1080barras.

Num. GDs	FO (US\$)	Geração Distribuída (kW)			Perdas de Potência (kW)		Magnitude de Tensão Min. (pu)	
		Barra	Nível de Carga		Nível de Carga		Nível de Carga	
			1	2	1	2	1	2
Sem GD	9.864.013,00	-	-	-	41,95	18,28	0,964	0,976
1 GD	4.911.048,00	615	599,00	599,00	22,531	8,53	0,968	0,980
2 GD	3.185.952,75	366	596,00	359,00	12,63	5,09	0,983	0,990
		679	599,00	536,00				
3 GD	2.924.357,50	199	575,00	575,00	10,72	4,27	0,982	0,989
		506	413,00	200,00				
		634	568,00	489,00				
4 GD	2.861.475,50	62	597,20	364,40	9,01	3,98	0,985	0,990
		318	391,70	271,30				
		517	364,40	233,50				
		607	534,10	366,70				

Fonte: Próprio Autor (2017)

A Tabela 5.25 demonstra que a alocação de quatro GDs permite a maior redução de perdas para o sistema 1080 barras e ainda apresenta o menor custo total apresentando uma redução de 70,99% dos custos originais para o sistema, assim sendo a melhor configuração.

Na Tabela 5.26 encontra-se uma análise de desempenho do algoritmo para as possibilidades de alocação e dimensionamento da GD para o sistema 1080 barras.

Tabela 5.26: Tabela de comparação do desempenho das metodologias propostas para o sistema 1080 barras, considerando os níveis de carga.

Num. GD	Método	Tempo	Iterações	FO Calc.
1 GD	AGE	679,07	1871	520.422
	AGE-IET	12,13	482	15.284
2 GD	AGE	708,22	1215	399.726
	AGE-IET	83,05	483	53.353
3 GD	AGE	1.264,68	2.062	913.987
	AGE-IET	82,77	394	73.444
2 GD	AGE	708,22	1215	399.726
	AGE-IET	83,05	483	53.353
4 GD	AGE	1.746,65	2.493	936.086
	AGE-IET	109,54	513	135.484

Fonte: Próprio autor (2017).

Nota-se na Tabela 5.26 que para sistema de grande porte o AGE-IET necessita de menor esforço computacional, assim salientando a importância do uso do índice de sensibilidade na população inicial.

5.5 Discussões e Considerações finais

Como foi possível observar neste capítulo a alocação das GDs, reduz as perdas e melhora o perfil de tensão dos sistemas. Porém, quando se aloca e dimensiona a GD estes benefícios são potencializados. Nota-se que o elevado custo de implementação e manutenção não permite a alocação de um grande número de GD, mesmo isto melhorando as características do sistema, perfil de tensão e valores de perdas.

A qualidade da solução encontrada pela metodologia proposta é validada quando compara-se os resultados obtidos para sistema 70 barras com os resultados encontrados na literatura, devido a ausência de resultado para sistemas de grande porte na literatura especializada. O algoritmo genético empregando metodologia analítica para geração da população inicial, AGE-IET, reduziu significativamente a complexidade computacional quando comparado com o AGE permitindo encontrar soluções de boa qualidade.

A seguir são apresentados as conclusões finais sobre o trabalho.

6 Conclusão

Neste trabalho foi apresentada uma metodologia de solução e um modelo matemático para a alocação e dimensionamento da geração distribuída em sistemas de distribuição radiais equilibrados, considerando diferentes nível de carga, sendo modelado como um problema não linear inteiro misto. A metodologia empregada neste trabalho utiliza um algoritmo genético especializado, o qual encontra soluções de altíssima qualidade. Verifica-se que o número de gerações alocada varia de acordo com a demanda do sistema, sendo independente do tamanho do sistema considerado e que, quando o despacho de potência fornecido pela GD é dimensionado de maneira correta, ocorre uma maior redução das perdas de potência do sistema.

Pode-se afirmar que a boa convergência do algoritmo genético especializado se deve a etapa de melhoria local, uma vez que permite encontrar rapidamente soluções de altíssima qualidade através da busca em vizinhança e da varredura de potência a ser instalada, para o caso do dimensionamento.

Quantos aos resultados, é notável como a alocação da GD impacta positivamente os sistemas, reduzindo as perdas de potência ativa. Outro benefício a ser considerado é a melhoria nos níveis de tensão nas barras do sistema, que ocorre principalmente quando o despacho de potência da GD é dimensionado de maneira correta, aumentando assim a confiabilidade do sistema. Nota-se também que a alocação da GD privilegia as barras em seu entorno, visto que as barras na vizinhança da barra onde é alocada a GD tem seus níveis de tensão melhorados, enquanto que barras muito distantes podem não sofrer nenhum tipo de impacto, uma vez que a potência injetada pela GD não seja o suficiente para melhorar os níveis de tensão do sistema todo.

Quanto à redução dos custos, verificou-se uma minimização mais significativa quando o despacho de potência é ótimo, porém o custo de instalação é muito elevado, sendo necessário considerar longos períodos para que o retorno econômico seja notável.

Um diferencial a ser destacado da metodologia empregada é não necessitar de *solvers* comerciais ou do fluxo de potência ótimo para dimensionar o despacho de potência ótimo para a GD, sendo estas as formas mais utilizadas na literatura. Para solucionar este problema a potência a ser despachada foi discretizada e se torna mais um parâmetro do modelamento. Esta metodologia se apresentou eficiente quando comparada com os

resultados encontrados na literatura.

A implementação de uma metodologia analítica para a geração da população inicial utilizada pelo AGE permitiu uma redução significativa nos tempos computacionais.

Concluindo o trabalho, a combinação do modelo matemático utilizado com a técnica meta-heurística, possibilitou encontrar soluções de altíssima qualidade, que possuem desempenho computacional bom para sistemas de médio e grande portes. Ao analisar este trabalho do ponto de vista comercial-financeiro, o algoritmo proposto mostrou-se eficaz na minimização das perdas de potência para os sistemas apresentados.

6.1 **Trabalhos Futuros**

- Introduzir uma maior discretização para os níveis de carga do sistema;
- Considerar os fatores geográficos e climáticos para a implementação da GD de fontes renováveis;
- Comparar diferentes índices de sensibilidade para o melhoramento da população inicial;
- Implementar uma busca capaz de determinar o fator de potência para a GD.
- Considerar sistemas de distribuição malhados.
- Avaliar o melhor funcionamento da GD, quando ocorre uma falha na rede, assim direcionando o fluxo de potência evitando o ilhamento.

Referências

ABU-MOUTI, F. S.; EL-HAWARY, M. E. A new and fast power flow solution algorithm for radial distribution feeders including distributed generations. *Conference Proceedings - IEEE International Conference on Systems, Man and Cybernetics*, p. 2668–2673, 2007. ISSN 1062922X.

ABU-MOUTI, F. S.; EL-HAWARY, M. E. Optimal DG placement for minimizing power loss in distribution feeder systems using sensory-deprived optimization algorithm. *Canadian Conference on Electrical and Computer Engineering*, p. 000205–000209, 2011. ISSN 08407789.

ACHARYA, N.; MAHAT, P.; MITHULANANTHAN, N. An analytical approach for DG allocation in primary distribution network. *International Journal of Electrical Power and Energy Systems*, v. 28, n. 10, p. 669–678, 2006.

ACKERMANN, T.; ANDERSSON, G.; SÖDER, L. Distributed generation: A definition. *Electric Power Systems Research*, v. 57, n. 3, p. 195–204, 2001. ISSN 03787796.

ADEFARATI, T.; BANSAL, R. Integration of renewable distributed generators into the distribution system: a review. *IET Renewable Power Generation*, v. 10, n. 7, p. 873–884, aug 2016. ISSN 1752-1416.

ALINEJAD-BEROMI, Y.; SEDIGHIZADEH, M.; BAYAT, M. R.; KHODAYAR, M. E. Using genetic algorithm for Distributed generation allocation to reduce losses and improve voltage profile. *Proceedings of the Universities Power Engineering Conference*, p. 954–959, 2008.

ANEEL. *Decreto nº 5163*. 2004. Disponível em: http://www.planalto.gov.br/ccivil/_03/_ato2004-2006/2004/decreto/d5163.HTM).

ANEEL. *Atlas de energia elétrica do Brasil, 2ª ed.* Brasil, 2005. Disponível em: <http://www2.aneel.gov.br/aplicacoes/atlas/download.htm>. Acesso em 09/05/2016.

ANEEL. *Resolução normativa ANEEL nº 235*. 2006. Disponível em: <http://www2.aneel.gov.br/cedoc/ren2006235.pdf>).

ANEEL. *Resolução Normativa ANEEL nº 482*. 2012. Disponível em: <http://www2.aneel.gov.br/cedoc/ren2012482.pdf>).

ANEEL. *Resolução Normativa ANEEL 687*. 2015. Disponível em: <http://www2.aneel.gov.br/cedoc/ren2015687.pdf>).

ANEEL. *BIG - Banco de Informações de Geração*. 2017. Disponível em: <http://www2.aneel.gov.br/aplicacoes/capacidadebrasil/capacidadebrasil.cfm>).

BANERJEE, B.; ISLAM, S. M. Reliability based optimum location of distributed generation. *International Journal of Electrical Power and Energy Systems*, Elsevier Ltd, v. 33, n. 8, p. 1470–1478, 2011. ISSN 01420615.

BARAN, M.; WU, F. Optimal capacitor placement on radial distribution systems. *IEEE Transactions on Power Delivery*, v. 4, n. 1, p. 725–734, 1989.

- BOHRE, A. K.; AGNIHOTRI, G.; DUBEY, M. Optimal sizing and siting of DG with load models using soft computing techniques in practical distribution system. *IET Generation, Transmission & Distribution*, v. 10, n. 11, p. 2606–2621, aug 2016. ISSN 1751-8687.
- CALLÉ, F. R.; ROTHMAN, S. V. B. and= H. *Uso da biomassa para a produção de energia na indústria brasileira*. 1. ed. Campinas, Brasil: UNICAMP, 2005.
- CAMARGO, V.; LAVORATO, M.; ROMERO, R. Specialized genetic algorithm to solve the electrical distribution system expansion planning. *2013 IEEE Power Energy Society General Meeting*, p. 1–5, July 2013. ISSN 1932-5517.
- CELLI, G.; GHIANI, E.; MOCCI, S.; PILO, F. A multiobjective evolutionary algorithm for the sizing and siting of distributed generation. *IEEE Transactions on Power Systems*, v. 20, n. 2, p. 750–757, 2005. ISSN 08858950.
- CHENG, C. S.; SHIRMOHAMMADI, D. A three-phase power flow method for real-time distribution system analysis. *IEEE Transactions on Power Systems*, v. 10, May 1995.
- CHIRADEJA, P.; RAMAKUMAR, R. An approach to quantify the technical benefits of distributed generation. *IEEE Transactions on Energy Conversion*, v. 19, n. 4, p. 764–773, 2004. ISSN 08858969.
- CHU, P. C.; BEASLEY, J. E. A genetic algorithm for the generalised assignment problem. *Journal of the Operational Research Society*, v. 48, n. 8, p. 804–809, 1997. ISSN 0160-5682.
- COELHO, F. C. R. *Alocação de geração distribuída em sistemas de distribuição de energia elétrica via otimização bioinspirada na ecolocalização de morcegos*. Tese (Mestrado) — Universidade Federal de Juiz de Fora, 2013.
- CORMEN, T. H.; AL. et. *Introduction to algorithms*. 3. ed. Cambridge, Massachusetts: The MIT Press, 2009.
- DAHAL, S.; SALEHFAR, H. Impact of distributed generators in the power loss and voltage profile of three phase unbalanced distribution network. *International Journal of Electrical Power & Energy Systems*, v. 77, p. 256–262, may 2016. ISSN 01420615.
- DENIS, I. F. *Métodos de Alocação de Perdas em Sistemas de Distribuição com Geradores Distribuídos*. 102 p. Tese (Doutorado) — UNIVERSIDADE ESTADUAL PAULISTA JÚLIO DE MESQUITA FILHO, 2003.
- DEVI, S.; GEETHANJALI, M. Application of Modified Bacterial Foraging Optimization algorithm for optimal placement and sizing of Distributed Generation. *Expert Systems with Applications*, Elsevier Ltd, v. 41, n. 6, p. 2772–2781, 2014. ISSN 09574174.
- DIAS, B. H.; OLIVEIRA, L. W.; GOMES, F. V.; SILVA, I. C.; OLIVEIRA, E. J. Hybrid heuristic optimization approach for optimal Distributed Generation placement and sizing. *2012 IEEE Power and Energy Society General Meeting*, p. 1–6, 2012.
- EL-ELA, A. A. A.; MOUWAFI, M. T.; KINAWY, A.-M.; EL-SEHIEMY, R. A. Optimal capacitor placement in distribution systems for power loss reduction and voltage profile improvement. *IET Generation, Transmission & Distribution*, v. 10, n. 5, p. 1209–1221, 2016. ISSN 1751-8687.
- EL-KHATTAM, W.; HEGAZY, Y.; SALAMA, M. An Integrated Distributed Generation Optimization Model for Distribution System Planning. *IEEE Transactions on Power Systems*, v. 20, n. 2, p. 1158–1165, may 2005. ISSN 0885-8950.

- EL-SAADANY, Y. M. A. E. F. Probabilistic approach for optimal allocation of wind- based distributed generation in distribution systems. *IET Renewable Power Generation*, n. February 2009, p. 79–88, 2010.
- ELGERD, O. I. *Electric Energy Systems Theory: An Introduction*. [S.l.]: McGraw-Hil, 1971. 564 p.
- EÓLICA, A. B. de E. *Dados Mensais*. 2017. Disponível em: <http://www.abeeolica.org.br/wp-content/uploads/2017/05/Dados-Mensais-ABEEolica-05.2017.pdf>.
- EPE. *Balanço Energético Nacional*. Brasil, 2015. Disponível em: https://ben.epe.gov.br/downloads/Relatorio_Final_BEN_2015.pdf. Acesso em 09/06/2016.
- GALLEGO, L. A.; RIDER, M. J.; ROMERO, R.; GARCIA, A. V. A Specialized Genetic Algorithm to Solve the Short Term Transmission Network Expansion Planning. In: *2009 IEEE Bucharest PowerTech*. [S.l.: s.n.], 2009. p. 1–7. ISBN 9781424422357.
- GARCES, L.; ROMERO, R. Specialized Genetic Algorithm for Transmission Network Expansion Planning Considering Reliability. *Intelligent System Applications to Power Systems, 2009. ISAP '09. 15th International Conference on*, p. 1–6, 2009.
- GEORGILAKIS, P. S.; MEMBER, S.; HATZIARGYRIOU, N. D. in Power Distribution Networks : Models , Methods , and Future Research. *IEEE Transactions on Power Systems*, v. 28, n. 3, p. 3420–3428, 2013.
- GOLDBERG, D. E. *Genetic Algorithms in Search, Optimization and Machine Learning*. 1st. ed. Boston, MA, USA: Addison-Wesley Longman Publishing Co., Inc., 1989. ISBN 0201157675.
- GÖZEL, T.; HOCAOGLU, M. H. An analytical method for the sizing and siting of distributed generators in radial systems. *Electric Power Systems Research*, v. 79, n. 6, p. 912–918, 2009. ISSN 03787796.
- GRISALES, L. F.; GRAJALES, A.; MONTOYA, O. D.; HINCAPIE, R. A.; GRANADA, M. Optimal location and sizing of Distributed Generators using a hybrid methodology and considering different technologies. In: *2015 IEEE 6th Latin American Symposium on Circuits & Systems (LASCAS)*. [S.l.]: IEEE, 2015. p. 1–4. ISBN 978-1-4799-8332-2.
- GUIMARÃES, M.; CASTRO, C. An Efficient Method for Distribution Systems Reconfiguration and Capacitor Placement using a Chu-Beasley Based Genetic Algorithm. *IEEE Trondheim PowerTech*, p. 1–7, 2011.
- HAMEDI, H.; GANDOMKAR, M. A straightforward approach to minimizing unsupplied energy and power loss through DG placement and evaluating power quality in relation to load variations over time. *International Journal of Electrical Power and Energy Systems*, Elsevier Ltd, v. 35, n. 1, p. 93–96, 2012. ISSN 01420615.
- HEDAYATI, H.; NABAVINIAKI, S. A.; AKBARIMAJD, A. A new method for placement of DG units in distribution networks. *2006 IEEE PES Power Systems Conference and Exposition, PSCE 2006 - Proceedings*, v. 23, n. 3, p. 1904–1909, 2006. ISSN 08858977.
- HOLLAND, J. H. *Adaptation in Natural and Artificial Systems*. [S.l.]: The University of Michigan Press, 1975.

- HOSSEINI, S. M.; ABBASI, F. Optimal DG allocation and sizing in presence of storage systems considering network configuration effects in distribution systems. *IET Generation, Transmission & Distribution*, v. 10, n. 3, p. 617–624, 2016. ISSN 1751-8687.
- HUANG, Y.-C.; YANG, H.-T.; HUANG, C.-L. Solving the capacitor placement problem in a radial distribution system using tabu search approach. *IEEE Transactions on Power Systems*, v. 11, n. 4, p. 1868–1873, Nov 1996. ISSN 0885-8950.
- HUNG, D. Q.; MITHULANANTHAN, N. Multiple distributed generator placement in primary distribution networks for loss reduction. *IEEE Transactions on Industrial Electronics*, v. 60, n. 4, p. 1700–1708, 2013. ISSN 02780046.
- HUNG, D. Q.; MITHULANANTHAN, N.; LEE, K. Y. Optimal placement of dispatchable and nondispatchable renewable DG units in distribution networks for minimizing energy loss. *International Journal of Electrical Power and Energy Systems*, Elsevier Ltd, v. 55, p. 179–186, 2014. ISSN 01420615.
- IEA. *World Energy Outlook 2015*. Paris, 2015. Disponível em: <https://www.iea.org/Textbase/npsum/WEO2015SUM.pdf>. Acesso em 09/06/2016.
- INEE. *Instituto Nacional de Eficiência Energética*. 2016. Disponível em: http://www.inee.org.br/forum/_sobre/_gd/_cg.asp?Cat=gd.
- JABR, R. A.; PAL, B. C. Ordinal optimisation approach for locating and sizing of distributed generation. *IET Generation, Transmission Distribution*, v. 3, n. 8, p. 713–723, August 2009. ISSN 1751-8687.
- JAIN, N.; SINGH, S. N.; SRIVASTAVA, S. C. PSO based placement of multiple wind DGs and capacitors utilizing probabilistic load flow model. *Swarm and Evolutionary Computation*, v. 19, p. 15–24, 2014. ISSN 22106502.
- KANSAL, S.; KUMAR, V.; TYAGI, B. Hybrid approach for optimal placement of multiple DGs of multiple types in distribution networks. *International Journal of Electrical Power & Energy Systems*, Elsevier Ltd, v. 75, p. 226–235, 2016. ISSN 01420615.
- KASHEM, M.; LE, A.; NEGNEVITSKY, M.; LEDWICH, G. Distributed generation for minimization of power losses in distribution systems. *2006 IEEE Power Engineering Society General Meeting*, p. 8 pp., 2006.
- KAUR, S.; KUMBHAR, G.; SHARMA, J. Electrical Power and Energy Systems A MINLP technique for optimal placement of multiple DG units in distribution systems. *International Journal of Electrical Power and Energy Systems*, Elsevier Ltd, v. 63, p. 609–617, 2014. ISSN 0142-0615.
- KEANE, A.; O'MALLEY, M. Optimal allocation of embedded generation on distribution networks. *Power Systems, IEEE Transactions on*, v. 20, n. 3, p. 1640–1646, 2005. ISSN 0885-8950.
- KHALESI, N.; REZAEI, N.; HAGHIFAM, M. R. DG allocation with application of dynamic programming for loss reduction and reliability improvement. *International Journal of Electrical Power and Energy Systems*, v. 33, n. 2, p. 288–295, 2011. ISSN 01420615.
- KHAN, H.; CHOUDHRY, M. A. Implementation of Distributed Generation (IDG) algorithm for performance enhancement of distribution feeder under extreme load growth. *International Journal of Electrical Power and Energy Systems*, Elsevier Ltd, v. 32, n. 9, p. 985–997, 2010. ISSN 01420615.

- KHANBABAPOUR, S.; Hamedani Golshan, M. E. Synchronous DG Planning for Simultaneous Improvement of Technical, Overcurrent and Timely Anti-Islanding Protection Indices of the Network to Preserve Protection Coordination. *IEEE Transactions on Power Delivery*, v. 8977, n. c, p. 1–1, 2016. ISSN 0885-8977.
- KUMAR, A.; GAO, W. Optimal distributed generation location using mixed integer non-linear programming in hybrid electricity markets. *IET Generation, Transmission & Distribution*, v. 4, n. 2, p. 281–298, 2010. ISSN 17518687.
- Kyu-Ho Kim; Yu-Jeong Lee; Sang-Bong Rhee; Sang-Kuen Lee; Seok-Ku You. Dispersed Generator Placement using Fuzzy-GA in Distribution Systems. *IEEE Power Engineering Society Summer Meeting*, v. 3, p. 1148–1153, 2002.
- LAPSEE. *1080 Buses Test System*. 2017. Disponível em: <http://www.feis.unesp.br/\#!/departamentos/engenharia-eletrica/pesquisas-e-projetos/lapsee/downloads/materiais-de-cursos1193/>.
- LÓPEZ-LEZAMA, J. M.; CONTRERAS, J.; PADILHA-FELTRIN, A. Location and contract pricing of distributed generation using a genetic algorithm. *International Journal of Electrical Power & Energy Systems*, v. 36, n. 1, p. 117–126, 2012. ISSN 01420615.
- LOPEZ-LEZAMA, J. M.; PADILHA-FELTRIN, A.; CONTRERAS, J.; MUNOZ, J. I. Optimal Contract Pricing of Distributed Generation in Distribution Networks. *IEEE Transactions on Power Systems*, v. 26, n. 1, p. 128–136, feb 2011. ISSN 0885-8950.
- LORA, J. A. H. E. S. *Geração Distribuída: Aspectos Tecnológicos, Ambientais e Institucionais*. 1. ed. Brasil: Interciencia, 2006.
- MLADENOVIC, N.; HANSEN, P. Variable neighborhood search. *Computers & Operations Research*, v. 24, n. 11, p. 1097–1100, 1997. ISSN 03050548.
- MOHAMED, I. A.; KOWSALYA, M. Optimal size and siting of multiple distributed generators in distribution system using bacterial foraging optimization. *Swarm and Evolutionary Computation*, v. 15, 2014. ISSN 22106502.
- MOHANDAS, N.; BALAMURUGAN, R.; LAKSHMINARASIMMAN, L. Electrical Power and Energy Systems Optimal location and sizing of real power DG units to improve the voltage stability in the distribution system using ABC algorithm united with chaos. *International Journal of Electrical Power and Energy Systems*, Elsevier Ltd, v. 66, p. 41–52, 2015. ISSN 0142-0615.
- MURTY, V.; KUMAR, A. Optimal placement of DG in radial distribution systems based on new voltage stability index under load growth. *International Journal of Electrical Power & Energy Systems*, Elsevier Ltd, v. 69, p. 246–256, 2015. ISSN 01420615.
- OCHOA, L. F.; PADILHA-FELTRIN, A.; HARRISON, G. P. Evaluating distributed time-varying generation through a multiobjective index. *IEEE Transactions on Power Delivery*, v. 23, n. 2, p. 1132–1138, 2008. ISSN 08858977.
- PEREIRA, B. R.; Martins da Costa, G. R. M.; CONTRERAS, J.; MANTOVANI, J. R. S. Optimal Distributed Generation and Reactive Power Allocation in Electrical Distribution Systems. *IEEE Transactions on Sustainable Energy*, v. 7, n. 3, p. 975–984, jul 2016. ISSN 1949-3029.
- PISICA, I.; BULAC, C.; EREMIA, M. Optimal Distributed Generation Location and Sizing Using Genetic Algorithms. *2009 15th International Conference on Intelligent System Applications to Power Systems*, n. 1, p. 1–6, 2009.

- PRADO, I. F. do. ALOCAÇÃO DE GERAÇÃO DISTRIBUÍDA UTILIZANDO O ALGORITMO GENÉTICO DE CHU-BEASLEY E ÍNDICES DE SENSIBILIDADE. *Tese de mestrado em Engenharia Elétrica da Universidade Federal do ABC como*, 2013.
- RAU, N. S.; WAN, Y.-H. Optimum location of resources in distributed planning. *IEEE Transactions on Power Systems*, v. 9, n. 4, p. 2014–2020, Nov 1994. ISSN 0885-8950.
- Ravikumar Pandi, V.; ZEINELDIN, H. H.; XIAO, W. Determining optimal location and size of distributed generation resources considering harmonic and protection coordination limits. *IEEE Transactions on Power Systems*, v. 28, n. 2, p. 1245–1254, 2013. ISSN 08858950.
- REN21. *Renewable energy policy network for the 21st century, renewables 2015 global status repor*. Paris, 2015. Disponível em: http://www.ren21.net/wp-content/uploads/2015/07/REN12-GSR2015-Onlinebook_low1.pdf. Acesso em 08/06/2016.
- RENDÓN, R. A. G. *Planejamento a Longo Prazo de Sistemas de Transmissão Usando Técnicas de Otimização Combinatorial*. Tese (Doutorado) — Unicamp, 1997.
- REPÚBLICA, P. da. *Lei Nº 9.074*. 1995. Disponível em: http://www.planalto.gov.br/ccivil/_03/LEIS/L9074compilada.htm.
- RUEDA-MEDINA, A. C.; FRANCO, J. F.; RIDER, M. J.; PADILHA-FELTRIN, A.; ROMERO, R. A mixed-integer linear programming approach for optimal type, size and allocation of distributed generation in radial distribution systems. *Electric Power Systems Research*, Elsevier B.V., v. 97, p. 133–143, apr 2013. ISSN 03787796.
- SANTOS, F.; SANTOS, F. dos. Geração distribuída versus centralizada. *Revista do Instituto Politécnico de Viseu n°*, Viseu, v. 35, p. 1–15, 2008.
- SEVERINO, M. M.; MARQUES, I.; CAMARGO, D. T. Geração Distribuída : Discussão Conceitual E Nova Definição. v. 14, n. 61, p. 47–69, 2008.
- SHAABAN, M. F.; ATWA, Y. M.; EL-SAADANY, E. F. DG allocation for benefit maximization in distribution networks. *IEEE Transactions on Power Systems*, v. 28, n. 2, p. 939–949, 2013. ISSN 08858950.
- SHIRMOHAMMADI, D.; HONG, H. W.; SEMLYEN, a.; LUO, G. X. Compensation-based power flow method for weakly meshed distribution and transmission networks. *IEEE Transactions on Power Systems*, v. 3, n. 2, p. 753–762, 1988. ISSN 08858950.
- SILVA, D. M. K. *Fluxo de potência para sistemas de distribuição considerando redução de barras*. Trabalho de Conclusão de Curso — UEL, 2015.
- SINGH, R. K.; GOSWAMI, S. K. Optimum allocation of distributed generations based on nodal pricing for profit, loss reduction, and voltage improvement including voltage rise issue. *International Journal of Electrical Power and Energy Systems*, Elsevier Ltd, v. 32, n. 6, p. 637–644, 2010. ISSN 01420615.
- SOUSA, M. C. de. *Alocação de Bancos de Capacitores em Sistemas de Distribuição Radiais Usando Busca Dispersa*. Tese (Mestrado) — Unesp, 2015.
- SOUZA, S. S. F.; ROMERO, R.; PEREIRA, J.; SARAIVA, J. T. Specialized genetic algorithm of chu-beasley applied to the distribution system reconfiguration problem considering several demand scenarios. *2015 IEEE Eindhoven PowerTech*, p. 1–5, June 2015.

- SULTANA, S.; ROY, P. K. Krill herd algorithm for optimal location of distributed generator in radial distribution system. *Applied Soft Computing Journal*, Elsevier Ltd, v. 40, p. 391–404, 2016. ISSN 15684946.
- TAH, A.; DAS, D. Novel analytical method for the placement and sizing of distributed generation unit on distribution networks with and without considering P and PQV buses. *International Journal of Electrical Power & Energy Systems*, Elsevier Ltd, v. 78, p. 401–413, jun 2016. ISSN 01420615.
- TAMIMI, A. A.; PAHWA, A.; STARRETT, S. Effective wind farm sizing method for weak power systems using critical modes of voltage instability. *IEEE Transactions on Power Systems*, v. 27, n. 3, p. 1610–1617, 2012. ISSN 08858950.
- UGRANLI, F.; KARATEPE, E. Multiple-distributed generation planning under load uncertainty and different penetration levels. *International Journal of Electrical Power and Energy Systems*, v. 46, n. 1, p. 132–144, 2013. ISSN 01420615.
- VATANI, M.; GHAREHPETIAN, G. B.; SANJARI, M. J.; Solati Alkaran, D. Multiple distributed generation units allocation in distribution network for loss reduction based on a combination of analytical and genetic algorithm methods. *IET Generation, Transmission & Distribution*, v. 10, n. 1, p. 66–72, 2016. ISSN 1751-8687.
- VIRAL, R.; KHATOD, D. K. An analytical approach for sizing and siting of DGs in balanced radial distribution networks for loss minimization. *International Journal of Electrical Power and Energy Systems*, Elsevier Ltd, v. 67, p. 191–201, 2015. ISSN 01420615.
- VOVOS, P. N.; BIALEK, J. W. Direct incorporation of fault level constraints in optimal power flow as a tool for network capacity analysis. *IEEE Transactions on Power Systems*, v. 20, n. 4, p. 2125–2134, Nov 2005. ISSN 0885-8950.
- WOTTRICH, B. *Modelo para a análise econômica e financeira em projetos de geração distribuída de energia com fontes alternativas*. 106 p. Tese (Mestrado) — Universidade Federal de Santa Maria, 2010.
- ZHU, D.; BROADWATER, R. P.; TAM, K. S.; SEGUIN, R.; ASGEIRSSON, H. Impact of DG placement on reliability and efficiency with time-varying loads. *IEEE Transactions on Power Systems*, v. 21, n. 1, p. 419–427, 2006. ISSN 08858950.

Apêndices

Apêndice A – Parâmetros do Algoritmo Genético Especializado

Os parâmetros do algoritmo genético especializado implementado neste trabalho são: tamanho da população inicial (TMI), taxa de mutação (TM), e critério de parada relacionado ao número máximo de iterações necessárias para que a melhor solução não varie.

Com objetivo de averiguar a convergência do algoritmo em relação aos parâmetros TPI e TM, inicialmente fixa o valor de TM de acordo com o tamanho do sistema e varia-se o valor de TPI, também de acordo com o tamanho do sistema. Na Figura A.1 é apresentado um exemplo do comportamento do algoritmo em relação à variação de TPI. Para este caso a população inicial de 50 indivíduos apresentou melhor convergência, uma vez que, denotou um menor número de FO calculadas e um menor número de iterações necessárias para encontrar a melhor solução. Em seguida, o valor de TPI é fixado, no valor que apresentou menor esforço computacional e o valor de TM varia de acordo com o tamanho do sistema. Um exemplo de comportamento do algoritmo em relação à variação de TM pode ser visto na Figura A.2. Em seguida, é exposto o estudo relativo à variação dos parâmetros do AGE nos sistemas de distribuição utilizados neste trabalho. Os resultados são apresentados nas Tabelas A.1 a A.4, sendo que os valores em negrito correspondem aos parâmetros escolhidos para cada sistema. O critério de escolha foi o menor número de FO calculadas e o menor número de iterações, considerando que em todos os casos ocorre a convergência para a mesma solução.

Estes dados foram encontrados considerando o pior caso para cada sistema, que significa o maior número de GDs a ser alocada, referente apenas a alocação da GD, sendo a população inicial gerada aleatoriamente. Estes valores serão empregados para a alocação e dimensionamento da GD.

Figura A.1: Comportamento da F_0 do sistema de distribuição de 70 barras em relação à variação do parâmetro TPI, considerando $TM = 1\%$.

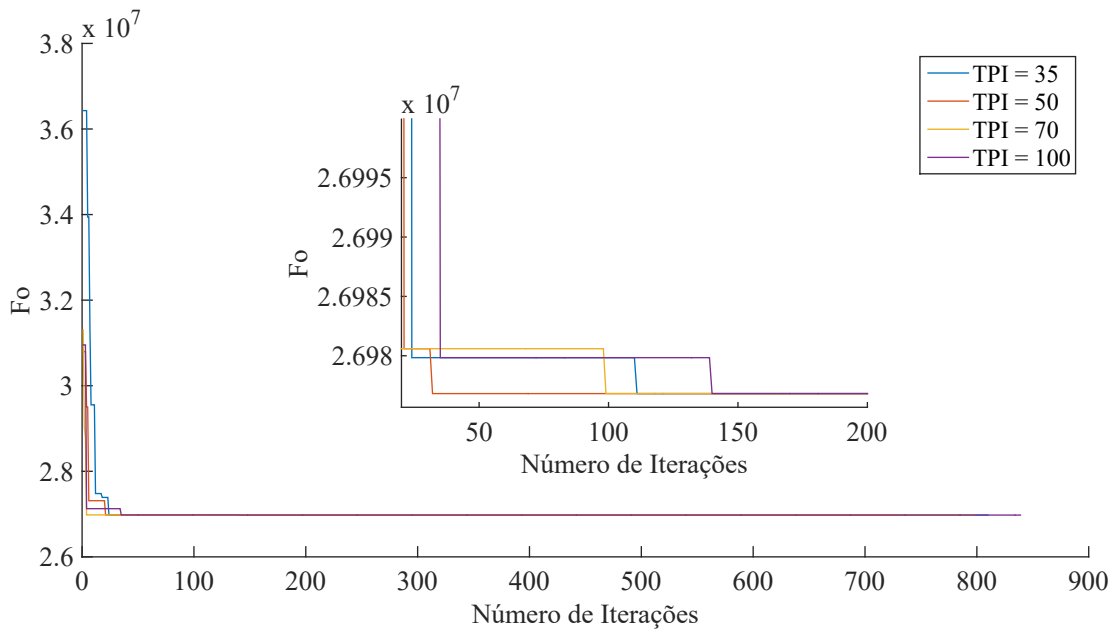


Figura A.2: Comportamento da F_0 do sistema de distribuição de 70 barras em relação à variação do parâmetro TM, considerando $TPI = 50$.




Tabela A.1: Parâmetros do algoritmo genético para o sistema de distribuição de 70 barras.

TPI	TM	Número de iterações	Tempo (s)	Número de FO
35	0,01	797	2,91	13576
50	0,01	748	2,63	12749
70	0,01	800	2,67	13668
100	0,01	833	2,98	14094
50	0,005	780	2,78	23538
50	0,02	951	4,01	1828
50	0,05	1121	4,45	23538

Fonte: Próprio autor(2017).

Tabela A.2: Parâmetros do algoritmo genético para o sistema de distribuição de 135 barras.

TPI	TM	Número de iterações	Tempo	Número de FO
65	0,02	1657	27,27	43758
100	0,02	1534	12,92	40492
135	0,02	1562	13,98	41244
150	0,02	1634	23,06	43030
100	0,005	1293	10,46	28113
100	0,01	1843	16,69	45973
100	0,05	14199	16,24	42108

Fonte: Próprio autor(2017).

Tabela A.3: Parâmetros do algoritmo genético para o sistema de distribuição de 400 barras.

TPI	TM	Número de iterações	Tempo	Número de FO
50	0,03	1802	66,24	63479
70	0,03	1912	81,79	67253
100	0,03	1778	48,07	62553
150	0,03	1944	70,86	68345
100	0,005	1831	30,02	47106
100	0,01	1814	45,16	49257
100	0,05	2200	87,41	42108

Fonte: Próprio autor(2017).

Tabela A.4: Parâmetros do algoritmo genético para o sistema de distribuição de 1080 barras.

TPI	TM	Número de iterações	Tempo	Número de FO
200	0,004	2611	102,83	77242
300	0,004	2931	117,44	86691
540	0,004	2255	107,78	66632
600	0,004	2212	86,01	65300
650	0,004	2240	91,86	66195
600	0,005	2331	118,65	71007
600	0,007	2337	100,20	75393
600	0,01	2218	102,98	93490

Fonte: Próprio autor(2017).

Apêndice B – Comparação do Desempenho dos Índices de Sensibilidade

Para escolha de qual índice de sensibilidade será utilizado neste trabalho, são realizados testes com o sistema 70 barras utilizando os parâmetros do genético escolhidos através da metodologia do apêndice A, sendo simulado 100 vezes para se obter o valor médio dos parâmetros. Na Tabela B.1, é possível se observar a comparação de performance dos diferentes índices de sensibilidade empregados para a geração da população inicial, considerando a alocação de três GDs, com despacho de potência fixa, 1000 kW com fator de potência de 0,95 indutivo; e o critério de parada adotado foi de 200 iterações, uma vez que apresentou a mesma taxa de dispersão da melhor solução, quando comparado ao algoritmo com a geração aleatória da população inicial.

Tabela B.1: Comparação da performance dos diferentes índices de sensibilidade para a geração da população inicial.

Índice de Sensibilidade	Iterações	FO	Tempo (s)
ISP^1	298	5188	0,92
ISP^2	334	5814	0,98
IET	282	4941	0,86

Na Tabela B.1 nota-se que o índice de sensibilidade com maior impacto na melhoria da geração da população inicial foi o índice de estabilidade de tensão. Um vez que, este índice apresentou uma redução significativa nos seus parâmetros quando comparado com as outras metodologias.

Apêndice C – Publicações

Título: Improved genetic algorithm applied to distributed generation allocation considering different load profiles;

Autores: Karina Yamashita, Alexandre Akira Kida e Luis Alfonso Gallego Pareja;

Congresso: XXI Congresso Brasileiro de Automática - CBA2016

Título: Improved Genetic Algorithm Applied to Multiple Distributed Generation Optimal Allocation Considering Different Load Profiles;

Autores: Karina Yamashita e Luis Alfonso Gallego Pareja;

Congresso: 12th IEEE/IAS International Conference on Industry Applications - INDUSCON 2016

Título: Algoritmo genético melhorado para o redimensionamento ótimo de cabos primários em sistemas de distribuição de energia elétrica;

Autores: Camila Maria Galo da Silva, Karina Yamashita e Luis Alfonso Gallego Pareja;

Congresso: 12th IEEE/IAS International Conference on Industry Applications - INDUSCON 2016

IMPROVED GENETIC ALGORITHM APPLIED TO DISTRIBUTED GENERATION ALLOCATION CONSIDERING DIFFERENT LOAD PROFILES

KARINA YAMASHITA*, ALEXANDRE AKIRA KIDA*, LUIS ALFONSO GALLEGOPAREJA*

* *Universidade Estadual de Londrina
Londrina, Paraná, Brasil*

Emails: karina_yamashita@hotmail.com, alexandrevida@gmail.com, gallegopareja@gmail.com

Abstract— This paper presents an improved genetic algorithm to solve the distributed generation (DG) allocation problem in radial electrical energy distribution systems. The problem is formulated as a matter of nonlinear mixed integer programming, since it presents integer variables, which indicate the position where the DG will be allocated, and continuous variables, associated with electrical values (voltage, current, active and reactive power losses and power flow). In the proposed formulation, different load levels are considered. The objective is to minimize costs produced by system losses and the implementation and maintenance expenses of the distributed generation. The proposed methodology has been successfully tested for distribution systems with 70 and 135 buses.

Keywords— Distributed Generation, Radial Distribution Systems, Improved Genetic Algorithm.

1 Introduction

Changes in economic and regulatory scenarios, environmental awareness to minimize impacts, the need for more flexible electrical systems and restrictions for construction of new transmission lines carry the energy systems to a decentralized and small-scale model (Dunn, 2000). Current electrical systems that comply with consumer demand are characterized by conventional or centralized generation. This type of system has large power plants, associated with primary energy sources, connected to extensive transmission and distribution lines.

In this context, distributed generation (DG) is involved in the search for efficient and decentralized energy systems, if well planned and implemented. Despite that the DG concept exists for more than a century, recent discussions on the subject produced various definitions for this type of generation, as demonstrated by (Severino et al., 2008). The INEE. (2016) says that DG can be defined as any generating source with production destined, the most part, to local or nearby loads without need for long transmission lines.

In specialized literature, there is a vast amount of content with different approaches on the subject. The work in (Khalesi et al., 2011) presents a multi-objective function for optimal DG allocation in distribution systems, in order to minimize power losses, increase systems reliability indicators and improve the voltage profile. Load levels are considered to obtain more realistic results.

In (Kazemi and Sadeghi, 2009) the proposed work has an algorithm for DG allocation which aims to reduce losses and ensure that the voltage profile remains at acceptable levels. The algorithm is based on power flow and is divided into two steps. First, the buses are classified by the loss reduction criteria. Second, allocates the DG

and calculates the new voltage levels after the allocation.

In the work presented by (Grisales et al., 2015) a hybrid algorithm is proposed based on a (Chu and Beasley, 1997), which determines the candidate node for installation. The dispatch of power is performed by the particles swarm algorithm, which allows to vary the function goal according to the system requirements, improving the profile voltages or reduced losses. The use of wind, photovoltaic or small hydroelectric plants is considered, according to the topology and weather conditions of the site where the DG will be located.

This article objective is to propose a mathematical model for DG allocation, which considers the costs of installation and maintenance of a DG and the costs of active system losses. To solve this problem, an improved genetic algorithm (IGA) is used in order to insert the DG, considering it's active and reactive power is fixed to all load levels, since different load levels are used, thus, reducing losses and improving voltage profile.

This work is divided into five sections. Section II presents the mathematical model for DG allocation, Section III exposes the IGA and the characteristics used for the solution of the problem. In section IV the IGA results are presented for two main systems. The main conclusions of this paper are presented in Section V.

2 Mathematical modeling

The allocation of the DGs is formulated as a mathematical optimization problem, where the objective is to minimize installation and maintenance costs as well as the network operating costs (power losses).

Distributed generation allocation is analyzed as a nonlinear mixed integer problem, due to the presence of integer variables, which indicates the

allocated DG position, and the associated electrical continuous variables of the electric system (voltages, currents, power flows and losses of active and reactive power). The proposed modeling of this article is displayed as follows.

$$\text{Min. } f_o = \sum_{k=1}^{nb} n_k^{dg} \cdot (c_k + r_k \cdot T \cdot P_k^{dg}) + \sum_{d=0}^{nt} k_e^d T_d P_d^{loss} \quad (1)$$

subject to

$$\sum_{i=1}^{nb} P_i^S - \sum_{i=1}^{nb} P_{i,d}^D - \sum_{ij \in \Omega_L} (P_{ij,d} + I_{ij,d}^2 \cdot R_{ij}) + \sum_{i=1}^{nb} P_i^{dg} \cdot n_i^{dg} = 0; \quad (2)$$

$$\sum_{i=1}^{nb} Q_i^S - \sum_{i=1}^{nb} Q_{i,d}^D - \sum_{ij \in \Omega_L} (Q_{ij,d} + I_{ij,d}^2 \cdot X_{ij}) + \sum_{i=1}^{nb} Q_i^{dg} \cdot n_i^{dg} = 0; \quad (3)$$

$$0 \leq P_i^S \leq \overline{P_i^S} \quad \forall i \in \Omega_b; \quad (4)$$

$$0 \leq Q_i^S \leq \overline{Q_i^S} \quad \forall i \in \Omega_b; \quad (5)$$

$$0 \leq P_i^{dg} \leq \overline{P_i^{dg}} \quad \forall i \in \Omega_b; \quad (6)$$

$$0 \leq Q_i^{dg} \leq \overline{Q_i^{dg}} \quad \forall i \in \Omega_b; \quad (7)$$

$$\underline{V} \leq V_{i,d} \leq \overline{V} \quad \forall i \in \Omega_b; \quad (8)$$

$$\underline{I_{ij}} \leq I_{ij,d} \leq \overline{I_{ij}} \quad \forall ij \in \Omega_L; \quad (9)$$

$$\sum_{k=1}^{nb} n_k^{dg} \leq \overline{n^{dg}} \quad (10)$$

$$n_k^{dg} \in \{1, 0\} \quad (11)$$

such that

nb is the number of buses; c_k is a constant representing the cost of installation; n_k^{dg} is a vector filled with binary values, which indicate the presence or absence of DG; T is the total time used by the system; r_k is a constant that represents the cost of maintenance of a DG; k_e^d is the power cost parameter for each load level; nt is the number of system load profiles; P_k^{dg} is the active power installed by DG; T_d is the period for the load profile; $P_d^{loss} = I_{ij,d}^2 \cdot R_{ij}$ are the total active power losses for each period; P_i^S and Q_i^S are the active and

reactive power injected by the substation, respectively; $P_{i,d}^D$ and $Q_{i,d}^D$ are the active and reactive power demands for bus i , at the load level d , respectively; $P_{ij,d}$ and $Q_{ij,d}$ are the active and reactive power flow, respectively; $I_{ij,d}^2 R_{ij}$ and $I_{ij,d}^2 X_{ij}$ are the active and reactive losses in the sector ij , respectively, as shown in Fig. 1 of $I_{ij,d}^2 \overline{Z}_{ij}$ (impedance), R_{ij} and X_{ij} are resistance and reactance of the branch ij ; P_{ki}^{dg} and Q_{ki}^{dg} are the active and reactive powers inserted by distributed generation; $\overline{P_i^S}$ and $\overline{Q_i^S}$ are the maximum acceptable values for active and reactive power entered by the substation, respectively, for all buses (Ω_b); $\overline{P_i^{dg}}$ and $\overline{Q_i^{dg}}$ are the maximum acceptable values for active and reactive power entered by DG, respectively, to Ω_b ; $V_{i,d}$ bus voltage i for charge level d ; \underline{V} and \overline{V} are the minimum and maximum acceptable values for Ω_b , respectively; $\underline{I_{ij}}$ and $\overline{I_{ij}}$ are the minimum and maximum acceptable values for the current in the whole set of lines respectively (Ω_L); $\overline{n^{dg}}$ is a constant representing the maximum number of DGs installed in the system.




Figure 1: Simplified system representation.

The objective function shown in (1) contains two summations. The first, exposes the DG installation and maintenance costs. Maintenance costs considers different expenses involved in energy acquisition. The second one represents the losses cost for each load level.

To calculate the losses, P_i^{loss} , the power flow Backward-Forward Sweep (Shirmohammadi et al., 1988) algorithm is used.

The load levels represent the system demand for a period of time T_i , this paper considers three load profiles – high, medium and light.

The constrains considered in the problem are those traditionally used in literature (Baran and Wu, 1989), (Pereira et al., 2016): the power flow balance ((2) and (3))–shown in figure 1–, the substation power limits ((4) and (5)), the buses voltage limit (8) and the branch current limit (9).

Injected power restrictions are defined in (6) and (7).

The restriction (10) presents the maximum, $\overline{n^{dg}}$, number of DGs to be inserted into the system.

The (11) constraint refers to the type of data contained in vector n_k^{dg} , where 1 is used to indicate the existence of a DG in a given bus and 0 for the absence of DG.

In any violation of these restrictions, the ob-

jective function will suffer a penalty, by adding a very high value.

3 Improved Genetic Algorithm

This work uses an improved genetic algorithm (IGA) based on (Chu and Beasley, 1997) ideas, which is a meta-heuristic technique for solving nonlinear problems. The GA mimics genetic evolution and biological selection of individuals behaviors in a computer programming format (Holland, 1975).

Following features are the difference between IGA and the traditional GA (Holland, 1975): 1) there is a fitness and an unfitness function, which are used to identify the objective function value and quantify feasibility of the tested solution, respectively; 2) replaces only one individual in the population for each iteration and 3) each individual goes through a local improvement strategy.

The flowchart shown in figure 2, presents the main steps of the IGA used in this work.

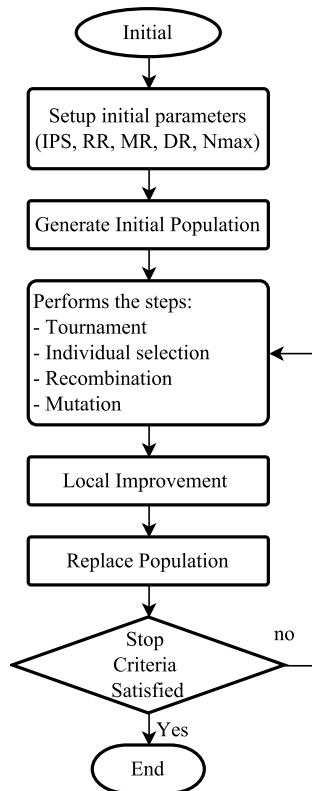


Figure 2: Flowchart IGA.

The flowchart has these steps: Setup the control parameters – size of the initial population (IPS), recombination rate (RR), mutation rate (MR), diversity rate (DR) and maximum number of iterations (N_{max})– creation of the initial population, tournament selection, recombination, mutation, local improvement, replacement and verification of the stop criteria.

Each step is described as follows:

3.1 Codification

An individual is represented by a vector with size equal to the number of buses in the system, as shown in Fig 3. This vector is filled in a binary form, where 1 is the point of allocation.




Figure 3: Example encoding for an individual.

3.2 Initial population

Initial population is represented by a matrix $IPS \times nb$, where individuals in the population are randomly generated.

3.3 Selection

The adopted selection process is based on the tournament method. In this method, two groups of potential parents are generated, each group will consist of k individuals, randomly chosen within the current population. In each group the best individual is chosen, which has the best objective function. At the end of this process, two individuals are selected, named as parents, who are employed in the recombination step (Gallego et al., 2009).

3.4 Recombination

Recombination proceeds with a cut at a single point, chosen in random order, as shown in Figure 4. Further, it can be noted that each child inherits characteristics of both parents. At the IGA proposed, only one children will continue to the next step, the chosen is the one with a lower objective function.

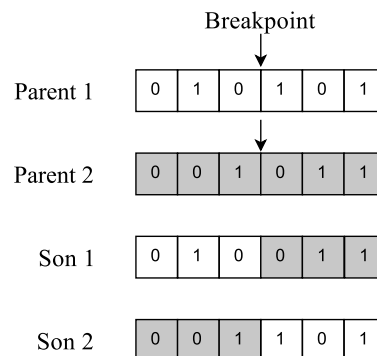


Figure 4: An example of a recombining step.

3.5 Mutation

According to the mutation rate, individual points are selected at random to change their state, as

seen in figure 5. This process can generate individuals who break the amount of allocated DGs, so a check must be made to that number, if it is higher than the limit, the amount of DGs over the limit is eliminated. With the individual within bounds, the objective function is calculated. This process is done for all possible combinations of DG allocations within the limits, and the combination that has the best answer to the objective function is selected.




Figure 5: Example of a mutation step.

3.6 Local improvement

A neighborhood search is performed, consisting of a search in the buses near the DG allocation point, in order to improve response of the objective function. If this goal is achieved the individual is modified, otherwise, the DG remains in the original bus.

3.7 Replacement

After the local improvement stage, the generated individual enters the current population if it satisfies the following conditions: it is not within the current population and have a better objective function than the worst individual of the current population. Otherwise, the individual will be discarded.

3.8 Stop criteria

If the best solution does not change in a range of N iterations the algorithm is said convergent and the best individual of the current population is exposed. If N_{max} is reached before the algorithm converges the program stops.

4 Results

The proposed methodology was tested in two radial distribution systems: 70 bus (Baran and Wu, 1989) and 135 bus (Guimaraes and Castro, 2011).

The cost of installation $c_k = 150k\$/MW$ and maintenance cost $r_k = 0.5\$/MVAh$ (Pereira et al., 2016).

The parameters used are presented in table 1.

The algorithm was implemented in C++, using a computer with processor *Core^(TM) i5 - 3210M*, 2.50 GHz.

Table 1: IGA Parameters.

Feature	Used values
Initial Population(IPS)	40 individuals
Mutation Rate(MR)	5%
Diversity Rate(DR)	1%
Maximum Number of Iterations(Nmax)	10000

4.1 System 70 buses

System topology is shown in Figure 6, where its total load is $S = 3.8021 MW + j.2.6946 MVar$.

Parameters for this system are: energy cost $k_e^0 = 0.7 \$/kWh$, $k_e^1 = 1.78 \$/kWh$ and $k_e^2 = 2.95 \$/kWh$, for each load level. Maximum and minimum values adopted for system voltages are respectively 1.05 to 0.90 per unit (p.u.). The load levels considered are $S_0 = 1.25$ (heavy), $S_1 = 1.0$ (medium) and $S_2 = 0.625$ (light). Each charge level has a distinct duration $T_0 = 1000h, T_1 = 6760h$ and $T_2 = 1000h$. It is proposed to allocate only one DG 1MW with power factor, inductive, 0.95 and stop criteria of $N = 20$ iterations.




Figure 6: Line diagram of the radial system with 70 buses.

The initial cost without DG allocation, relative to system losses, is \$ 3202084.75. Table 2 refers to losses – active and reactive – and minimum voltage levels for each load level for the system without DG allocation.

Table 2: Initial solution to the system with 70 buses (without DGs).

	Power		Voltage	
	Load Level	Active (kW)	Reactive (kVar)	Minimum (p.u.)
1	1.250	367.76	166.57	0.8852
2	1.000	224.56	101.98	0.9102
3	0.625	82.24	37.49	0.9456
Total:		674.55	306.04	-

The solution found by the algorithm is the allocation of a DG in bus 50 with a total cost of \$ 2258780.50, being \$154610.51 the installation and maintenance expenses, active losses cost was \$ 2104170.00. Thus, the total active power losses and costs are reduced by 34.29% and 29.46%, respectively.

Table 3 presents the losses and minimum voltages for each voltage level considering the DG allocation at bus 50. The computational time required to find the answer was 0.056 seconds.

Table 3: 70 buses system, considering DG allocation.

	Power			Voltage
	Load Level	Active (kW)	Reactive (kVar)	Minimum (p.u.)
1	1.250	248.32	115.28	0.9247
2	1.000	146.92	68.47	0.9469
3	0.625	55.08	25.46	0.9788
Total:		450.32	209.21	-

Comparing data from tables 2 and 3, there is a notorious reduction in total active losses of approximately 33 % and voltage levels achieved a considerable improvement, justifying the high amount of money used to install the DG.

IGA convergence characteristics for the system 70 buses is shown in Figure 7. Note that the algorithm converges to the answer in less than 55 iterations.




Figure 7: IGA convergence characteristic for the 70 buses system.

To verify the validity of the results, the method was tested with random seeds to the random number generator, and thus converging closely to the same answer. This behavior is shown in figure 8 to the 70 buses system.

4.2 System 135 buses

The parameters for this system are: energy cost $k_e = 0.06$ \$/kWh, to all load level, cost of installation $c_k = 150k$ \$/MW and maintenance cost

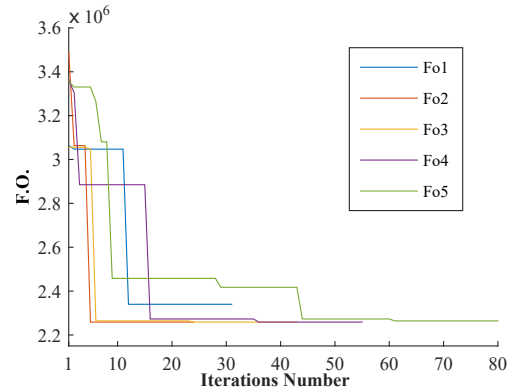


Figure 8: IGA convergence characteristic for the 70 buses system, with different initial populations where each curve (F.O.1, F.O.2, F.O.3, F.O.4, F.O.5, F.O.6) is a different seed to the random number generator.

$r_k = 0.5$ \$MVAh. The maximum and minimum values adopted for system voltages are respectively 1.05 to 0.90 per unit (p.u.). Load levels are considered $S_0 = 1.8$ (high), $S_1 = 1.0$ (average) and $S_2 = 0.5$ (light). Each charge level has a distinct duration $T_0 = 1000h$, $T_1 = 6760h$ and $T_2 = 1000h$. It is proposed to allocate two DG with 2MW, power factor 0.95, inductive, with the stopping criteria of $N = 100$ iterations, considering a period of 20 years. System total load is $S = 18,31$ MW + $j.7.93$ MVar.

Cost of losses without DG allocation are \$ 3974710.75 and table 4 refers losses, active and reactive, and voltage levels, minimum, for each load level for the DG without allocation system.

Table 4: System with 135 buses without DG allocation.

	Power			Voltage
	Load Level	Active (kW)	Reactive (kVar)	Minimum (p.u.)
1	1.8	1084.11	2378.73	0.8985
2	1.0	318.23	698.18	0.9388
3	0.5	76.91	168.72	0.9686
Total:		1479.25	3245.62	-

After using the IGA for DG allocation, the best positions found were in bus 12 and 155 with a total cost of \$ 3713878.25, being \$ 668842.06 the cost of implementation and maintenance, and the cost of active losses as \$ 3045036.25, so the cost of implementation is only 18% of the total cost.

In Table 5, active and reactive losses are presented, along with the minimum voltage levels for each load level, considering DG allocation in buses 12 and 155. The computational time required to find the answer was 0.770 seconds.

Comparing the results of Table 4 with Table 5, there is a reduction in 20.37 % for active losses and 21.27 % in reactive losses. In this system the

Table 5: System with 135 buses considering DGs allocations.

	Power		Voltage	
	Load Level	Active (kW)	Reactive (kVar)	Minimum (p.u.)
1	1.8	867.34	1884.44	0.8833
2	1.0	236.05	509.78	0.9379
3	0.5	74.47	161.16	0.9735
Total:		1177.86	2555.37	-

improvement in the voltage profile is barely noticeable, since the reactive power injection, which is the primary responsible for improvements in the voltage profile, is insignificant to the system.

5 Conclusion

In this paper, a mathematical model for optimal allocation of distributed generators in radial distribution systems was proposed. This mixed integer linear problem is solved using a meta-heuristic technique named as improved genetic algorithm (IGA).

The mathematical model combined with the meta-heuristics techniques presented optimum solutions, to the allocation problem, and also have a good computational performance for medium and large electrical energy distribution systems.

With the obtained results, it was demonstrated that the DG allocation reduces the overall system losses. Also, an improvement of the voltage profile was observed for each load level considered.

Acknowledgment

The authors would like to thank CNPQ and Capes for the financial support.

References

Baran, M. and Wu, F. (1989). Optimal capacitor placement on radial distribution systems, *IEEE Transactions on Power Delivery* **4**(1): 725–734.

Chu, P. C. and Beasley, J. E. (1997). A genetic algorithm for the generalised assignment problem, *Journal of the Operational Research Society* **48**(8): 804–809.

Dunn, S. (2000). Micropower: The next electrical era, *Worldwatch Paper* (151): 1–94.

Gallego, L. a., Rider, M. J., Romero, R. and Garcia, A. V. (2009). A specialized genetic algorithm to solve the short term transmission network expansion planning, *2009 IEEE Bucharest PowerTech*, number 5, IEEE, pp. 1–7.

Grisales, L. F., Grajales, A., Montoya, O. D., Hincapie, R. A. and Granada, M. (2015). Optimal location and sizing of Distributed Generators using a hybrid methodology and considering different technologies, *2015 IEEE 6th Latin American Symposium on Circuits & Systems (LASCAS)*, IEEE, pp. 1–4.

Guimaraes, M. and Castro, C. (2011). An Efficient Method for Distribution Systems Reconfiguration and Capacitor Placement using a Chu-Beasley Based Genetic Algorithm, *IEEE Trondheim PowerTech* pp. 1–7.

Holland, J. H. (1975). *Adaptation in Natural and Artificial Systems*, The University of Michigan Press.

INEE. (2016). Instituto nacional de eficiência energética.

Kazemi, a. and Sadeghi, M. (2009). Distributed generation allocation for loss reduction and voltage improvement, *Asia-Pacific Power and Energy Engineering Conference, APPEEC*.

Khalesi, N., Rezaei, N. and Haghifam, M. R. (2011). DG allocation with application of dynamic programming for loss reduction and reliability improvement, *International Journal of Electrical Power and Energy Systems* **33**(2): 288–295.

Pereira, B. R., Martins da Costa, G. R. M., Contreras, J. and Mantovani, J. R. S. (2016). Optimal Distributed Generation and Reactive Power Allocation in Electrical Distribution Systems, *IEEE Transactions on Sustainable Energy* **7**(3): 975–984.

Severino, M. M., Marques, I. and Camargo, D. T. (2008). Geração Distribuída : Discussão Conceitual E Nova Definição, **14**(61): 47–69.

Shirmohammadi, D., Hong, H. W., Semlyen, a. and Luo, G. X. (1988). Compensation-based power flow method for weakly meshed distribution and transmission networks, *IEEE Transactions on Power Systems* **3**(2): 753–762.

Improved Genetic Algorithm Applied to Multiple Distributed Generation Optimal Allocation Considering Different Load Profiles

Karina Yamashita and Luis Alfonso Gallego Pareja

State University of Londrina

Electrical Engineering

Email: karina_yamashita@hotmail.com, gallegopareja@gmail.com

Abstract—Distributed generation (DG) allocation is a non-linear mixed integer problem, being the position where a DG will be allocated an integer variable, and the associated electrical values (voltage, current, active and reactive power losses and power flow) the continuous variables. In this paper an improved genetic algorithm (IGA) is presented to solve the distributed generation (DG) allocation problem in radial electrical distribution systems. The proposed formulation uses different load levels to obtain more realistic results. The IGA goal is to determine the optimal position to insert a DG into the system, thus, minimizing costs produced by system losses, maintenance and the DG implementation. The proposed methodology has been successfully tested for distribution systems with 34, 70 and 136 buses, presenting a better computational performance when compared to an exhaustive search method.

I. INTRODUCTION

Current electrical systems comply with consumer demand and are characterized by conventional or centralized generation. Changes in economic and regulatory scenarios, environmental awareness to minimize impacts, the need for more flexible electrical systems and restrictions for construction of new transmission lines carry the energy systems to a decentralized model and small-scale [1]. This type of system has large power plants, associated with primary energy sources, connected to extensive transmission and distribution lines.

In this context, distributed generation (DG) is involved in the search for efficient and decentralized energy systems, if well planned and implemented. Despite that the DG concept exists for more than a century, recent discussions on the subject produced various definitions for this type of generation, as demonstrated by [2]. The [3] says that DG can be defined as any generating source with production destined, the most part, to local or nearby loads without need for long transmission lines.

Many different techniques have been developed and described in the literature for DG allocation. Note that there is no rigid format to address this problem. Analytical approaches can be employed using a sensitivity factor, in [4] this factor is based on the exact power loss formula, in [5] the sensitivity factor is based on current injection, both with the purpose of allocate and scale the DG optimally, considering only one load profile. In [6] an analytical methodology to allocate and scale multiple DGs is described, considering only one voltage

profile. In [7] an analytical methodology to minimize active and reactive power losses, allocate and scale multiple DGs is described. Another approach is numerical: in [8] a linear mix-integer programming technique is used to allocate, measure and define the type of DG that should be installed, considering the load profiles. In [9] a mix-integer non-linear programming indicates the location and size of the DG to be allocated, in order to get the best voltage profile. Dynamic programming is used in [10] in order to maximize the profit of the distribution network operator, evaluating the load profiles. The exhaustive search is used by [11] and [12]; in the first the goal is to maximize reliability and minimize system losses, resulting in the location of the DG, in the second a multi-objective performance index based on the variation of the time, demand behavior and generation is used, indicating the position of the DG.

In the literature there are also many works using heuristics. The genetic algorithm (GA) is presented in [13] Chu-Beasley is employed to maximize the profit to the owner of DG, in [14] GA is implemented to allocate renewable DGs considering variations in load, in [15] a fuzzy logic GA is used to minimize power loss costs, in [16] Chu-Beasley is employed to minimize the power loss, based on load flow and in [17] a GA is used in conjunction with the ε -constrained method to solve the multi-objective modeling. Particle Swarm is the technique used by [18] to find the type, location and size of DG considering standard harmonic limits and protection coordination constraints. Modified bacterial foraging optimization algorithm for optimal placement and sizing of DG is proposed to reduce the total loss and improve the voltage profile [19]. A Modified Firefly Algorithm is the technique used by [20] for optimal sizing and positioning of voltage controlled distributed generators on balanced and unbalanced distribution networks. Another widely used heuristic method is practical where in [21] the modeling is based on the continuous power flow, [22] uses to calculate the regions of higher probability for location of DG, in [23] it is used in order to minimize the cost of improving network reliability, [24] uses considering the load levels to minimize losses costs, indicating the DG position, [25] it is used to design wind farms based on voltage instability.

This article objective is to propose a mathematical model for

the allocation of DGs, which considers the costs of installation and maintenance of a DG and the costs of active system losses. To solve this problem, an improved genetic algorithm (IGA) is used in order to insert the DG, considering its active and reactive power is fixed to all load levels, since different load levels are used, thus reducing losses and improving voltage profile.

This work is divided into five sections. Section II presents the mathematical model for allocation of DGs, Section III exposes the IGA and the characteristics used for the solution of the problem. In section IV the IGA results are presented for two main systems. The main conclusions of this paper are presented in Section V.

II. MATHEMATICAL MODELING

The allocation of DGs is formulated as a problem of mathematical optimization, which has the objective of minimizing the GD installation and maintenance costs and network operating costs (power losses). This issue is subject to operational constraints of the network – the balance of loads, the power inserted by the substation or the DG, the minimum and maximum voltages and currents allowed in buses and lines, respectively, and the DG number inserted in the network.

The allocation of DGs is a non-linear mixed-integer problem, due to the presence of integer variables, which indicate the position where the DG will be allocated, and continuous variables, associated with the electric system (voltages, currents, power flows and losses of active and reactive power). The proposed modeling of this paper is displayed as follows.

$$\text{Min. } f_o = kc \cdot \sum_{k=1}^{nb} n_k^{dg} \cdot (c_k + r_k \cdot T \cdot P_k^{dg}) + \sum_{d=0}^{nt} k_e^d \cdot T_d \cdot P_d^{loss} \quad (1)$$

subject to

$$\sum_{i=1}^{nb} P_i^S - \sum_{i=1}^{nb} P_{i,d}^D - \sum_{ij \in \Omega_L} (P_{ij,d} + I_{ij,d}^2 \cdot R_{ij}) + \sum_{i=1}^{nb} P_i^{dg} \cdot n_i^{dg} = 0; \quad (2)$$

$$\sum_{i=1}^{nb} Q_i^S - \sum_{i=1}^{nb} Q_{i,d}^D - \sum_{ij \in \Omega_L} (Q_{ij,d} + I_{ij,d}^2 \cdot X_{ij}) + \sum_{i=1}^{nb} Q_i^{dg} \cdot n_i^{dg} = 0; \quad (3)$$

$$0 \leq P_i^S \leq \overline{P_i^S} \quad \forall i \in \Omega_b; \quad (4)$$

$$0 \leq Q_i^S \leq \overline{Q_i^S} \quad \forall i \in \Omega_b; \quad (5)$$

$$0 \leq P_i^{dg} \leq \overline{P_i^{dg}} \quad \forall i \in \Omega_b; \quad (6)$$

$$0 \leq Q_i^{dg} \leq \overline{Q_i^{dg}} \quad \forall i \in \Omega_b; \quad (7)$$

$$\underline{V} \leq V_{i,d} \leq \overline{V} \quad \forall i \in \Omega_b; \quad (8)$$

$$\underline{I_{ij}} \leq I_{ij,d} \leq \overline{I_{ij}} \quad \forall ij \in \Omega_L; \quad (9)$$

$$\sum_{k=1}^{nb} n_k^{dg} \leq \overline{n^{dg}} \quad (10)$$

$$n_k^{dg} \in \{1, 0\} \quad (11)$$

such that kc capital recovery factor of distributed generation; nb is the number of buses; c_k is a constant representing the cost of installation; n_k^{dg} is a vector filled with binary values, which indicate the presence or absence of DG; T is the total time used by the system; r_k is a constant that represents the cost of maintenance of DG; k_e^d is the power cost parameter for each load level; nt is the number of system load profiles; P_k^{dg} is the active power installed by DG; T_d is the period for the load profile; $P_d^{loss} = I_{ij,d}^2 \cdot R_{ij}$ are the total active power losses for each period; P_i^S and Q_i^S are the active and reactive power injected by the substation, respectively; $P_{i,d}^D$ and $Q_{i,d}^D$ are the active and reactive power demands for bus i , at the load level d , respectively; $P_{ij,d}$ and $Q_{ij,d}$ are the active and reactive power flow, respectively; $I_{ij,d}^2 \cdot R_{ij}$ and $I_{ij,d}^2 \cdot X_{ij}$ are the active and reactive losses in the sector ij , respectively, as shown in Fig. 1 of $I_{ij,d}^2 \cdot \vec{Z}_{ij}$ (impedance), R_{ij} and X_{ij} are resistance and reactance of the branch ij ; P_{ki}^{dg} and Q_{ki}^{dg} are the active and reactive powers inserted by distributed generation; $\overline{P_i^S}$ and $\overline{Q_i^S}$ are the maximum acceptable values for active and reactive power entered by the substation, respectively, for all buses (Ω_b); $\overline{P_i^{dg}}$ and $\overline{Q_i^{dg}}$ are the maximum acceptable values for active and reactive power entered by DG, respectively, to Ω_b ; $V_{i,d}$ bus voltage i for charge level d ; \underline{V} and \overline{V} are the minimum and maximum acceptable values for Ω_b , respectively; $\underline{I_{ij}}$ and $\overline{I_{ij}}$ are the minimum and maximum acceptable values for the current in the whole set of lines respectively (Ω_L); $\overline{n^{dg}}$ is a constant representing the maximum number of DGs installed in the system.




Fig. 1. Simplified system representation.

The objective function shown in (1) contains two summations. The first, exposes the installation and maintenance costs of DGs. The second one represents the cost of losses for all system load levels.

In the proposed methodology, a penalization were applied in the objective function to avoid voltage and current violations, as shown in the following equations:

$$f'_o = \tau \sum_{d=0}^{nt} \gamma_d \cdot T_d \cdot P_d^{loss} + kc \cdot \sum_{k=1}^{nb} n_k^{dg} \cdot (c_k + r_k \cdot T \cdot P_k^{dg}) \quad (12)$$

Being τ the penalization factor, which must be a very high value (10^5 in this work, which will ensure that all unfeasible solutions are removed), γ_d is set to 0 if the voltages and currents, maximum and minimum values, in load level d , are not violating any limits and is set to 1 otherwise.

To calculate the losses, P_i^{loss} , the power flow solution method Backward-Forward Sweep [26] is used, which can calculate the losses for each load level.

The load levels represent the demand of the system for a period of time T_i , this paper considers three load profiles—high, medium and light.

The restrictions (2) and (3) represents the load balance, as shown in Fig. 1. These are frequently used in the method Backward-Forward Sweep load flow [8], representing the steady state operation of a radial distribution system.

Restrictions (4) and (5) express the limits of active and reactive power to the substation and restrictions (6) and (7) to DGs.

Restrictions (8) and (9) express the voltage and current limits to buses and lines of the system.

The restriction (10) presents the maximum, $\overline{n^{dg}}$, number of DGs to be inserted into the system.

The (11) constraint refers to the type of data contained in vector n_k^{dg} , 1 used to indicate the existence of a DG in a given bus and 0 for the absence of DG.

III. IMPROVED GENETIC ALGORITHM

In this work, to solve the non-linear problem, an Improved Genetic Algorithm (IGA) is used, that is based in the works of [27] and is a meta-heuristic technique.

[28] proposed that the traditional GA mimics the genetic evolution and biological selection of individuals behaviors in a computer programming format.

The following features are the difference between the IGA and the traditional GA [29]:

- there is a fitness and an unfitness function, which are used to identify the value of the objective function and quantify the feasibility of the tested solution, respectively;
- replaces only one individual in the population for each iteration and
- each individual goes through a local improvement strategy.

The flowchart shown in figure 2, presents the main steps of the IGA used in this work. The flowchart has the following steps: Setup the control parameters – size of the initial population (IPS), recombination rate (RR), mutation rate (MR), diversity rate (DR) and maximum number of iterations(N_{max})–

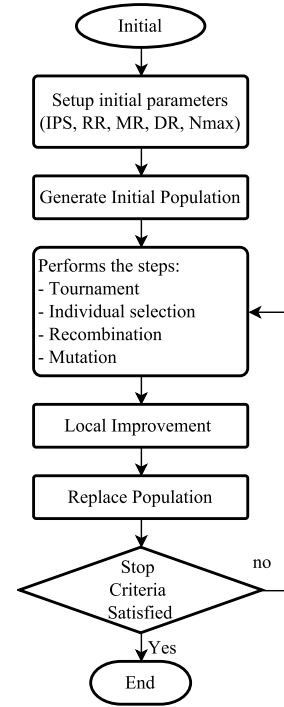


Fig. 2. Flowchart IGA.

creation of the initial population, tournament selection, recombination, mutation, local improvement, replacement and verification of the stop criteria.

Each step is described as follows:

A. Codification

The individual is represented by a vector with size equal to the number of buses in the system, as shown in Fig 3. The vector is filled in a binary form, where 1 is the point of allocation.




Fig. 3. Example encoding of an individual.

B. Initial population

The initial population is represented by a matrix $IPS \times nb$. The individuals in the population are randomly generated.

C. Selection

After the initial population is formed, selection is performed using the tournament method. In this method, two groups of potential parents are generated, each group will consist of k individuals randomly chosen within the current population. In each group the best individual is chosen, which has the best objective function. At the end of this process, two individuals are selected, named as parents, who are employed in the recombination step [30].

D. Recombination

The recombination method is the cut at a single point, chosen in random order, as shown in Figure 4. After carrying out the recombination, descendants are generated and each one inherits characteristics of both parents. In the proposed IGA, only one of the descendants can proceed to the next step, the chosen is the one with a lower objective function of value.

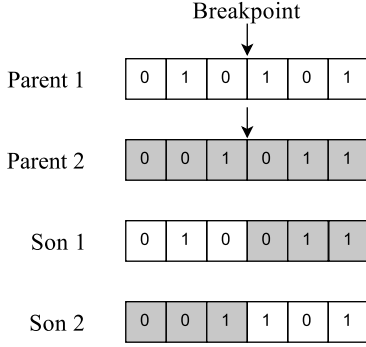


Fig. 4. An example of a recombining step.

E. Mutation

According to the mutation rate, individual points are selected at random to change their state, as seen in figure 5.




Fig. 5. Example of a mutation step.

F. Local improvement

The local improvement step can be divided into two processes.

- In the first step, the number of allocated DGs is verified, if this value is superior to a maximum allowed number, a combinatory analysis is performed with the allocated DGs and the combination with a lower objective function remains.
- A neighborhood search is performed, consisting of a search in the buses near of DG allocation point, in order to improve the response of the objective function. If this goal is achieved the individual is modified, otherwise, the DG remains in the original bus.

G. Replacement

After the local improvement stage, the generated individual enters the current population if it satisfies the following conditions: it is not within the current population and have a better objective function than the worst individual of the current population. Otherwise, the individual will be discarded.

H. Stop criteria

If the best solution does not change in a range of N iterations the algorithm is said convergent and the best individual of the current population is exposed. If N_{max} is reached before the algorithm converges the program stops.

IV. RESULTS

The proposed methodology was tested in two radial distribution systems: 34 buses [31], 70 buses [32] and 136 buses [33].

The algorithm was implemented in C++, using a computer with a processor *Core^(TM) i5 - 3210M*, 2.50 GHz.

The proposed methodology is validated by comparing its results with the ones of an exhaustive search algorithm. This exhaustive search method avails all possible solutions to the problem, one by one, in order to obtain the optimal solution. To implement the exhaustive search algorithm, the MATLAB package MATPOWER [34] was employed to calculate load flows and determine losses for every DGs allocation combination.

The cost used in all systems is: cost of installation $c_k = 150k\$/MW$ and maintenance cost $r_k = 0.5\$/MVAh$.

A. System 34 buses

In Figure 6, the 34 buses system topology is shown, the total load is $S = 4.636 MW + j2.885 MVar$.




Fig. 6. Line diagram of the radial system with 34 buses.

The parameters used by the IGA are presented in Table I.

TABLE I
PARAMETERS TO THE IGA.

Feature	Used values
Initial Population(IPS)	60 individuals
Mutation Rate(MR)	0.05%
Diversity Rate(DR)	1%

The parameters for this system are: energy cost $k_e = 0.06$ $\$/kWh$, to all load level. The maximum and minimum values adopted for system voltages are respectively 1.05 to 0.93 per unit (p.u.). Load levels are considered $S_0 = 1.1$ (high), $S_1 = 0.8$ (average) and $S_2 = 0.6$ (light). Each charge level has

a distinct duration $T_0 = 1000h$, $T_1 = 6760h$ and $T_2 = 1000h$. For this system, the allocation of a DG with 1.0MW is proposed, with power factor 0.95, inductive, considering a period of 20 years.

The initial cost without allocation of DG, relative to system losses, is \$ 1550005.75. Table II refers to losses – active and reactive – and minimum voltage levels for each load level for the system without allocation of DG.

TABLE II

INITIAL SOLUTION TO THE SYSTEM WITH 34 BUSES (WITHOUT DGs). WHERE 1 IS HIGH, 2 IS AVERAGE AND 3 IS LIGHT, LOAD CONDITIONS.

	Power			Voltage
	Load Level	Active (kW)	Reactive (kVar)	Minimum (p.u.)
1	1.10	271.64	79.75	0.9356
2	0.80	139.50	40.98	0.9539
3	0.60	77.00	22.63	0.9658
Total:	488.14	143.35	-	-

The program was tested with stopping criteria N . Table VIII shows the variation of its response accordingly to N iterations, comparing the time and results found by the exhaustive method against the proposed method.

TABLE III

COMPARISON BETWEEN THE COMPUTATIONAL TERMS AND THE ANSWER OBTAINED BY THE EXHAUSTIVE METHOD AND THE PROPOSED IGA.

	Stop criteria (Iterations)	1 DG		2 DGs	
		Time (s)	Bus	Time (s)	Buses
Exhaustive search	-	7.499	23	65.423	7/23
	15	0.024	23	0.028	7/23
	50	0.070	23	0.082	7/23
	100	0.102	23	0.156	7/23
Proposed	150	0.138	23	0.210	7/23

Analyzing the data from table VIII, note that increasing the number of iterations only increase the computational cost without changing the end result, for this reason, $N = 15$ has been used to get the results that follows. Thus, computing times of the proposed method are lower, independent of the criteria.

In tables IV and V, it is possible to verify the results for one and two DGs, respectively, where the total cost of each possibility was 1260272.87, for one DG, and 1249503.50 for two DGs.

TABLE IV

34 BUSES SYSTEM, CONSIDERING ONLY ONE DG ALLOCATION.

	Power			Voltage
	Load Level	Active (kW)	Reactive (kVar)	Minimum (p.u.)
1	1.10	202.85	59.91	0.9558
2	0.80	98.88	28.95	0.9736
3	0.60	53.55	15.36	0.9816
Total:	355.28	104.22	-	-

One DG installation provided a reduction in 18.69 % of the total costs and a reduction of 27.22 % in active power losses.

TABLE V

34 BUSES SYSTEM, CONSIDERING TWO DG ALLOCATION.

	Power			Voltage
	Load Level	Active (kW)	Reactive (kVar)	Minimum (p.u.)
1	1.10	172.02	50.59	0.9613
2	0.80	84.29	24.46	0.9788
3	0.60	49.04	13.86	0.9895
Total:	305.34	88.91	-	-

Two DGs installation resulted in a total cost reduction of 19.39 % and a 37.45 % reduction in active power losses. Thus, in the long run, a greater number of DGs will provide better results to this system.

B. System 70 buses

In Figure 7, the 70 buses system topology is shown, the total load is $S = 3.80 \text{ MW} + j2.70 \text{ MVar}$.

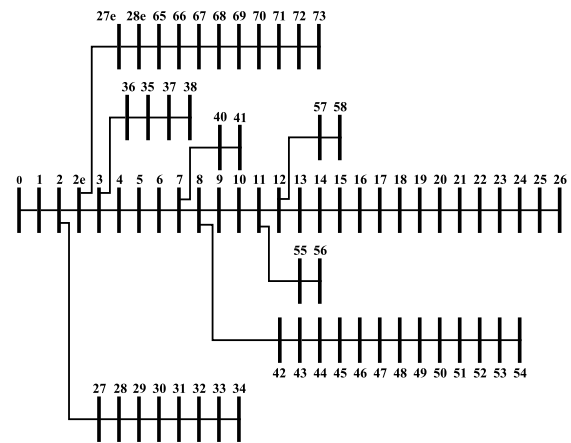


Fig. 7. Line diagram of the radial system with 70 buses.

The parameters used by the IGA are presented in Table VI.

TABLE VI

PARAMETERS TO THE IGA.

Feature	Used values
Initial Population(IPS)	40 individuals
Mutation Rate(MR)	5%
Diversity Rate(DR)	1%

The parameters of this system are: energy cost $k_e^0 = 0.7$ \$/kWh, $k_e^1 = 1.78$ \$/kWh and $k_e^2 = 2.95$ \$/kWh, for each load level. The maximum and minimum values adopted for system voltages are respectively 1.05 to 0.90 per unit (p.u.). Load levels are considered $S_0 = 1.0$ (high), $S_1 = 0.8$ (average) and $S_2 = 0.5$ (light). Each charge level has a distinct duration $T_0 = 1000h$, $T_1 = 6760h$ and $T_2 = 1000h$. For this system it is proposed to allocate only one DG of 1MW, with power factor 0.95, inductive, with the stopping criteria of $N = 20$ iterations.

The initial cost without allocation of DG, relative to system losses, is \$39625968.00. Table VII refers to losses – active

and reactive – and minimum voltage levels for each load level for the system without allocation of DG.

TABLE VII

INITIAL SOLUTION TO THE SYSTEM WITH 70 BUSES (WITHOUT DGs). WHERE 1 IS HIGH, 2 IS AVERAGE AND 3 IS LIGHT, LOAD CONDITIONS.

	Power			Voltage
	Load Level	Active (kW)	Reactive (kVar)	Minimum (p.u.)
1	1.00	225.02	102.18	0.9092
2	0.80	138.91	63.21	0.9288
3	0.50	51.61	23.56	0.9567
Total:	415.54	188.95	-	-

The program was tested with stopping criteria N . Table VIII shows the variation of its response accordingly to N iterations, comparing the time and results found by the exhaustive method against the proposed method.

TABLE VIII

COMPARISON BETWEEN THE COMPUTATIONAL TERMS AND THE ANSWER OBTAINED BY THE EXHAUSTIVE METHOD AND THE PROPOSED IGA.

	Stop criteria (Iterations)	1 DG		3 DGs	
		Time (s)	Bus	Time (s)	Buses
Exhaustive	-	11.222	50	6712.66	277/50
	20	0.156	50	0.337	277/50
Proposed	100	0.531	50	4.203	277/50
	500	3.02	50	18.545	277/50
	1000	7.111	50	39.336	277/50

Note that, to this system, more iterations are needed to achieve the optimal solution with the proposed algorithm, however, the computation times were lower than those from the exhaustive search method.

Analyzing the data from table VIII, observe that increasing the number of iterations only increase the computational cost without changing the end result, for this reason, $N = 15$ has been used to get the results that follow. Thus, computing times of the proposed method are lower, independent of the criteria.

In tables IX and X, it is possible to verify the results for one and three DGs, respectively, where the total cost of each possibility was 2642252.00, for one DG, and 26707760.00 for three DGs.

TABLE IX

70 BUSES SYSTEM, CONSIDERING ONLY ONE DG ALLOCATION.

	Power			Voltage
	Load Level	Active (kW)	Reactive (kVar)	Minimum (p.u.)
1	1.00	149.18	69.55	0.9422
2	0.80	90.86	42.37	0.9606
3	0.50	39.29	17.88	0.9837
Total:	279.33	129.79	-	-

One DG installation provided a reduction in 33.32 % of the total costs and a reduction of 32.60 % in active power losses.

Three DGs installation resulted in a total cost reduction of 32.77 % and a 33.17 % reduction in active power losses. Thus,

TABLE X

70 BUSES SYSTEM, CONSIDERING THREE DG ALLOCATION.

	Power			Voltage
	Load Level	Active (kW)	Reactive (kVar)	Minimum (p.u.)
1	1.00	142.45	66.06	0.9470
2	0.80	89.65	41.77	0.9653
3	0.50	45.57	21.25	0.9882
Total:	277.67	129.08	-	-

in the long run, the allocation of three DG will provide better results to this system.

C. System 136 buses

The parameters for this system are: energy cost $k_e = 0.06$ \$/kWh, to all load level, the cost of installation $c_k = 150k$ \$/MW and maintenance cost $r_k = 0.5$ \$/MVAh. The maximum and minimum values adopted for system voltages are respectively 1.05 to 0.90 per unit (p.u.). Load levels are considered $S_0 = 1.8$ (high), $S_1 = 1.0$ (average) and $S_2 = 0.5$ (light). Each charge level has a distinct duration $T_0 = 1000h$, $T_1 = 6760h$ and $T_2 = 1000h$. For this system is proposed to allocate only one DG with 2MW, power factor 0.95, capacitive, with the stopping criteria of $N = 100$ iterations, considering a period of 20 years. Total load of the system is $S = 18,31$ MW + $j.7.93$ MVar.

The parameters used in the IGA are presented in Table XI.

TABLE XI

PARAMETERS TO THE IGA.

Feature	Used values
Initial Population(IPS)	100 individuals
Mutation Rate(MR)	2%
Diversity Rate(DR)	1%

The initial cost without allocation of DG, relative to system losses, is \$ 3974710.75 DG. The table XII refers to the loss –active and reactive– and minimum voltage levels for each load level of the system without an DG allocation.

TABLE XII

SYSTEM WITH 136 BUSES WITHOUT THE ALLOCATION OF DG. WHERE 1 IS HIGH, 2 IS AVERAGE AND 3 IS LIGHT, LOAD CONDITIONS

	Power			Voltage
	Load Level	Active (kW)	Reactive (kVar)	Minimum (p.u.)
1	1.8	1084.11	2378.73	0.8985
2	1.0	318.23	708.18	0.9388
3	0.5	76.91	168.72	0.9686
Total:	1479.25	3245.62	-	-

The program was tested with stopping criteria N . Table XIII shows the results for a variation of the stop criteria in order to verify the variation of the response accordingly to N .

Analyzing the data from table XIII, it is noted that increasing the number of iterations only increase the computational cost without changing the end result, for this reason $N = 50$ has been used to produce the results that follow.

TABLE XIII

RESULT, COMPUTATIONAL TIME AND NUMBER OF ITERATIONS FOR DIFFERENT STOPPING CRITERIA.

Stop Criteria (N)	Time(s)	Iterations	DG buses	
50	1.828	55	12	155
100	4.337	113	12	155
2000	37.986	1036	12	155
2000	59.150	2027	12	155
5000	167.016	5025	12	155

After using the IGA for the allocation of DGs, the best positions found were in bus 12 and 155 with a total cost of \$ 3713878.25, being \$ 668842.06 the cost of implementation and maintenance, and the cost of active losses as \$ 3045036.25, so the cost of implementation is only 18% of the total cost.

In the Table XIV the active and reactive losses are presented, along with the minimum voltage levels for each load level, considering the allocation of DGs in buses 12 and 155.

TABLE XIV

SYSTEM WITH 136 BUSES CONSIDERING THE ALLOCATION OF DGs.

	Power			Voltage
	Load Level	Active (kW)	Reactive (kVar)	Minimum (p.u.)
1	1.8	867.34	1884.44	0.8833
2	1.0	236.05	509.78	0.9379
3	0.5	74.47	161.16	0.9735
Total:		1177.86	2555.37	-

Comparing the results of Table XII with Table XIV, there is a reduction in total 20.37 % active losses and 21.27 % in total reactive losses. In this system the improvement in the voltage profile is barely noticeable, since the reactive power injection, which is the primary responsible for the improvement in the voltage profile, is insignificant to the system.

V. CONCLUSION

In this paper, a mathematical model for optimal allocation of distributed generators in radial distribution systems was proposed. This mixed integer linear problem is solved using a meta-heuristic technique named as improved genetic algorithm (IGA). The results are validated through a comparison with an exhaustive search algorithm.

The mathematical model combined with the meta-heuristics techniques, discovered of high-quality solutions that also have a good computational performance for small, medium and large electrical energy systems, when compared with the exhaustive search algorithm.

With the obtained results, it was demonstrated that the allocation of DGs reduces the overall system losses. Also, an improvement of the voltage profile was observed for each load level considered.

ACKNOWLEDGMENT

The authors would like to thank CNPQ and Capes for the financial support.

REFERENCES

- [1] S. Dunn, "Micropower: The next electrical era," *Worldwatch Paper*, no. 151, pp. 1–94, 2000.
- [2] M. M. Severino, I. Marques, and D. T. Camargo, "Geração Distribuída : Discussão Conceitual E Nova Definição," vol. 14, no. 61, pp. 47–69, 2008.
- [3] INEE., "Instituto nacional de eficiência energética," May 2016. [Online]. Available: http://www.inee.org.br/forum_sobre_gd_cg.asp?Cat=gd
- [4] N. Acharya, P. Mahat, and N. Mithulananthan, "An analytical approach for DG allocation in primary distribution network," *International Journal of Electrical Power and Energy Systems*, vol. 28, no. 10, pp. 669–678, 2006.
- [5] T. Gözel and M. H. Hocaoglu, "An analytical method for the sizing and siting of distributed generators in radial systems," *Electric Power Systems Research*, vol. 79, no. 6, pp. 912–918, 2009.
- [6] D. Q. Hung and N. Mithulananthan, "Multiple distributed generator placement in primary distribution networks for loss reduction," *IEEE Transactions on Industrial Electronics*, vol. 60, no. 4, pp. 1700–1708, 2013.
- [7] R. Viral and D. K. Khatod, "An analytical approach for sizing and siting of DGs in balanced radial distribution networks for loss minimization," *International Journal of Electrical Power and Energy Systems*, vol. 67, pp. 191–201, 2015. [Online]. Available: <http://dx.doi.org/10.1016/j.ijepes.2014.11.017>
- [8] A. C. Rueda-Medina, J. F. Franco, M. J. Rider, A. Padilha-Feltrin, and R. Romero, "A mixed-integer linear programming approach for optimal type, size and allocation of distributed generation in radial distribution systems," *Electric Power Systems Research*, vol. 97, pp. 133–143, apr 2013.
- [9] R. S. Al Abri, E. F. El-Saadany, and Y. M. Atwa, "Optimal placement and sizing method to improve the voltage stability margin in a distribution system using distributed generation," *Power Systems, IEEE Transactions on*, vol. 28, no. 1, pp. 326–334, 2013.
- [10] N. Khalesi, N. Rezaei, and M. R. Haghifam, "DG allocation with application of dynamic programming for loss reduction and reliability improvement," *International Journal of Electrical Power and Energy Systems*, vol. 33, no. 2, pp. 288–295, 2011.
- [11] D. Zhu, R. P. Broadwater, K. S. Tam, R. Seguin, and H. Asgerisson, "Impact of DG placement on reliability and efficiency with time-varying loads," *IEEE Transactions on Power Systems*, vol. 21, no. 1, pp. 419–427, 2006.
- [12] L. F. Ochoa, A. Padilha-Feltrin, and G. P. Harrison, "Time-series-based maximization of distributed wind power generation integration," *IEEE Transactions on Energy Conversion*, vol. 23, no. 3, pp. 968–974, 2008.
- [13] J. M. López-Lezama, J. Contreras, and A. Padilha-Feltrin, "Location and contract pricing of distributed generation using a genetic algorithm," *International Journal of Electrical Power & Energy Systems*, vol. 36, no. 10, pp. 117–126, 2012.
- [14] M. F. Shaaban, Y. M. Atwa, and E. F. El-Saadany, "DG allocation for benefit maximization in distribution networks," *IEEE Transactions on Power Systems*, vol. 28, no. 2, pp. 939–949, 2013.
- [15] Kyu-Ho Kim, Yu-Jeong Lee, Sang-Bong Rhee, Sang-Kuen Lee, and Seok-Ku You, "Dispersed Generator Placement using Fuzzy-GA in Distribution Systems," *IEEE Power Engineering Society Summer Meeting*, vol. 3, pp. 1148–1153, 2002.
- [16] W. Moreti, "a Fast Solver for Distributed Generation Allocation Problem Using Genetic Algorithm of Chu-Beasley and Sensibility Analysis," *XLVI Simpósio Brasileiro de Pesquisa Operacional*, pp. 1003–1014, 2014.
- [17] G. Celli, E. Ghiani, S. Mocci, and F. Pilo, "A multiobjective evolutionary algorithm for the sizing and siting of distributed generation," *IEEE Transactions on Power Systems*, vol. 20, no. 2, pp. 750–757, 2005.
- [18] V. Ravikumar Pandi, H. H. Zeineldin, and W. Xiao, "Determining optimal location and size of distributed generation resources considering harmonic and protection coordination limits," *IEEE Transactions on Power Systems*, vol. 28, no. 2, pp. 1245–1254, 2013.
- [19] S. Devi and M. Geethanjali, "Application of Modified Bacterial Foraging Optimization algorithm for optimal placement and sizing of Distributed Generation," *Expert Systems with Applications*, vol. 41, no. 6, pp. 2772–2781, 2014.
- [20] M. M. Othman, Y. G. Hegazy, and A. Y. Abdelaziz, "A Modified Firefly Algorithm for Optimal Sizing and Siting of Voltage Controlled Distributed Generators in Distribution Networks," *Periodica Polytechnica*

Electrical Engineering and Computer Science, vol. 59, no. 3, pp. 104–109, 2015.

- [21] H. Hedayati, S. A. Nabaviniaki, and A. Akbarimajd, "A new method for placement of DG units in distribution networks," *2006 IEEE PES Power Systems Conference and Exposition, PSCE 2006 - Proceedings*, vol. 23, no. 3, pp. 1904–1909, 2006.
- [22] H. M. Khodr, M. R. Silva, Z. Vale, and C. Ramos, "A probabilistic methodology for distributed generation location in isolated electrical service area," *Electric Power Systems Research*, vol. 80, no. 4, pp. 390–399, 2010.
- [23] B. Banerjee and S. M. Islam, "Reliability based optimum location of distributed generation," *International Journal of Electrical Power and Energy Systems*, vol. 33, no. 8, pp. 1470–1478, 2011.
- [24] H. Hamed and M. Gandomkar, "A straightforward approach to minimizing unsupplied energy and power loss through DG placement and evaluating power quality in relation to load variations over time," *International Journal of Electrical Power and Energy Systems*, vol. 35, no. 1, pp. 93–96, 2012.
- [25] A. A. Tamimi, A. Pahwa, and S. Starrett, "Effective wind farm sizing method for weak power systems using critical modes of voltage instability," *IEEE Transactions on Power Systems*, vol. 27, no. 3, pp. 1610–1617, 2012.
- [26] D. Shirmohammadi, H. W. Hong, a. Semlyen, and G. X. Luo, "Compensation-based power flow method for weakly meshed distribution and transmission networks," *IEEE Transactions on Power Systems*, vol. 3, no. 2, pp. 753–762, 1988.
- [27] P. C. Chu and J. E. Beasley, "A genetic algorithm for the generalised assignment problem," *Journal of the Operational Research Society*, vol. 48, no. 8, pp. 804–809, 1997.
- [28] J. H. Holland, *Adaptation in Natural and Artificial Systems*. The University of Michigan Press, 1975.
- [29] L. Garces and R. Romero, "Specialized Genetic Algorithm for Transmission Network Expansion Planning Considering Reliability," *Intelligent System Applications to Power Systems, 2009. ISAP '09. 15th International Conference on*, pp. 1–6, 2009.
- [30] L. a. Gallego, S. Member, M. J. Rider, R. Romero, and A. V. Garcia, "A Specialized Genetic Algorithm to Solve the Short Term Transmission Network Expansion Planning," *PowerTech, 2009 IEEE Bucharest*, no. 5, pp. 1–7, 2009.
- [31] M. M. a. Salama, "Capacitor Placement in Distribution System using Heuristic Search Strategies," *IEE Proc-Gener. Transm. Distrib.*, vol. 144, no. 3, pp. 225–230, 1997.
- [32] M. Baran and F. Wu, "Optimal capacitor placement on radial distribution systems," *IEEE Transactions on Power Delivery*, vol. 4, no. 1, pp. 725–734, 1989.
- [33] M. Guimaraes and C. Castro, "An Efficient Method for Distribution Systems Reconfiguration and Capacitor Placement using a Chu-Beasley Based Genetic Algorithm," *IEEE Trondheim PowerTech*, pp. 1–7, 2011.
- [34] R. D. Zimmerman, C. E. Murillo-Sanchez, and R. J. Thomas, "Matpower's extensible optimal power flow architecture," July 2009, pp. 1–7.

Algoritmo genético melhorado para o redimensionamento ótimo de cabos primários em sistemas de distribuição de energia elétrica

Camila Maria Galo da Silva, Karina Yamashita, Luis Alfonso Gallego Pareja

Universidade Estadual de Londrina

Engenharia Elétrica

Londrina, Paraná (43) 3371-5879

Emails: camilamgalo@gmail.com, karina.hoshi@gmail.com, gallegopareja@gmail.com

Abstract— This work is proposed a methodology to solve the resizing problem of the great conductors in systems power distribution. The methodology is based at the ideas of improved genetic algorithm. The problem to be solved in this work is formulated as matter of nonlinear mixed integer programming, because have the presence of integer variables wich represent the position of the gauge to be substituted, and the continuous wich indicate the eletrical system variables (voltage, current, power flow, active power losses and reactive power losses). The objective is to minimize the cost of system losses. To test the methodology systems with 27, 23 and 70 bars were employed.

I. INTRODUÇÃO

Oferecer qualidade no fornecimento de energia elétrica aos consumidores têm-se tornado uma necessidade, devido ao aumento da demanda de consumo. Para esse fim, são desenvolvidas ferramentas, programas computacionais, para a expansão dos sistemas de distribuição de energia elétrica (SDEE) de maneira econômica [1]. Neste sentido, é realizado a implementação da técnica de redimensionamento de condutores, cuja finalidade consiste na alteração do calibre das linhas, buscando minimizar o custo dos condutores empregados na troca, assim como as perdas elétricas dos SDEE, e respeitando as restrições operativas da rede elétrica.

Uma vez que, os condutores elétricos cooperam com as perdas técnicas nos sistemas operacionais, se faz necessário estudar os efeitos dos parâmetros que caracterizam os condutores elétricos tanto no aspecto elétrico como no econômico, como exposto em [2], no qual, analisa um modelo matemático para a correta seleção dos cabos.

A seleção dos condutores elétricos possui uma ampla bibliografia na literatura especializada, com diferentes abordagens. No trabalho de [3] é apresentado um método para a seleção dos condutores, levando em consideração as características de custo de instalação, manutenção e das perdas com o objetivo de buscar uma solução mais econômica. Simulações foram realizadas em diferentes cenários, analisando-se valores como custo de energia, custo de instalação, operação para chegar a uma solução mais eficiente, como uma análise aprofundada de um conjunto de condutores.

No trabalho de [4] a seleção dos condutores ideais e o dimensionamento de bancos de capacitores em redes de distri-

buição radial foram implementados através de um algoritmo genético (AG) apresentando uma função objetivo que busca minimizar o custo total da alocação de capacitores e seleção dos condutores e das perdas técnicas, através de restrições de tensão, corrente máxima admissível pelos condutores. Para demonstrar a eficiência do método é utilizado um sistema de 27 barras, cujos resultados mostram que as tensões nas barras estão nos limites permitidos.

No trabalho de [5] é proposto um algoritmo eficiente para a seleção ótima dos condutores em SDEE. Inicialmente, foi utilizado um fluxo de carga para o cálculo de tensões e correntes. A função objetivo foi definida com base no custo dos condutores, do perfil de tensão e da capacidade de corrente nos condutores. O algoritmo desenvolvido no software MATLAB foi testado em um sistema de 27 barras, apresentando resultados satisfatórios para a otimização das redes de distribuição.

No trabalho apresentado por [6] o algoritmo genético de Chu-Beasley é utilizado no planejamento de expansão de rede de transmissão, buscando uma solução mais eficiente visando as restrições de segurança. O algoritmo utilizado foi testado em três sistemas de energia.

Este artigo tem como objetivo propor um modelamento matemático para o redimensionamento de condutores, através da análise de variáveis que caracterizam a minimização das perdas técnicas, considerando os custos de instalação dos cabos. Na presença desse modelo têm-se a otimização da solução por meio do algoritmo genético melhorado exposto no trabalho de [7].

Este artigo está dividido em cinco seções. Na seção 2 é definido o modelo matemático para o redimensionamento de condutores. Na Seção 3 é apresentada os principais passos do algoritmo genético empregado. Na Seção 4 são apresentados os resultados obtido pelo algoritmo genético para a rede de distribuição testada, e finalmente na seção 5 são apresentadas as principais conclusões deste trabalho.

II. MODELAMENTO MATEMÁTICO

O redimensionamento de condutores é um problema de ordem não linear inteiro misto, pois têm-se a presença de va-

riáveis inteiras que representam a posição da troca do calibre, e as contínuas que indicam as variáveis do sistema elétrico (tensões, correntes, fluxo de potência, perdas de potência ativa e perdas de potência reativa). Dessa maneira, o problema pode ser formulado encontrando um valor mínimo da função objetivo, como apresentado:

$$\text{Min } F.O. = \sum_{i=1}^{nl} (C_i^{red} \cdot n_i^{red}) + \sum_{i=1}^{nc} K \cdot T_d \cdot P_d^{perdas} \quad (1)$$

s.a.

$$\sum_{i=1}^{nl} P_i^g - P_j^d - \sum_{ij \in \Omega_l} (P_{ij,d} + I_{ij}^2 R_{ij}) = 0 \quad (2)$$

$$\sum_{i=1}^{nl} Q_i^g - Q_j^d - \sum_{ij \in \Omega_l} (Q_{ij,d} + I_{ij}^2 X_{ij}) = 0 \quad (3)$$

$$0 \leq P_i^S \leq \overline{P_i^S} \quad \forall i \in \Omega_b \quad (4)$$

$$0 \leq Q_i^S \leq \overline{Q_i^S} \quad \forall i \in \Omega_b \quad (5)$$

$$\underline{I_{ij}} \leq I_{ij} \leq \overline{I_{ij}} \quad \forall i \in \Omega_l \quad (6)$$

$$\underline{V_{ij}} \leq V_i \leq \overline{V_{ij}} \quad \forall i \in \Omega_b \quad (7)$$

Sendo nl o número de linhas; nc é o número de nível de carga; nb é o número de barras; C_i^{red} é a constante que representa o custo de instalação dos condutores; n_i^{red} é o vetor constituído por valores binários indicando os ramos candidatos para a troca de condutores; K é o parâmetro de custo de energia para cada nível de carga; nt é o número de perfis de carga do sistema; T_d é o período de tempo para a carga; $P_d^{perdas} = I_{ij,d}^2 \cdot R_{ij}$ são as perdas de potência ativa totais para um determinado período de tempo; P_i^S é a potência ativa inserida pela subestação; Q_i^S é a representação da potência reativa inserida pela subestação; $P_{ij,d}$ é o fluxo de potência ativo no ramo ij ; $Q_{ij,d}$ é o fluxo de potência reativo no ramo ij ; X_{ij} é a reatância no ramo ij ; R_{ij} é a resistência no ramo ij ; $I_{ij}^2 X_{ij}$ é a perda reativa no ramo ij ; $I_{ij}^2 R_{ij}$ é a perda ativa no ramo ij ; $\overline{Q_i^S}$ e $\overline{P_i^S}$ são as representações dos valores máximos aceitáveis de potência reativa e ativa, respectivamente. V_i^{min} e V_i^{max} são os valores mínimos e máximos aceitáveis para a tensão no conjunto de linhas; $\underline{I_{ij}}$ e $\overline{I_{ij}}$ são os valores mínimos e máximos aceitáveis para a corrente no conjunto de linhas; $\overline{n_i^{red}}$ é o número máximo de condutores presentes no sistema.

Na equação 1 têm-se a função objetivo da técnica de redimensionamento, o primeiro somatório é destinado aos custos de investimentos da troca dos condutores, enquanto que o segundo somatório institui o custo das perdas do sistema de distribuição de energia elétrica.

Para se determinar o estado operativo atual da rede elétrica, (magnitudes de tensões, correntes, perdas, fluxos nas linhas)

foi desenvolvido um fluxo de potência por meio do método *Backward - Forward Sweep* proposto em [8].

As restrições das equações 2 e 3 são as equações de balanço de potência nas barras e calculada a partir de um fluxo de potência.

As restrições 4 e 5 se referem as potências ativas e reativas injetadas pela subestação.

As restrições 6 e 7 correspondem as restrições de correntes de linhas e tensões nas barras da rede operacional.

III. ALGORITMO GENÉTICO MELHORADO

Os algoritmos genéticos são ferramentas computacionais baseados nas ideias fundamentais da evolução das espécies, para solucionar, otimizar diversos problemas da vida real [9], como pode ser observado em [10], [11], [12]. O algoritmo genético proposto neste trabalho diferencia do algoritmo proposto por [9] de acordo com as seguintes condições apresentadas em [13]: 1) propõe soluções para problema de ordem não-linear através de algumas características peculiares. 2) utilização de uma função de aptidão e inaptidão para avaliar a solução encontrada.

No fluxograma 1, são representadas as principais características do algoritmo genético.

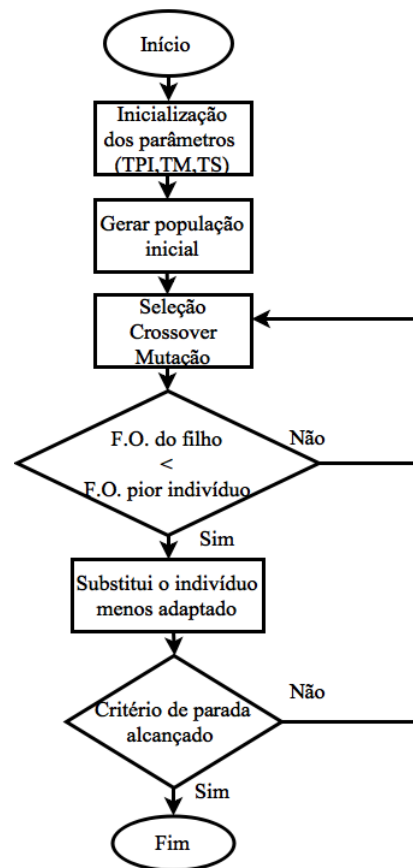


Fig. 1. Fluxograma representativo do AGM.

As etapas são mostradas a seguir: codificação do problema, geração da população inicial, recombinação, mutação, seleção

e teste de convergência. Inicialmente temos a inicialização dos parâmetros que são representados pelo tamanho da população inicial (TPI), taxa de mutação (TM), taxa de seleção (TS). Em seguida, tem a geração da população inicial através de torneio, seleção, recombinação e mutação. Caso a F.O. do filho for menor que a F.O. do pior indivíduo há a substituição do indivíduo menos adaptado dentro da população, se o critério de parada for alcançado têm-se a finalização do AGM.

A. Função Objetivo

A restrição para a solução do problema abordado é dada através de comparações entre diferentes graus de adaptação, pois para cada indivíduo-membro é atribuído um índice que indica o seu grau de adequação ao meio, além de restrições como os limites de tensão e corrente que devem ser respeitados.

Cada indivíduo da população possui uma função objetivo que representa o custo total da troca do condutor existente no ramo (redimensionamento). Neste trabalho é apresentado a formulação matemática referente a equação 1, dependente das perdas do sistema assim como o nível de carga.

Deve-se constatar que quanto menor o valor da F.O. conseqüentemente menor será o custo na implantação da técnica de redimensionamento.

B. Codificação do Problema

No redimensionamento de condutores, o indivíduo deve ser representado por um vetor de tamanho de nl posições.

Na Figura 2, cada posição do vetor representa uma linha do sistema e o valor armazenado em cada uma representa o tipo de condutor que deverá ser utilizado para a técnica de redimensionamento.




Fig. 2. Exemplo de codificação.

C. População Inicial

A população inicial é representada por uma matriz $TPI \times nb$. Nessa etapa, cada indivíduo da população é gerado de forma aleatória.

D. Seleção

Neste artigo será utilizado a seleção por torneio. Neste caso são escolhidos K_s indivíduos da população inicial de forma aleatória para competir entre eles, sendo que o melhor indivíduo (melhor resposta da função objetivo) será utilizado como o pai escolhido. Este procedimento é realizado duas vezes. Ao final temos dois pais para realizar o seguinte passo do AGM como apresentado por [14].

E. Recombinação

Nesse procedimento, forma-se novos indivíduos através da partilha de características genéticas, como observado na Figura 3.

Utilizando os pais selecionados anteriormente se escolhe de forma aleatória um ponto de quebra para a geração dos filhos, que recebem características advindas dos pais. Somente o filho com a melhor resposta para a função objetivo irá prosseguir no processo.

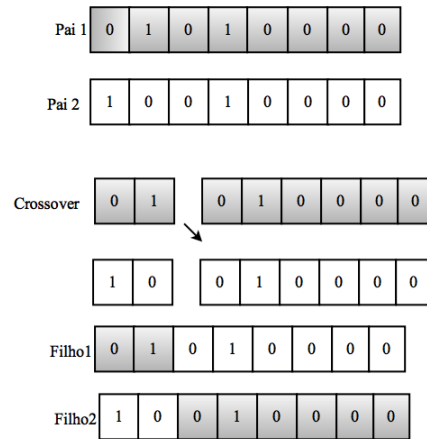


Fig. 3. Exemplificação da troca de informação.

F. Mutação

Nesta etapa, têm-se a modificação das características do indivíduo através de pontos sorteados de forma aleatória e de acordo com a taxa de mutação utilizada, visto que, novos atributos são concedidos a esse indivíduo. O processo pode ser observado na figura 4.




Fig. 4. Pontos de mutação.

G. Substituição

A etapa da substituição se caracteriza pela inserção do indivíduo gerado na população, se esse apresenta uma melhor função objetivo comparada com a do pior indivíduo, caso contrário, esse indivíduo deverá ser eliminado.

H. Critério de Parada

Se após um intervalo de N iterações a solução encontrada não se modificar, o algoritmo fornecerá como resposta o melhor indivíduo da população em análise. O programa apenas irá parar se um número máximo de iterações for alcançado antes do algoritmo convergir.

IV. RESULTADOS

Todos os algoritmos elaborados neste trabalho foram implementados na linguagem de programação C++, e executados em um computador pessoal *Core^(TM) i3-3110M* de 2,40 GHz.

A. Sistema 27 barras

A metodologia proposta foi testada em um sistema de 27 barras. Os dados elétricos do sistema foram retirados de [4].

Os parâmetros utilizados no desenvolvimento do algoritmo genético melhorado estão expostos na tabela I.

TABELA I

PARÂMETROS UTILIZADOS NO AGM PARA O SISTEMA DE 27 BARRAS.

Parâmetros	Valores
Tamanho da População Inicial	40
Taxa de Mutação	5%
Taxa de Seleção	1%
Número Máximo de Iterações	10000

Na figura 5 é apresentada uma topologia do sistema de distribuição de energia de 27 barras. A carga total do sistema é equivalente a: 4255,32 kW + j2716,91 kVar. O custo de energia k utilizado é 0,06 \$/kWh.




Fig. 5. Diagrama unifilar do sistema radial de 27 barras.

Para a resolução do problema de redimensionamento de condutores é proposto cinco diferentes tipos de condutores, como mostrado na tabela II. Nesta tabela, têm-se também a descrição dos custos e correntes elétricas dos condutores, retirados de [5].

TABELA II

CARACTERÍSTICAS ELÉTRICAS DOS CONDUTORES PARA O SISTEMA DE 27 BARRAS.

Condutor Elétrico	Resistência $\left[\frac{\Omega}{Km}\right]$	Reatância $\left[\frac{\Omega}{Km}\right]$	Custo $\left[\frac{\$}{Km}\right]$	Corrente Máxima [A]
1	0,7822	0,2835	31	150
2	0,4545	0,2664	48	212
3	0,2733	0,2506	70	288
4	0,2712	0,2664	81	308
5	0,1576	0,2277	151	400

O custo total inicial do sistema é igual a \$1.784.714.240,00. As perdas iniciais apresentadas pelo sistema foram 33,955 kW.

Através da utilização da técnica do redimensionamento de condutores foi proposto uma alocação ótima cujo valor das perdas são equivalentes a 14,851 kW, apresentando dessa forma, uma redução de aproximadamente 56,26%. O novo custo total foi de \$780.608.768,00, representando uma redução de aproximadamente 56,26%. O algoritmo encontrou a solução ótima em um tempo equivalente a 0,4480 segundos.

A característica de convergência da metodologia adotada pode ser visto na figura 6.




Fig. 6. Característica de convergência para o sistema de 27 barras.

Para a validação dos resultados, o sistema de distribuição de 27 barras foi executado várias vezes, sempre considerando a semente da geração de dados aleatória, mostrando a convergência para a mesma resposta, como ilustrado na figura 7.




Fig. 7. Características de convergência para o sistema de 27 barras, com cada curva sendo representada por diferentes populações iniciais.

Dessa maneira, a figura 7 mostra várias sementes analisadas aleatoriamente com diferentes valores da função objetivo.

A solução ótima apresentada na figura 6 foi encontrada após 82 iterações do algoritmo genético.

Na figura 8 são analisadas as tensões do sistema de 27 barras. Pode-se notar a melhora no perfil de tensão após o redimensionamento.




Fig. 8. Perfil de tensão antes e após o redimensionamento de condutores no sistema de 27 barras.

Para esse sistema é observado um aumento de tensão mínima de 0,9884 para 0,9935 fornecidos em p.u. (por unidade). Através da figura descrita, pode-se notar que o valor da tensão em todas as barras foram maiores após o redimensionamento, justificando o alto custo de investimento.

A melhor solução encontrada pelo algoritmo genético proposto neste trabalho é apresentada na tabela III. Nesta tabela, são apresentados os condutores da rede inicial, e os condutores propostos para serem trocados nos ramos que são apresentados pelo AGM.

TABELA III

RESULTADOS ANTES E DEPOIS DO REDIMENSIONAMENTO NO SISTEMA DE 27 BARRAS.

Seção	Nó início	Nó fim	Condutor inicial	Condutor final
1	1	2	2	5
2	2	3	2	5
3	3	4	2	3
4	9	10	4	5
5	2	11	1	3
6	6	7	1	4
7	12	13	3	5
8	13	14	3	4
9	14	15	2	3
10	15	16	1	2
11	17	18	3	5
12	18	19	5	4
13	20	21	1	3
14	5	23	1	3
15	6	24	1	5
16	8	26	5	3

B. Sistema 23 barras

A metodologia proposta foi testada também em um sistema de 23 barras. As características elétricas como resistência, reatância e custo são mostradas na tabela IV retirados de [15].

TABELA IV

CARACTERÍSTICAS ELÉTRICAS DOS CONDUTORES PARA O SISTEMA DE 23 BARRAS.

Condutor Elétrico	Resistência $\left[\frac{\Omega}{Km}\right]$	Reatância $\left[\frac{\Omega}{Km}\right]$	Custo $\left[\frac{\$}{m}\right]$
1	0,716	0,372	2128
2	0,580	0,362	2598
3	0,470	0,350	3488
4	0,383	0,327	4186

Os parâmetros utilizados no desenvolvimento do algoritmo genético melhorado estão expostos na tabela V.

TABELA V

PARÂMETROS UTILIZADOS NO AGM PARA O SISTEMA DE 23 BARRAS.

Parâmetros	Valores
Tamanho da População Inicial	30
Taxa de Mutação	3%
Taxa de Seleção	1%
Número Máximo de Iterações	10000

A carga total do sistema é equivalente a: 6510,00 kW + j3560,00 kVar. O custo de energia k utilizado é 0,06 \$/kWh.

O custo total inicial do sistema de 23 barras é equivalente a \$15.570.711.552,00. As perdas iniciais foram de 296,240 kW.

Através da utilização da técnica do redimensionamento de condutores o custo total do sistema apresentado foi \$12.299.722.752,00, enquanto que as perdas foram de 234,010 kW, dessa forma, houve uma redução de 21,00% no custo e nas perdas do sistema de distribuição de 23 barras.

O algoritmo encontrou a melhor solução em um tempo de 0,1400 segundos.

A característica de convergência para esse sistema é mostrada na figura 9.




Fig. 9. Características de convergência para o sistema de 23 barras.

Considerando a semente da geração de dados aleatória é possível analisar a convergência do sistema para a mesma resposta, como mostrado na figura 10.




Fig. 10. Características de convergência para o sistema de 23 barras, com cada curva sendo representada por diferentes populações iniciais.

Na figura 11 é analisado o comportamento do perfil de tensão desse sistema. Para esse sistema é observado um aumento de tensão mínima de 0,9397 para 0,9505 dados em p.u.




Fig. 11. Perfil de tensão antes e após o redimensionamento de condutores para o sistema de 23 barras.

A melhor solução encontrada é apresentada na tabela VI, no qual, têm-se a presença dos condutores da rede inicial, e os condutores propostos para serem substituídos nos ramos apresentados pelo AGM.

TABELA VI

RESULTADOS ANTES E DEPOIS DO REDIMENSIONAMENTO NO SISTEMA DE 23 BARRAS.

Seção	Nó início	Nó fim	Condutor inicial	Condutor final
1	1	2	3	4
2	2	3	3	4
3	3	4	3	4
4	4	5	3	4
5	5	6	2	4
6	6	7	2	4
7	7	8	2	4
8	2	9	2	4
9	9	10	2	4
10	3	11	2	4
11	11	12	2	4
12	4	13	2	4
13	13	14	2	4
14	14	15	1	4
15	5	16	2	4
16	16	17	1	4
17	17	18	1	4
18	18	19	1	4
19	6	20	1	4
20	20	21	1	4
21	6	22	1	4
22	22	23	1	4

C. Sistema 70 barras

A metodologia implementada também foi testada em um sistema de 70 barras. Esse sistema é o mais próximo de um sistema real de distribuição. Os dados elétricos desse sistema foram retirados de [16].

Os parâmetros utilizados na implementação do algoritmo genético são mostrados na tabela VII.

TABELA VII

PARÂMETROS UTILIZADOS NO AGM PARA O SISTEMA DE 70 BARRAS.

Parâmetros	Valores
Tamanho da População Inicial	30
Taxa de Mutação	5%
Taxa de Seleção	1%
Número Máximo de Iterações	10000

A carga total do sistema é equivalente a: 3802,19 MW + j2694,60 MVar. O custo de energia k utilizado é 0,06 \$/kWh.

Para executar a técnica do redimensionamento são proposto três diferentes tipos de condutores como mostrado na tabela VIII com suas respectivas correntes.

TABELA VIII

CARACTERÍSTICAS ELÉTRICAS DOS CONDUTORES PARA O SISTEMA DE 70 BARRAS.

Condutor Elétrico	Resistência $\left[\frac{\Omega}{Km}\right]$	Reatância $\left[\frac{\Omega}{Km}\right]$	Corrente Máxima [A]
1	0,7488	0,2475	65
2	0,3089	0,1021	65
3	0,0140	0,0046	130

Os custos dos condutores foram analisados e fundamentados em pesquisas realizadas pelos autores.

O custo inicial do sistema é igual \$11.827.006.464,00. As perdas iniciais apresentadas pelo sistema foram 225,01 kW. Com a utilização da técnica do redimensionamento foi proposto uma alocação ótima cujas perdas são reduzidas para 16,19 kW, enquanto que o novo custo apresentou um valor de \$851.233.600,00.

O algoritmo encontrou a solução ótima em um tempo de 0,3270 segundos.

A característica de convergência do sistema de 70 barras é mostrada na figura 12.




Fig. 12. Característica de convergência para o sistema de 70 barras.

Para a validação dos resultados, o sistema de distribuição de 70 barras foi testado por meio de sementes.




Fig. 13. Características de convergência para o sistema de 70 barras, com cada curva sendo representada por diferentes populações iniciais.

Na figura 14 é analisado o perfil de tensão do sistema de 70 barras sem o redimensionamento e com adição da técnica implementada.




Fig. 14. Perfil de tensão do sistema de 70 barras antes e após a técnica do redimensionamento.

Observando a figura 14, pode-se notar a melhora no perfil de tensão após a alocação dos condutores.

Para esse sistema é observado um aumento de tensão mínima de 0,9197 para 0,9955 p.u.

V. CONCLUSÃO

Através dos resultados obtidos pode-se concluir que o redimensionamento de condutores traz benefícios aos sistemas de distribuição de energia. Com a utilização do algoritmo genético melhorado foi possível realizar a alocação de condutores que retornasse um valor mínimo da função objetivo.

A principal vantagem da metodologia executada é a minimização dos custos dos sistemas, assim como, a redução nas perdas, diminuindo a dispersão de potência ativa nas linhas de distribuição. Outra vantagem importante, é o melhoramento do perfil de tensão, pois como observado nos sistemas acima, as tensões abaixo do limite foram elevadas, visando melhorar a qualidade no fornecimento de energia elétrica.

VI. AGRADECIMENTOS

Agradecimentos ao Programa de Iniciação Científica (PROIC) da Universidade Estadual de Londrina, pelo apoio fornecido para a concretização do trabalho exposto.

REFERÊNCIAS

- [1] A. M. Cossi and J. R. S. Mantovani, "Integrated planning of electric power distribution networks," *IEEE Latin America Transactions*, vol. 7, no. 2, pp. 203–210, June 2009.
- [2] G. J. Anders, M. Vainberg, D. J. Horrocks, S. M. Foty, J. Motlis, and J. Jarnicki, "Parameters affecting economic selection of cable sizes," *IEEE Transactions on Power Delivery*, vol. 8, no. 4, pp. 1661–1667, Oct 1993.
- [3] S. Mandal and A. Pahwa, "Optimal selection of conductors for distribution feeders," *IEEE Transactions on Power Systems*, vol. 17, no. 1, pp. 192–197, Feb 2002.
- [4] M. Vahid, N. Manouchehr, A. Jamaledin, and S. D. Hossein, "Combination of optimal conductor selection and capacitor placement in radial distribution systems for maximum loss reduction," in *Industrial Technology, 2009. ICIT 2009. IEEE International Conference on*, Feb 2009, pp. 1–5.
- [5] H. Falaghi, M. Ramezani, M. R. Haghifam, and K. R. Milani, "Optimal selection of conductors in radial distribution systems with time varying load," in *Electricity Distribution, 2005. CIRED 2005. 18th International Conference and Exhibition on*, June 2005, pp. 1–4.
- [6] I. de J Silva, M. J. Rider, R. Romero, A. V. Garcia, and C. A. Murari, "Transmission network expansion planning with security constraints," *IEEE Proceedings - Generation, Transmission and Distribution*, vol. 152, no. 6, pp. 828–836, Nov 2005.
- [7] P. Chu and J. Beasley, "A genetic algorithm for the generalised assignment problem," *Computers & Operations Research*, vol. 24, no. 1, pp. 17–23, 1997.

- [8] D. Shirmohammadi, H. W. Hong, A. Semlyen, and G. X. Luo, "A compensation-based power flow method for weakly meshed distribution and transmission networks," *IEEE Transactions on Power Systems*, vol. 3, no. 2, pp. 753–762, May 1988.
- [9] J. H. Holland, *Adaptation in Natural and Artificial Systems*. The University of Michigan Press, 1975.
- [10] V. Miranda, J. V. Ranito, and L. M. Proenca, "Genetic algorithms in optimal multistage distribution network planning," *IEEE Transactions on Power Systems*, vol. 9, no. 4, pp. 1927–1933, Nov 1994.
- [11] K. Nara, A. Shiose, M. Kitagawa, and T. Ishihara, "Implementation of genetic algorithm for distribution systems loss minimum re-configuration," *IEEE Transactions on Power Systems*, vol. 7, no. 3, pp. 1044–1051, Aug 1992.
- [12] M. A. Semenov and D. A. Terkel, "Analysis of convergence of an evolutionary algorithm with self-adaptation using a stochastic lyapunov function," *Evolutionary Computation*, vol. 11, no. 4, pp. 363–379, Dec 2003.
- [13] I. F. Prado and L. P. Garces, "Chu-beasley genetic algorithm applied to the allocation of distributed generation," in *Innovative Smart Grid Technologies Latin America (ISGT LA), 2013 IEEE PES Conference On*, April 2013, pp. 1–7.
- [14] L. A. Gallego, M. J. Rider, R. Romero, and A. V. Garcia, "A specialized genetic algorithm to solve the short term transmission network expansion planning," in *PowerTech, 2009 IEEE Bucharest*, June 2009, pp. 1–7.
- [15] J. F. Franco, Y. S. Restrepo, and P. Tabares, "Repotenciacion de alimentadores primarios para la reducción de pérdidas," *Scientia et Technica*, vol. XII, no. 30, pp. 19–24, 2006.
- [16] M. E. Baran and F. F. Wu, "Optimal capacitor placement on radial distribution systems," *IEEE Transactions on Power Delivery*, vol. 4, no. 1, pp. 725–734, Jan 1989.