

UNIVERSIDADE FEDERAL DO PARÁ
INSTITUTO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

**ALOCAÇÃO ÓTIMA DE GERAÇÃO DISTRIBUÍDA EM REDES DE
DISTRIBUIÇÃO UTILIZANDO ALGORITMO HÍBRIDO BASEADO EM
CUCKOO SEARCH E ALGORITMO GENÉTICO**

VICTORIA YUKIE MATSUNAGA DE OLIVEIRA

TD - 23 / 2019

UFPA / ITEC / PPGEE
Campus Universitário do Guamá
Belém-Pará-Brasil
2019

UNIVERSIDADE FEDERAL DO PARÁ
INSTITUTO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

VICTORIA YUKIE MATSUNAGA DE OLIVEIRA

ALOCAÇÃO ÓTIMA DE GERAÇÃO DISTRIBUÍDA EM REDES DE DISTRIBUIÇÃO
UTILIZANDO ALGORITMO HÍBRIDO BASEADO EM CUCKOO SEARCH E
ALGORITMO GENÉTICO

TD - 23 / 2019

UFPA / ITEC / PPGEE
Campus Universitário do Guamá
Belém-Pará-Brasil
2019

UNIVERSIDADE FEDERAL DO PARÁ
INSTITUTO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

VICTORIA YUKIE MATSUNAGA DE OLIVEIRA

ALOCAÇÃO ÓTIMA DE GERAÇÃO DISTRIBUÍDA EM REDES DE DISTRIBUIÇÃO
UTILIZANDO ALGORITMO HÍBRIDO BASEADO EM CUCKOO SEARCH E
ALGORITMO GENÉTICO

Tese submetida à Banca
Examinadora do Programa de Pós-
Graduação em Engenharia Elétrica
da UFPA para a obtenção do Grau
de Doutor em Engenharia Elétrica na
área de Sistemas de Energia Elétrica.

UFPA / ITEC / PPGEE
Campus Universitário do Guamá
Belém-Pará-Brasil
2019

**Dados Internacionais de Catalogação na Publicação (CIP) de acordo com ISBD
Sistema de Bibliotecas da Universidade Federal do Pará
Gerada automaticamente pelo módulo Ficat, mediante os dados fornecidos pelo(a) autor(a)**

O48a Oliveira, Victoria Yukie Matsunaga de
Alocação ótima de geração distribuída em redes de distribuição
utilizando algoritmo híbrido baseado em Cuckoo Search e
Algoritmo Genético / Victoria Yukie Matsunaga de Oliveira. —
2019.
90 f. : il. color.

Orientador(a): Prof^a. Dra. Carolina de Mattos Affonso
Tese (Doutorado) - Programa de Pós-Graduação em Engenharia
Elétrica, Instituto de Tecnologia, Universidade Federal do Pará,
Belém, 2019.

1. Sistemas de distribuição. 2. Geração distribuída. 3.
Alocação ótima. 4. Cuckoo Search. 5. Algoritmo Genético. I.
Título.

CDD 621.31



UNIVERSIDADE FEDERAL DO PARÁ
INSTITUTO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

**“ALOCAÇÃO ÓTIMA DE GERAÇÃO DISTRIBUÍDA EM REDES DE DISTRIBUIÇÃO
UTILIZANDO ALGORITMO HÍBRIDO BASEADO EM CUCKOO SEARCH E
ALGORITMO GENÉTICO”**

AUTORA: **VICTORIA YUKIE MATSUNAGA DE OLIVEIRA**

TESE DE DOUTORADO SUBMETIDA À BANCA EXAMINADORA APROVADA PELO
COLEGIADO DO PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA, SENDO
JULGADA ADEQUADA PARA A OBTENÇÃO DO GRAU DE DOUTOR EM ENGENHARIA
ELÉTRICA NA ÁREA DE SISTEMAS DE ENERGIA ELÉTRICA.

APROVADA EM: 02/09/2019

BANCA EXAMINADORA:



Prof.ª Dr.ª Carolina de Mattos Affonso
(Orientadora – PPGEE/UFPA)



Prof. Dr. Marcus Vinícius Alves Nunes
(Avaliador Interno – PPGEE/UFPA)



Prof. Dr. Roberto Célio Limão de Oliveira
(Avaliador Interno – PPGEE/UFPA)



Prof. Dr. Walter Barra Júnior
(Avaliador Interno – PPGEE/UFPA)



Prof. Dr. André Maurício Damasceno Ferreira
(Avaliador Externo – IFPA)



Prof. Dr. Luiz Carlos Pereira da Silva
(Avaliador Externo – UNICAMP)

VISTO:



Prof.ª Dr.ª Maria Emília de Lima Tostes
(Coordenadora do PPGEE/ITEC/UFPA)

*Dedico este trabalho aos meus pais, Hiroshi e Marlene,
pelo amor, educação e dedicação constantes.*

Agradecimentos

À minha orientadora, professora Carolina Affonso, pelo aprendizado, disponibilidade, empenho e compreensão. Agradeço por compartilhar os seus conhecimentos que foram primordiais para o desenvolvimento deste trabalho.

Aos meus pais, Hiroshi e Marlene, por sempre se dedicarem à minha formação humanística e intelectual, sem medir esforços. Sou infindavelmente grata pelo amor, carinho, confiança e apoio.

Aos meus irmãos, Masaharu e Masashigue, pelos incentivos, amizade e ajuda incondicional em todos os momentos da minha vida. Aos meus irmãos, Ângela e Ilons, que apesar da distância, sempre me apoiaram.

Ao Rodrigo, pelo amor, carinho, companheirismo e dedicação em todos os momentos. Agradeço também pelas suas contribuições técnicas, sendo de grande importância na construção deste trabalho.

Ao professor Walter Barra, pelo conhecimento que adquiri durante a graduação e mestrado. O seu trabalho como educador é de grandiosa relevância no âmbito científico.

À FAPESPA pelo apoio financeiro, à UFPA e a todos os professores do PPGEE.

*“Não faz mal que seja pouco,
o que importa é que o avanço de hoje
seja maior que o de ontem.
Que nossos passos de amanhã
sejam mais largos que os de hoje”.*

(Daisaku Ikeda)

Resumo

Esta tese de doutorado propõe um novo algoritmo Cuckoo Search (CS) chamado Cuckoo-GRN (*Cuckoo Search with Genetically Replaced Nests*), que incorpora benefícios do algoritmo genético (GA) no algoritmo CS. O método proposto trata os ninhos abandonados do CS de maneira mais eficiente, substituindo-os geneticamente. Isto melhora significativamente o desempenho do algoritmo, estabelecendo o equilíbrio ideal entre a diversificação e a intensificação de busca. O novo algoritmo é utilizado para otimizar a localização e o dimensionamento de unidades de geração distribuída em um sistema de distribuição, a fim de minimizar as perdas de energia ativa, melhorando a estabilidade da tensão do sistema e o perfil de tensão. Alocações de uma ou mais unidades de geração distribuída são consideradas. O algoritmo proposto é extensivamente testado em funções matemáticas de *benchmark*, bem como nos sistemas de distribuição de 33 e 119 barras. Os resultados da simulação mostram que o Cuckoo-GRN pode levar a uma melhora substancial de desempenho em relação ao algoritmo CS original e a outras técnicas atualmente conhecidas na literatura, não apenas em termos de convergência, mas também de precisão da solução.

Palavras-chaves: Sistemas de Distribuição; Geração Distribuída; Algoritmo Genético; Cuckoo Search; Substituição Genética de Ninhos; Alocação Ótima.

Abstract

This thesis presents a novel Cuckoo Search (CS) algorithm called Cuckoo-GRN (Cuckoo Search with Genetically Replaced Nests), which incorporates the benefits of genetic algorithm (GA) into the CS algorithm. The proposed method handles the abandoned nests from CS more efficiently by genetically replacing them, significantly improving the performance of the algorithm by establishing optimal balance between diversification and intensification. The algorithm is used for the optimal location and size of distributed generation units in a distribution system, in order to minimise active power losses while improving system voltage stability and voltage profile. The allocation of single and multiple distribution generation units is considered. The proposed algorithm is extensively tested in mathematical benchmark functions as well as in the 33-bus and 119-bus distribution systems. Simulation results show that Cuckoo-GRN can lead to a substantial performance improvement over the original CS algorithm and others techniques currently known in literature, regarding not only the convergence but also the solution accuracy.

Key words: Distribution System; Distributed Generation; Genetic Algorithm; Cuckoo Search; Genetic Replacement of Nests; Optimal Allocation.

Lista de ilustrações

Figura 1 – Exemplo de representação binária.	34
Figura 2 – Exemplo de seleção por roleta.	35
Figura 3 – Exemplo de cruzamento de um ponto.	36
Figura 4 – Fluxograma do algoritmo genético.	37
Figura 5 – Diagrama do processo de substituição de ninhos abandonados para $n_a = n_g = 2$	45
Figura 6 – Função de teste de Easom (<i>Cuckoo Search</i> e Cuckoo-GRN).	48
Figura 7 – Função de teste de De Jong (<i>Cuckoo Search</i> e Cuckoo-GRN).	49
Figura 8 – Funções de teste de Easom e de De Jong (AG e PSO).	50
Figura 9 – Comportamento dos ninhos do Cuckoo-GRN para a função De Jong com $p_m = 2\%$ e $n_g = 12$. (a) Iteração 1, (b) Iteração 2, (c) Iteração 8 e (d) Iteração 17.	52
Figura 10 – Exemplo de 20 passos do voo de Lévy.	53
Figura 11 – Sistema de distribuição de 33 barras.	60
Figura 12 – NMAF para o CS e Cuckoo-GRN com $n_a = 4$ e diferentes valores de p_m	63
Figura 13 – NMAF para o CS com $n_a = 4$ e Cuckoo-GRN com $n_a = 5$ e diferentes valores de p_m	64
Figura 14 – NMAF para o CS com $n_a = 4$ e Cuckoo-GRN com $6 \leq n_a \leq 12$ e diferentes valores de p_m	65
Figura 15 – Desvio padrão das avaliações para diferentes valores de $n_a = 4$ e p_m	66
Figura 16 – Curvas PV do sistema 33 barras antes e depois da inserção de GD.	67
Figura 17 – Sistema de distribuição de 119 barras.	68
Figura 18 – Otimização de três GDs com fator de potência igual a 0,95.	70
Figura 19 – Otimização de três GDs com fator de potência igual a 1,0.	70
Figura 20 – Otimização de quatro GDs com fator de potência igual a 0,95.	71

Figura 21 – Otimização de quatro GDs com fator de potência igual a 1,0.	72
Figura 22 – Otimização de cinco GDs com fator de potência igual a 0,95.	73
Figura 23 – Otimização de cinco GDs com fator de potência igual a 1,0.	73
Figura 24 – Desempenho do Cuckoo-GRN para o sistema de 119 barras com 3GDs e FP = 0,95. Funções: (a) F_1 , (b) F_2 , (c) F_3 e (d) $F = w_1F_1 + w_2F_2 + w_3F_3$	76
Figura 25 – Perfil de convergência média do CS e Cuckoo-GNR ($n_a = n_g = 12$) – 500 execuções independentes.	79
Figura 26 – Perfil de tensão antes e depois da instalação de uma GD utilizando o algoritmo Cuckoo-GRN.	80

Lista de tabelas

Tabela 1 – Classificação da GD quanto à potência instalada (P_i).	22
Tabela 2 – Classificação da GD quanto à potência instalada (P_i) de acordo com a ANEEL.	23
Tabela 3 – Resultados estatísticos para as funções de teste de <i>benchmark</i>	51
Tabela 4 – Comparação entre diferentes métodos para o sistema de 33 barras, considerando fator de potência unitário da GD.	61
Tabela 5 – Comparação entre os métodos AG, PSO, CS e Cuckoo-GRN para a otimização de 3, 4 e 5 unidades de GDs do sistema de 119 barras.	75
Tabela 6 – Resultados da simulação para o sistema 119 barras $\lambda = 1,5$, $\alpha = 1$ e critério de parada igual a 938,4744 kW.	80

Lista de Siglas

AG	Algoritmo Genético
ANEEL	Agência Nacional de Energia Elétrica
BIG	Banco de Informações de Geração
Cuckoo-GRN	<i>Cuckoo Search with Genetically Replaced Nests</i>
CS	<i>Cuckoo Search</i>
EPRI	<i>Electric Power Research Institute</i>
FDP	Função Densidade de Probabilidade
FP	Fator de Potência
GD	Geração Distribuída
IET	Índice de Estabilidade de Tensão
IREA	<i>International Renewable Energy Agency</i>
NMAF	Número Médio de Avaliações da Função Objetivo
PCH	Pequena Central Hidrelétrica
PI	Proporcional-Integral
PROINFA	Programa de Incentivos às Fontes Alternativas de Energia Elétrica
PSO	<i>Particle Swarm Optimization</i>
SOS	<i>Symbiotic Organism Search</i>

Lista de Símbolos

α	Constante positiva ajustada de acordo com as dimensões do espaço de busca
λ	Decaimento da função densidade de probabilidade
B_{ij}	Parte imaginária da matriz admitância nodal
F	Função objetivo
FP_{GD}	Fator de potência da geração distribuída
G_{ij}	Parte real da matriz admitância nodal
G_m	Condutância do ramo m que conecta as barras i a j
K	Conjunto de barras adjacentes à barra i (incluindo a barra i)
n	Número de ninhos hospedeiros disponíveis
n_a	Número total de ninhos abandonados
n_g	Número de ninhos abandonados substituídos geneticamente
n_r	Número de ninhos abandonados substituídos aleatoriamente
N	Número total de ramos no sistema de distribuição
N_b	Número total de barras no sistema de distribuição
p_a	Probabilidade de uma ave hospedeira distinguir um ovo de cuco
p_m	Probabilidade de mutação
P	Potência ativa
P_{di}	Potência ativa da demanda na barra i
P_{gi}	Potência ativa do gerador na barra i
P_D	Demanda total do sistema
P_{GD}	Potência ativa da unidade de GD
Q	Potência reativa
Q_{di}	Potências reativa da demanda na barra i
Q_{gi}	Potência reativa do gerador na barra i

r_{ij}	Resistência do ramo que conecta as barras i a j
V	Magnitude de tensão
V_{nom}	Tensão nominal
V_i	Tensão na barra i
V_j	Tensão na barra j
V_i^{min}	Tensão mínima permitida na barra i
$V_i^{máx}$	Tensão máxima permitida na barra i
x_{ij}	Reatância do ramo que conecta as barras i a j
w	Peso relativo à função objetivo F

Sumário

	Lista de ilustrações	11
	Lista de tabelas	13
	Sumário	17
1	INTRODUÇÃO	20
1.1	Justificativa	20
1.2	Geração distribuída	21
1.3	Revisão bibliográfica	25
1.4	Objetivo da Tese	31
1.5	Estrutura da Tese	32
2	ALGORITMOS BIO-INSPIRADOS: ALGORITMO GENÉTICO E CUCKOO SEARCH	33
2.1	Introdução	33
2.2	Algoritmo genético	33
2.2.1	Representação genética	34
2.2.2	População	34
2.2.3	Função de avaliação (<i>fitness</i>)	34
2.2.4	Seleção	35
2.2.5	Cruzamento (<i>crossover</i>)	35
2.2.6	Mutação	36
2.2.7	Estrutura do AG	36
2.3	Cuckoo Search	38
2.4	Conclusões do capítulo	41

3	CUCKOO-GRN: DEFINIÇÃO DA METODOLOGIA PROPOSTA E BENCHMARKING	43
3.1	Introdução	43
3.2	Estrutura do algoritmo Cuckoo-GRN	44
3.3	Problemas matemáticos de <i>benchmark</i>	47
3.4	Conclusões do capítulo	53
4	DEFINIÇÃO DO PROBLEMA E RESULTADOS	55
4.1	Introdução	55
4.2	Definição do problema	55
4.2.1	Função objetivo	56
4.2.1.1	Minimização de perdas de potência ativa	56
4.2.1.2	Desvio de tensão	56
4.2.1.3	Índice de estabilidade de tensão	57
4.2.2	Restrições	57
4.2.2.1	Restrições de balanço de potência	58
4.2.2.2	Restrições dos limites de tensão	58
4.2.2.3	Restrição da capacidade de potência da GD	58
4.2.2.4	Restrições do fator de potência	59
4.3	Resultados	59
4.3.1	Sistema de 33 barras: otimização da localização e do dimensionamento da GD	59
4.3.2	Sistema de 119 barras	67
4.3.2.1	Cenário 1 - Otimização multiobjetivo visando minimização de perdas e desvio de tensão, e maximização do IET	69
4.3.2.2	Cenário 2 - Otimização mono-objetivo visando minimização de perdas para localização, dimensionamento e fator de potência da GD	77
4.4	Conclusões do capítulo	81

5	CONCLUSÕES	82
	REFERÊNCIAS	84

1 Introdução

1.1 Justificativa

Com o crescente aumento da demanda de energia elétrica no mundo, conceitos e tecnologias têm sido desenvolvidos no setor elétrico considerando diversos aspectos como economia, segurança e preservação ambiental. Nos últimos anos, houve um grande interesse na utilização de unidades de geração distribuída (GD) através de fontes renováveis de energia por apresentarem menor impacto ambiental (RAZAVI et al., 2019). Além disso, o uso dessas unidades de geração em sistemas de distribuição apresenta diversos benefícios para a rede elétrica, tais como redução nas perdas de potência ativa, aumento na confiabilidade e melhoria no perfil de tensão do sistema (MAHMOUD; YORINO; AHMED, 2016; SINGH; SHARMA, 2017). Apesar das vantagens, a implantação da GD deve ser feita após a realização de estudos detalhados de seus efeitos na rede de distribuição, pois a escolha inadequada da localização dessas unidades pode ocasionar impactos indesejados na rede (KROPOSKI; SEN; MALMEDAL, 2009).

Diferentes abordagens têm sido propostas na literatura para determinar a localização e o dimensionamento ótimos de unidades de GD com o objetivo de obter a minimização das perdas de potência e dos custos de geração e a melhoria do perfil de tensão e da confiabilidade em sistemas elétricos de potência. As técnicas utilizadas nesses estudos podem ser classificadas, principalmente, como métodos analíticos, heurísticos e híbridos (PRAKASH; KHATOD, 2016). Os métodos analíticos, geralmente, fundamentam-se em estratégias para simplificar o problema de otimização, e isso pode levar a resultados não ótimos (NAIK; KHATOD; SHARMA, 2015; HUNG; MITHULANANTHAN, 2013). Os métodos heurísticos e meta-heurísticos utilizam técnicas de inteligência computacional inspiradas em vários comportamentos e mecanismos da natureza (YANG, 2010b), podendo gerar soluções ótimas ou quase ótimas.

Um algoritmo chamado *Cuckoo Search* (CS) tem atraído a atenção de muitos pesquisadores devido ao seu desempenho ser potencialmente superior a de outros algoritmos meta-heurísticos (YANG; DEB, 2009; MORAVEJ; AKHLAGHI, 2013). Este método é baseado no comportamento parasitário de ninho de algumas espécies de aves cuco. Alguns autores também têm proposto modificações para o CS com a finalidade de melhorar sua eficácia e resolver vários problemas do mundo real de alta complexidade (CHIROMA et al., 2017; AKUMALLA; PEDDAKOTLA; KUPPA, 2016). A ideia é combinar as vantagens de diferentes técnicas e seus pontos fortes complementares.

Nesse contexto, destaca-se a importância de estudos de geração distribuída no planejamento de sistemas de potência. A inserção de GD na rede de distribuição, dependendo da sua localização e capacidade de geração, pode provocar impactos e portanto, uma análise prévia deve ser realizada para que se considere os benefícios que a GD pode fornecer ao sistema. A solução deste problema pode ser determinada através da utilização de diferentes técnicas (analíticas, heurísticas, meta-heurísticas e híbridas) (ACHARYA; MAHAT; MITHULANANTHAN, 2006; HUNG; MITHULANANTHAN; BANSAL, 2010; SHENG et al., 2015; KANSAL; KUMAR; TYAGI, 2013).

1.2 Geração distribuída

O crescimento cada vez maior da demanda por energia elétrica tem ocasionado diversos problemas relacionados aos aspectos econômicos, ambientais e técnicos. As empresas do setor elétrico têm buscado soluções para este problema, principalmente devido às fontes de energia tradicionais operarem de forma centralizada e ao elevado custo da geração e transmissão de energia (PRAKASH; KHATOD, 2016; Pesaran H.A; HUY; RAMACHANDARAMURTHY, 2017). Nesse cenário, a utilização de unidades de geração distribuída tem se tornado um fator importante em sistemas de distribuição, pois a sua instalação é mais simples do que as fontes tradicionais (as hidrelétricas, por exemplo) e podem ser alimentadas por fonte renovável e não renovável (PRAKASH; KHATOD, 2016;

JORDEHI, 2016).

A geração distribuída possui diferentes definições na literatura: geração dispersa, geração descentralizada e geração embutida. O *Electric Power Research Institute* (EPRI) definiu a GD como uma unidade gerando poucos quilowatts até 50 MW (JORDEHI, 2016; SAMBAIAH, 2018). No artigo *Distributed generation: a definition* de Ackermann *et. al* (ACKERMANN; ANDERSSON; SÖDER, 2001), as GDs são basicamente definidas como unidades de geração conectadas à rede de distribuição de energia, localizadas próximas às cargas. A Agência Nacional de Energia Elétrica (ANEEL) estabelece que a micro e a minigeração distribuída são pequenas centrais geradoras que produzem energia a partir de fontes renováveis de energia elétrica (solar, eólica, biomassa, PCHs) ou cogeração qualificada, conectadas à rede de distribuição por meio de instalações de unidades consumidoras (Agência Nacional de Energia Elétrica - ANEEL, 2016).

Os autores dos artigos (ACKERMANN; ANDERSSON; SÖDER, 2001; LOPES *et al.*, 2007; MORADI; ABEDINI, 2012; VIRAL; KHATOD, 2012; PRAKASH; KHATOD, 2016) apresentam a classificação da GD quanto à potência instalada conforme mostra a Tabela 1. A ANEEL também determinou uma classificação baseada na potência instalada estabelecida na Resolução Normativa N^o 687 de 24 de novembro de 2015, apresentada conforme a Tabela 2 (Agência Nacional de Energia Elétrica - ANEEL, 2015).

Tabela 1 – Classificação da GD quanto à potência instalada (P_i).

Tipo	Capacidade
Micro	$1 \text{ W} < P_i < 5 \text{ kW}$
Pequena	$5 \text{ kW} < P_i < 5 \text{ MW}$
Média	$5 \text{ MW} < P_i < 50 \text{ MW}$
Grande	$50 \text{ MW} < P_i < 300 \text{ MW}$

Tabela 2 – Classificação da GD quanto à potência instalada (P_i) de acordo com a ANEEL.

Tipo	Capacidade	Fonte
Microgeração distribuída	$P_i \leq 75$ kW	Todas
Minigeração distribuída	75 kW $< P_i \leq 5$ MW	Hídrica
Minigeração distribuída	75 kW $< P_i \leq 3$ MW	Demais

No mundo, o uso de fontes renováveis tem aumentado devido, principalmente, a preocupações ambientais e econômicas. Em 2015, a Organização das Nações Unidas (ONU) estabeleceu os Objetivos de Desenvolvimento Sustentável (ODS). São no total 17 objetivos e dentre eles, no ODS 7 é determinado: "Assegurar o acesso confiável, sustentável, moderno e a preço acessível à energia para todas e todos". O ODS 7 se refere à garantia de energia para todos, em qualquer região do mundo, a partir de fontes renováveis, eficientes e não poluentes (ONU no Brasil - ONUBR, 2018). O estabelecimento do ODS 7 contribuiu para o crescimento no uso da geração distribuída a partir de fontes renováveis em sistemas de energia elétrica.

Este ano, a *International Renewable Energy Agency* (IREA), publicou um estudo estatístico sobre a energia produzida no mundo a partir de fontes renováveis. De acordo com a IREA, a geração de energia renovável foi de 6.191 TWh em 2017. Isso indica um acréscimo de 5 % em relação ao ano de 2016, correspondendo a um aumento de 293 TWh. Também, esse estudo mostrou que a geração solar e eólica têm se destacado entre as demais fontes por apresentarem um crescimento de 35,5 % e 18,8 %, respectivamente (International Renewable Energy Agency, 2019).

No Brasil, no ano de 2004, o Programa de Incentivos às Fontes Alternativas de Energia Elétrica (PROINFA), com a finalidade de aumentar o uso de recursos naturais na geração de energia, impulsionou um aumento da participação de fontes renováveis de energia (ANGELIM, 2018). Outros incentivos ao uso de fontes renováveis também foram criados. A Resolução Normativa Nº 482 de 17 de abril de 2012 (Agência Nacional de Energia Elétrica - ANEEL, 2012) estabeleceu o sistema de compensação de energia elétrica e as

condições gerais para o acesso de microgeração e minigeração distribuída aos sistemas de distribuição. A Resolução Normativa Nº 687 de 24 de novembro de 2015 (Agência Nacional de Energia Elétrica - ANEEL, 2015) alterou a classificação relacionada à potência instalada da GD, conforme mostra a Tabela 2. Também foram criados: um sistema de crédito de energia (possibilidade em utilizar créditos do excedente de energia para serem descontados nas faturas dos meses seguintes ou serem utilizados para abater o consumo de unidades consumidoras do mesmo titular situadas em outro local), geração compartilhada entre cooperados e viabilidade de instalação de GD em condomínios.

A regulamentação da GD estimulou o crescimento de fontes renováveis na matriz energética do Brasil. No Banco de Informações de Geração (BIG) da ANEEL consta que o Brasil possui 165,47 GW de potência instalada em 2019, sendo 37,28 GW correspondendo à geração solar, eólica, biomassa e PCHs. Para essas fontes, está prevista para os próximos anos uma adição de 12,45 GW na capacidade de geração, proveniente de empreendimentos atualmente em construção e em construção não iniciada, representando um aumento de 33,4 % de fontes renováveis (Banco de Informações de Geração (BIG), 2019).

O aumento da instalação da GD em sistemas de distribuição acarreta mudanças nas características da rede (perfil de tensão, fluxo de potência e perdas de potência). Dependendo do local a ser instalada, a GD pode afetar a operação do sistema de forma positiva ou negativa se o planejamento da sua instalação não for adequado (GIL; JOOS, 2008; ASRARI; WU; LOTFIFARD, 2016; PRAKASH; KHATOD, 2016). Consequentemente, é essencial que a alocação e o dimensionamento das unidades de GD sejam feitos apropriadamente no sistema de distribuição, de modo a maximizar os seus benefícios para as concessionárias e consumidores ((JORDEHI, 2016)).

A geração distribuída a partir de fontes renováveis, como a energia solar e eólica, possui notável destaque devido à sua vasta disponibilidade na natureza e à sua produção a partir de energia limpa. Contudo, a natureza intermitente dessas fontes requer estudos estocásticos que depende do clima e localização geográfica. Em consequência a essas limitações, ocasionalmente esse tipo de GD não pode ser instalada em qualquer local de

um sistema de distribuição (SAMBALIAH, 2018).

Alguns impactos positivos da geração distribuída descritos em (MORADI; ABEDINI, 2012; SHARMA; SINGH; WANG, 2016; SINGH; SHARMA, 2017; RAZAVI et al., 2019) são listados a seguir:

- Diminuição dos danos ao meio ambiente quando são utilizadas fontes renováveis;
- Redução das perdas de potência ativa e reativa devido à proximidade da carga e a geração;
- Redução das quedas de tensão das barras do sistema;
- Aumento da estabilidade do sistema de potência com relação à tensão;
- A longo prazo, adiamento de investimentos na expansão do sistema de transmissão;
- Diversificação da matriz energética através do uso de fontes renováveis;
- Diminuição nos custos de transmissão devido à localização da GD ser próxima aos consumidores;

Desse modo, observa-se que a relevância da alocação de unidades de geração distribuída é significativa para que o fornecimento de energia elétrica seja estável, seguro, econômico e sustentável (JORDEHI, 2016). Ou seja, através da alocação adequada da GD, há melhorias na confiabilidade e qualidade do sistema, redução dos custos de investimento e operacionais e decréscimo dos efeitos prejudiciais ao meio ambiente.

1.3 Revisão bibliográfica

Diversas pesquisas propuseram métodos analíticos para encontrar o tamanho e a localização ótimos das GDs com o propósito de minimizar as perdas ativas do sistema. Os autores de (WANG; NEHRIR, 2004) apresentaram abordagens analíticas para calcular a

localização ótima da GD com fator de potência (FP) unitário para minimizar as perdas ativas de potência. Dois estudos de caso foram considerados: a demanda e a geração da GD invariante ou variante no tempo. Nas simulações, a unidade de GD foi instalada em diferentes barras e as perdas totais do sistema foram calculadas para cada caso.

Acharya, Mahat e Mithulanathan (2006) propuseram uma expressão analítica para calcular a capacidade ótima de uma única GD e uma metodologia baseada na técnica de injeção de corrente equivalente para identificar a localização ótima, considerando a redução de perdas. O estudo do dimensionamento e a localização da GD foi baseado em uma demanda no seu valor de pico, onde as perdas são máximas. Uma comparação foi realizada entre o método proposto, o fator de sensibilidade de perdas e o fluxo de carga exaustivo no cálculo das melhores localizações obtidas da GD. A análise sugeriu que as perdas decorrentes de uma alocação diferente variam muito e, portanto, esse fator deve ser levado em consideração ao determinar a localização apropriada da geração distribuída.

Gözel e Hocaoglu (2009) publicaram um estudo do dimensionamento e localização ótimos da GD de forma a minimizar as perdas totais de potência. Utilizou-se um método analítico baseado na técnica de injeção de corrente equivalente sem o uso de matrizes de impedância ou Jacobianas para sistemas radiais. Os resultados foram validados e comparados com o algoritmo de busca baseado em fluxo de carga exaustivo e também com o método de Acharya, Mahat e Mithulanathan (2006). As perdas totais foram calculadas para cada barra, onde a GD foi adicionada, mostrando que o dimensionamento ótimo da GD em cada barra é diferente. A diferença entre os resultados dos métodos analisados não é significativo, mas o tempo de simulação computacional foi menor utilizando o método desenvolvido. Também foi observado que o tempo de simulação torna-se mais significativo quando o tamanho do sistema aumenta.

Através do estudo realizado por Acharya, Mahat e Mithulanathan (2006), expressões analíticas foram propostas em (HUNG; MITHULANANTHAN; BANSAL, 2010) para calcular o tamanho ótimo e o fator de potência de diferentes tipos de geradores distribuídos para a minimização das perdas em sistemas de distribuição primária. A validade das

expressões analíticas propostas foi testada e verificada em três sistemas de distribuição de teste com tamanhos e complexidade variados, usando soluções de fluxo de carga exaustivo. Observou-se que a inserção da geração distribuída reduziu consideravelmente as perdas totais, satisfazendo todas as restrições de potência e tensão. Contudo, o problema para múltiplas GDs não foi investigado. Posteriormente, o problema de alocação de múltiplas unidades de GD foi analisado por Hung e Mithulanathan (2013) para a redução de perdas em redes de distribuição primária de grande porte utilizando as expressões analíticas propostas em (HUNG; MITHULANANTHAN; BANSAL, 2010). O método foi utilizado para obter o tamanho e localização ótimos de múltiplas unidades de geração distribuída. À medida que o número de unidades de GD aumentou, a redução das perdas tornou-se mais evidente. Os fatores de potência ótimos de cada GD também foram calculados, mostrando uma importância significativa na redução das perdas.

Aman et al. (2012) investigaram uma abordagem analítica baseada em um índice de estabilidade de tensão para alocar de forma ótima uma única GD para diminuir as perdas do sistema. O índice proposto foi usado para identificar a barra mais crítica do sistema que pode levar à instabilidade de tensão quando há um aumento na carga além de um limite pré-determinado. Na barra identificada foi inserida a GD. A análise das simulações mostrou uma melhoria no perfil de tensão, aumento da estabilidade de tensão, redução de perdas e aumento na capacidade total do sistema com a inserção da geração distribuída com a utilização da proposta desenvolvida. Para testar a eficiência do método, os resultados foram comparados com o algoritmo *Golden Section Search* (GSS) (GÖZEL; EMINOGLU; HOCAOGLU, 2008). Foi verificado que o método proposto encontra-se em concordância com o GSS (ambos apresentaram resultados aproximados), porém a sua vantagem é que necessita menos tempo computacional do que o GSS.

No artigo (NAIK; KHATOD; SHARMA, 2015), uma metodologia baseada na abordagem analítica foi apresentada para o dimensionamento e a localização otimizada da GD no sistema de distribuição, de modo a minimizar as perdas de energia ativas e reativas. Este artigo é a extensão do proposto em (NAIK; KHATOD; SHARMA, 2013). O método analí-

tico desenvolvido foi baseado na mudança nos valores das correntes nas linhas do sistema, devido à inserção de GD, para o cálculo das perdas. Os resultados foram determinados com o objetivo de explorar os benefícios da alocação adequada de GDs para a melhoria do desempenho da rede.

Yarahmadi e Shakarami (2018) abordaram um estudo analítico para alocação ótima de GD a partir da energia eólica, considerando diferentes modelos de carga dependentes do tempo (residencial, comercial e industrial). A função densidade de probabilidade de Rayleigh foi utilizada para descrever a natureza probabilística da velocidade do vento.

Em todos os casos analíticos foi constatado que há uma diminuição considerável de perdas quando há inserção de GD em uma rede de distribuição. No entanto, à medida que o número de GD aumenta, a complexidade do problema também aumenta, o que é a principal desvantagem da abordagem analítica.

Muitos métodos heurísticos e meta-heurísticos obtiveram resultados satisfatórios na solução ótima da localização e dimensionamento de GDs em sistemas elétricos de potência. Popović et al. (2005) e Borges e Falcão (2006) utilizaram o Algoritmo Genético para resolver um problema com a minimização simultânea de perdas de potência, melhoria do perfil de tensão e confiabilidade do sistema. Sheng et al. (2015) propuseram um Algoritmo Genético modificado para alocar múltiplas GDs no sistema de distribuição, considerando uma função multiobjetivo para minimização de perdas de potência, melhoria de margem de estabilidade de tensão e minimização de desvio de tensão.

No estudo apresentado em (GANDOMKAR; VAKILIAN; EHSAN, 2005b), um algoritmo foi proposto com a combinação do Algoritmo Genético e da Busca Tabu (BT) (GLOVER, 1993) para determinar a alocação ótima das unidades de GD na rede de distribuição. O método utiliza a vizinhança de soluções da BT para produzir uma parte (3–15% do tamanho da população) da nova geração no processo do AG. Os mesmos autores de (GANDOMKAR; VAKILIAN; EHSAN, 2005b) também publicaram o artigo (GANDOMKAR; VAKILIAN; EHSAN, 2005a) com a implementação de um algoritmo baseado no AG e na técnica do Recozimento Simulado para o estudo de GD. Vinothkumar

e Selvan (2011) desenvolveram uma metodologia que utiliza a teoria de conjuntos *fuzzy* e o AG para a formulação e avaliação do problema de alocação ótima de uma ou múltiplas GDs. Em (Borges et al., 2015), uma abordagem probabilística foi proposta para determinar a localização e o tamanho ótimos de parques eólicos em sistemas de energia considerando a incerteza da velocidade do vento e usando AG. Pereira et al. (2018) apresentaram uma metodologia para determinar e especificar os tipos de dispositivos de proteção e controle em sistemas de distribuição com GD, considerando os aspectos econômicos e o índice de continuidade na rede. O método baseia-se na técnica de otimização multiobjetivo NSGA-II (*Nondominated Sorting Genetic Algorithm*) (DEB et al., 2002) para realizar a alocação otimizada, coordenada e seletiva desses dispositivos.

Nafar (2012) investigou a alocação de GD baseada na técnica PSO (*Particle Swarm Optimization*) em um sistema de distribuição para obter melhoria na estabilidade de tensão e no nível de curto-circuito do sistema. Neste trabalho foram utilizados um índice de estabilidade de tensão e uma abordagem de corrente de curto-circuito na solução do problema.

Um algoritmo híbrido embasado no AG e no PSO foi proposto pelos autores Moradi e Abedini (2012) para obter a localização e a capacidade ótimas de GDs com objetivo de minimizar as perdas, melhorar a estabilidade de tensão e o perfil de tensão no sistema. A localização foi calculada com o AG e a capacidade foi otimizada pelo PSO. Kansal, Kumar e Tyagi (2013) apresentaram a alocação de diferentes tipos de GD usando a técnica de PSO para minimizar as perdas ativas de potência. O fator de potência ótimo também foi determinado para a minimização das perdas. Prasad e Kumar (2017) desenvolveram algoritmo híbrido baseado no PSO e KHA (*Krill Herd Algorithm*) (GANDOMI; ALAVI, 2012) que otimiza o número e a localização de dispositivos de medição em redes inteligentes de distribuição, considerando a variação na demanda e a incerteza dos dispositivos de medição. Em (SEDGHI; AHMADIAN; GOLKAR, 2016; ANILKUMAR; DEVRIESE; SRIVASTAVA, 2018), outras aplicações de PSO também foram realizadas em estudos de geração distribuída.

Saha e Mukherjee (2016) desenvolveram um algoritmo denominado *Chaotic Symbiotic Organism Search* (CSOS) a partir da técnica do *Symbiotic Organism Search* (SOS) (CHENG; PRAYOGO, 2014). Para uma análise comparativa e validação do algoritmo, os dois métodos foram aplicados em algumas funções matemáticas de *benchmark*. O CSOS apresentou um melhor desempenho em termos de precisão e de convergência. Além disso, o método foi aplicado no problema de alocação ótima, obtendo resultados satisfatórios em comparação com alguns métodos de otimização (SOS, AG, PSO, *Teaching-Learning-Based Optimisation* (SULTANA; ROY, 2014), AG-PSO (MORADI; ABEDINI, 2012)).

Com a finalidade de aumentar a margem de estabilidade de tensão no sistema de distribuição, Natarajan, Ramadoss e Lakshmanarao (2016) propuseram o uso do algoritmo Colônia Artificial de Abelhas Caótico para encontrar a localização e o dimensionamento ótimos das unidades GD.

Os métodos de otimização descritos, na sua maioria, consistem em resolver problemas de minimização ou maximização com o intuito de diminuir o esforço computacional e obter melhores resultados. O algoritmo denominado *Cuckoo Search* (CS) (YANG; DEB, 2009) tem se destacado entre os pesquisadores por apresentar um desempenho superior em relação a outros métodos.

Moravej e Akhlaghi (2013) estudaram alocação ótima de GDs com a aplicação do CS. O CS foi comparado com outros algoritmos evolutivos, como o PSO e o AG. Os resultados mostraram que o CS é superior a esses algoritmos. Nguyen, Truong e Phung (2016) apresentaram um método baseado no CS em que os ninhos hospedeiros são obtidos a partir da Teoria dos Grafos para reduzir o número de indivíduos com baixa avaliação em cada estágio do processo de otimização. O método foi aplicado na reconfiguração da rede de distribuição e alocação ótima da GD para minimizar as perdas de potência ativa e melhorar o índice de estabilidade de tensão. No artigo de Wang, Meskin e Grinberg (2017), a utilização de unidades de GD é investigada para melhorar o desempenho em termos da melhoria do perfil de tensão e para a diminuição das perdas de potência e do custo de geração da rede de distribuição. Uma otimização da função multiobjetivo, levando os

referidos benefícios, foi proposta fundamentando-se no algoritmo CS para resolver o fluxo de carga ótimo não linear.

Kalaam et al. (2017) desenvolveram um algoritmo baseado no CS e redes neurais para a otimização dos parâmetros de múltiplos controladores PI em sistemas fotovoltaicos conectados à rede elétrica. A eficácia dos valores ótimos é verificada pela implementação em tempo real de um sistema fotovoltaico de pequeno porte e observou-se que melhores respostas foram obtidas, provando sua eficácia para otimizar simultaneamente os parâmetros dos controladores. Outras pesquisas também investigaram modificações do *Cuckoo Search* e suas combinações com outros algoritmos de otimização com a finalidade de melhorar seu desempenho e resolver problemas de diferentes naturezas, conforme são descritos em (AKUMALLA; PEDDAKOTLA; KUPPA, 2016; CHIROMA et al., 2017; MARELI; TWALA, 2018; BOUSHAKI; KAMEL; BENDJEGHABA, 2018; SARASWATHI; MURALI; DEEPAK, 2018).

1.4 Objetivo da Tese

Esta tese de doutorado tem como objetivo aplicar o algoritmo híbrido de otimização Cuckoo-GRN (proposto neste trabalho) em um problema de alocação ótima de unidades de geração distribuída com a finalidade de minimizar as perdas de potência ativa e melhorar o perfil de tensão do sistema, calculando a localização e o dimensionamento ótimos de uma ou mais unidades de GD. Os testes são realizados utilizando os sistemas de distribuição de 33 barras (KASHEM et al., 2000) e 119 barras (ZHANG; FU; ZHANG, 2007).

O algoritmo proposto Cuckoo-GRN (*Cuckoo Search with Genetically Replaced Nests*) combina as características do *Cuckoo Search* e do Algoritmo Genético. A contribuição do Cuckoo-GRN está na forma como os ninhos abandonados do CS são gerados, sendo substituídos por novas soluções baseadas no AG. A finalidade da modificação proposta é obter soluções mais precisas e acelerar a convergência do algoritmo, ou seja, melhorar o desempenho do método com a redução do número médio de avaliações da função objetivo.

A eficiência do método é testada em funções matemáticas de *benchmark*. Através de análises estatísticas, os resultados obtidos a partir de simulações computacionais são comparados com o CS e outras técnicas de otimização para verificar as vantagens de convergência do Cuckoo-GRN.

1.5 Estrutura da Tese

Esta tese de doutorado é constituída dos seguintes capítulos:

- O capítulo 2 descreve uma breve revisão sobre Algoritmos Genéticos e *Cuckoo Search*. Além disso, aborda os principais conceitos das técnicas utilizadas para o desenvolvimento deste trabalho.
- O capítulo 3 apresenta a metodologia Cuckoo-GRN, proposta neste trabalho. Também são apresentados os testes realizados em problemas matemáticos de *benchmark* com o objetivo de avaliar a metodologia desenvolvida e compará-la com outros métodos.
- O capítulo 4 descreve a formulação matemática do problema a ser otimizado e os resultados obtidos com o método proposto. Os sistemas de distribuição de 33 barras e 119 barras são utilizados para a realização dos testes.
- O capítulo 5 apresenta as considerações finais deste trabalho e as sugestões de propostas para trabalhos futuros.

2 Algoritmos bio-inspirados: Algoritmo Genético e Cuckoo Search

2.1 Introdução

Este capítulo aborda brevemente os conceitos fundamentais dos algoritmos bio-inspirados utilizados no desenvolvimento deste trabalho (Algoritmo Genético e *Cuckoo Search*). Os algoritmos bio-inspirados fundamentam-se em técnicas de computação inspirados na natureza, onde o objetivo é desenvolver ferramentas computacionais para resolver problemas de otimização. Nos últimos anos, os métodos meta-heurísticos inspirados nessas técnicas têm sido amplamente utilizados.

2.2 Algoritmo genético

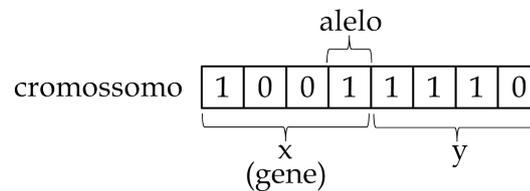
O Algoritmo Genético (AG) é um método clássico de otimização que tem sido utilizado em diversas áreas de pesquisa. Esta técnica foi introduzida por John Holland na década de 1960 e consolidada em 1975 com o estudo dos processos evolutivos (HOLLAND, 1975). Holland se inspirou na teoria da evolução e no processo de seleção natural proposta por Charles Darwin e em operadores genéticos, tais como a seleção, mutação e o cruzamento (MAN; TANG; KWONG, 1996; KRAMER, 2017).

O AG é baseado na geração de novas soluções de um determinado problema a partir de um conjunto de soluções iniciais (geração de filhos a partir de pais). Computacionalmente, as soluções no espaço de busca são representadas por cromossomos, denominados indivíduos de uma população. A qualidade desses indivíduos é avaliada através da função de avaliação, onde os mais aptos têm maior probabilidade de serem selecionados para se reproduzirem e conseqüentemente, de passarem os seus genes para a próxima geração. Esse processo é baseado nos operadores seleção, mutação e cruzamento.

2.2.1 Representação genética

Os indivíduos de uma população do AG podem ser representados de diversas formas. Os algoritmos genéticos clássicos consideram a representação binária, onde cada cromossomo é codificado através de bits (MELANIE, 1998). A codificação binária, utilizada neste trabalho, é ilustrada na Figura 1 para um problema bidimensional. Os cromossomos (sequência de bits) são formados por genes (variáveis x e y) e os alelos são valores binários (0 ou 1) que compõem cada gene.

Figura 1 – Exemplo de representação binária.



2.2.2 População

Na inicialização do algoritmo, há a geração de um conjunto de indivíduos denominado população inicial. Geralmente, a geração desses indivíduos é feita de forma aleatória. Durante o processo, novas populações são criadas através dos operadores genéticos seleção, mutação e cruzamento. Cada indivíduo da população é avaliado através da função de avaliação (KRAMER, 2017).

2.2.3 Função de avaliação (*fitness*)

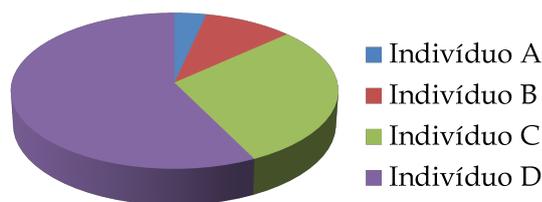
A função de avaliação corresponde à função objetivo a ser otimizada. Ela avalia a aptidão do indivíduo relacionada ao problema e através dessa avaliação, os indivíduos que apresentarem maior aptidão terão maiores possibilidades de serem selecionados para se reproduzirem. A função avaliação é um dos elementos fundamentais no AG, pois é

a ligação existente entre o algoritmo e o problema a ser solucionado (SIVANANDAM; DEEPA, 2008).

2.2.4 Seleção

A seleção é o operador genético associado ao processo de seleção natural. Os melhores indivíduos (mais aptos) terão maior probabilidade de gerar mais descendentes e os piores, menor probabilidade. Existem vários métodos de seleção, dentre eles podem-se destacar a roleta e o torneio (SIVANANDAM; DEEPA, 2008). O critério de seleção por roleta é utilizado neste trabalho e baseia-se na criação de uma roleta, dividida em frações que são proporcionais à aptidão de cada indivíduo. Os indivíduos mais aptos correspondem às maiores frações e, conseqüentemente, terão maior probabilidade de serem selecionados, ao contrário dos menos aptos. Dessa forma, a roleta é girada para o sorteio dos indivíduos que serão selecionados para a reprodução. Por exemplo, na Figura 2, o pior indivíduo (A) corresponde a menor parte da roleta e conseqüentemente, terá menor probabilidade de ser selecionado, enquanto o melhor indivíduo (D) terá maior probabilidade.

Figura 2 – Exemplo de seleção por roleta.

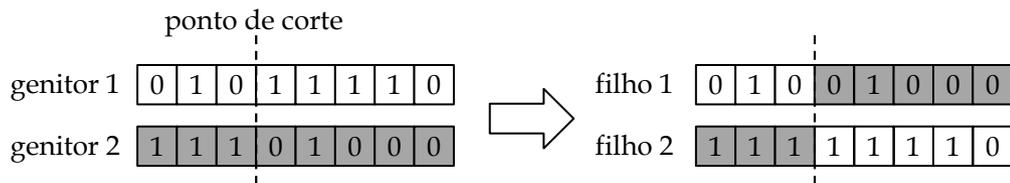


2.2.5 Cruzamento (*crossover*)

Este operador baseia-se na recombinação dos cromossomos dos pais para gerar os filhos. A função deste processo é que as melhores características dos pais sejam passadas aos seus descendentes, gerando melhores soluções para o problema. Os tipos de cruzamentos mais comuns na literatura são o cruzamento de um ponto, cruzamento de dois pontos e o

cruzamento uniforme (KRAMER, 2017). No desenvolvimento da metodologia proposta, foi utilizado o cruzamento de um ponto. Este método consiste na escolha aleatória de um ponto de corte dos cromossomos de dois genitores (determinados pelo processo de seleção) que são cruzados entre si, gerando dois filhos com a combinação genética dos seus genitores.

Figura 3 – Exemplo de cruzamento de um ponto.



2.2.6 Mutação

A mutação representa as mudanças aleatórias que podem ocorrer nas características dos indivíduos. Esse operador genético é utilizado para alterar aleatoriamente o valor dos bits (genes) nos cromossomos e o parâmetro que controla estatisticamente essa alteração é denominado probabilidade de mutação (p_m), sendo um valor definido de acordo com o problema. O principal objetivo é fornecer diversidade genética na população para diminuir a possibilidade do algoritmo não convergir para a solução global, de forma a evitar convergências para mínimos e os máximos locais no espaço da solução (KRAMER, 2017).

2.2.7 Estrutura do AG

A estrutura básica do algoritmo genético é mostrada no fluxograma da Figura 4. Inicialmente, uma população é criada aleatoriamente. Posteriormente, a função de avaliação é calculada para cada cromossomo. Em seguida, os três operadores genéticos básicos do AG são aplicados: (I) o procedimento de seleção é executado para selecionar os pais de acordo com sua função de avaliação; (II) o cruzamento e a mutação são também utilizados

no processo de reprodução. As seqüências de bits de ambos os pais são selecionadas aleatoriamente e utilizadas para produzir novos indivíduos, onde os cruzamentos são realizados para substituir a população anterior. Finalmente, cada bit dos novos indivíduos é alterado com uma pequena probabilidade de mutação, p_m . A qualidade dos novos cromossomos é então avaliada por meio da função de avaliação. O processo é repetido até que a convergência seja atingida.

Figura 4 – Fluxograma do algoritmo genético.



Com base no que foi descrito sobre o AG, a implementação básica computacional pode ser descrita conforme o Algoritmo 1.

Algoritmo 1: O Algoritmo Genético básico.

```
1 início
2   Função de avaliação  $f(\bar{x})$ ,  $\bar{x} = (x_1, x_2, \dots, x_d)^T$  ;
3   Inicialização da população ;
4   Avaliação dos cromossomos da população inicial utilizando a função  $f$ ;
5   Enquanto ( $t < \text{MáxGeração}$  ou  $\text{CritérioDeParada}$ )
6     Selecionar os indivíduos para a reprodução;
7     Aplicar o cruzamento ;
8     Aplicar a mutação ;
9     Avaliar e classificar a população atual utilizando a função  $f$  ;
10  Fim do Enquanto ;
11  Produzir resultados pós-processamento ;
12 fim
```

2.3 Cuckoo Search

O *Cuckoo Search* (CS) é um algoritmo meta-heurístico de busca mais recentemente em 2009 desenvolvido por Yang e Deb (YANG; DEB, 2009). Os estudos existentes sobre o CS na literatura mostram que o algoritmo é mais eficiente do que muitas outras técnicas meta-heurísticas de busca, incluindo o Algoritmo Genético e a Otimização por Enxame de Partículas (*Particle Swarm Optimization*, PSO). O CS tem sido aplicado com resultados satisfatórios em vários campos da engenharia, tais como em sistemas elétricos de potência (MORAVEJ; AKHLAGHI, 2013), aplicações em microondas (NETO et al., 2015), projeto de antenas (KHODIER, 2013) e engenharia biomédica (DEY et al., 2013).

Este algoritmo é baseado em dois conceitos fundamentais: a estratégia de reprodução das aves cuco e o comportamento do voo de Lévy de algumas aves na procura de alimentos. Geralmente, as aves cuco não constroem seus próprios ninhos, mas depositam seus ovos em ninhos de outras aves (aves hospedeiras). Se a ave hospedeira descobrir que os ovos

não são os seus, ela pode descartar os ovos do pássaro cuco ou construir um outro ninho em um novo local. Uma analogia da reprodução de aves cuco é concebida em (YANG; DEB, 2009) para desenvolver o algoritmo do CS, baseando-se em três regras fundamentais (YANG; DEB, 2014):

- Cada ave cuco coloca um ovo de cada vez em um ninho escolhido aleatoriamente entre os ninhos de hospedeiros.
- Um determinado número de ninhos com alta qualidade de ovos (representando as melhores soluções atuais) será preservado para as próximas gerações.
- O número de ninhos hospedeiros disponíveis n é fixo e a probabilidade de uma ave hospedeira distinguir um ovo de cuco é $p_a \in [0, 1]$. Quando o pássaro hospedeiro detecta um ovo do cuco, ele pode descartar o ovo ou abandonar o ninho e construir outro ninho em um novo local aleatório.

Na implementação básica do algoritmo, cada cuco pode colocar apenas um ovo (representando uma solução em um dado espaço de busca de dimensão d) e cada ovo em um ninho corresponde a uma solução, onde o objetivo é utilizar potencialmente as novas e melhores soluções (cucos) para substituir as piores soluções nos ninhos. Cada ninho tem apenas um único ovo e, portanto, não haverá distinção entre ovo, ninho ou cuco, pois cada ninho corresponde a um ovo que também representa um cuco. Uma nova possível solução de um ovo é expressa por

$$\bar{x}^{t+1} = (x_1^{t+1}, x_2^{t+1}, \dots, x_d^{t+1})^T. \quad (2.1)$$

em que d é a dimensão do problema.

Na natureza, muitos animais e insetos procuram alimento de forma aleatória ou semi-aleatória, conforme as características do voo de Lévy (YANG; DEB, 2009). No algoritmo CS, esse aspecto também é considerado no comportamento dos cucos. Para um dado cuco

i , um novo parâmetro de solução x_i^{t+1} é gerado através do voo de Lévy. Matematicamente, o voo de Lévy é definido por

$$x_i^{t+1} = x_i^t + \alpha \cdot Lévy(\lambda), \quad (2.2)$$

em que α é uma constante positiva ajustada de acordo com as dimensões do espaço de busca (YANG; DEB, 2009).

O voo de Lévy é um tipo de busca espacial aleatória, onde o comprimento dos passos é descrito por uma determinada distribuição de probabilidade. A expressão (2.2) é uma equação estocástica para um passo aleatório, que é uma cadeia de Markov, onde o próximo valor x_i^{t+1} depende apenas de dois parâmetros: o valor atual x_i^t e a probabilidade de transição (YANG; DEB, 2009). O comprimento do passo aleatório é obtido através da distribuição de Lévy definida por (2.3) como

$$Lévy(\lambda) \sim u = t^{-\lambda}, \quad (2.3)$$

em que λ define o decaimento da função densidade de probabilidade (FDP) em relação a t .

Os comprimentos dos passos do voo de Lévy são distribuídos de acordo com uma FDP de Cauda Pesada (YANG; DEB, 2009; SALGOTRA; SINGH; SAHA, 2018). Como os voos de Lévy possuem média e variação infinitas, algumas novas soluções estarão localizadas em torno das melhores soluções obtidas no tempo t , e outras estarão localizadas distante das melhores soluções atuais conhecidas (PAVLYUKEVICH, 2007; CHECHKIN; METZLER R.AND KLAFTER; GONCHAR, 2008). Esse recurso permite que o CS explore o espaço de busca com mais eficiência do que outros algoritmos que usam o processo Gaussiano padrão, evitando que o método fique preso em torno de ótimos locais. Computacionalmente, o CS é implementado conforme ilustrado no Algoritmo 2 e, na maioria das suas implementações, são adotados os valores $\alpha = 1$ e $1 < \lambda \leq 3$, como sugerido por (YANG; DEB, 2009; YANG; DEB, 2010).

Algoritmo 2: O algoritmo *Cuckoo Search* original.

```
1 início
2   Função objetivo  $f(\bar{x})$ ,  $\bar{x} = (x_1, x_2, \dots, x_d)^T$  ;
3   Inicialização aleatória da população com  $n$  ninhos do hospedeiro
    $\bar{x}_i = (i = 1, 2, \dots, n)$ ;
4   Enquanto ( $t < \text{MáxGeração}$  ou  $\text{CritérioDeParada}$ )
5     Selecionar um cuco aleatoriamente pelos voos de Lévy e avaliar a sua aptidão
    $F_i$ ;
6     Selecionar um ninho aleatoriamente dentre os  $n$  ninhos (um  $j$ -ésimo ninho) e
   avaliar a sua aptidão  $F_j$ ;
7     Se ( $F_i > F_j$ )
8       Substituir o  $j$ -ésimo ninho por uma nova solução;
9     Fim Se
10    Gerar aleatoriamente  $n_a = p_a \times n$  ninhos (com distribuição de probabilidade
   uniforme);
11    Substituir os  $n_a$  piores ninhos na população pelos ninhos criados
   aleatoriamente;
12    Classificar as soluções e encontrar a melhor solução atual;
13    Fim do Enquanto ;
14    Produzir resultados pós-processamento;
15 fim
```

2.4 Conclusões do capítulo

Neste capítulo, foram abordados os principais conceitos, características e estruturas do Algoritmo Genético e do *Cuckoo Search*. Esses métodos foram utilizados para o desenvolvimento do algoritmo proposto nesta tese.

O capítulo seguinte apresenta o algoritmo de otimização proposto chamado Cuckoo-GRN que combina o CS com o AG. Além disso, são realizados testes em funções matemáticas de *benchmark* para a validação, análise estatística e comparação do Cuckoo-GRN com outros métodos.

3 Cuckoo-GRN: definição da metodologia proposta e *benchmarking*

3.1 Introdução

Os métodos meta-heurísticos na solução de problemas de otimização são baseados em dois pontos importantes: a intensificação e a diversificação. A intensificação consiste na capacidade de aperfeiçoar as soluções existentes, explorando localmente a vizinhança dessas soluções, enquanto que a diversificação se refere à geração de diversas soluções, com intuito de buscar novas soluções, para explorar o espaço de busca em escala global. A combinação desses dois elementos com a seleção das melhores soluções possibilita uma melhor convergência no processo de otimização (YANG, 2010b; LOZANO; GARCÍA-MARTÍNEZ, 2010; YANG, 2010a).

O equilíbrio entre a intensificação e a diversificação são características essenciais para obter um bom desempenho nos métodos de busca (LOZANO; GARCÍA-MARTÍNEZ, 2010). O *Cuckoo Search* original possui esses dois recursos de otimização, intensificação e diversificação. A intensificação é caracterizada pela preservação do melhor ninho (melhor avaliação da função objetivo) nas futuras gerações. A diversificação é produzida tanto pelo voo de Lévy quanto pela inicialização aleatória dos ninhos abandonados (YANG; DEB, 2009).

No presente trabalho, é proposto um novo algoritmo de otimização, denominado Cuckoo-GRN (*Cuckoo Search with Genetically Replaced Nests*), que reúne as características do CS e do AG. No Cuckoo-GRN, a substituição dos ninhos abandonados do *Cuckoo Search* é efetuada de forma mais eficiente, sendo implementada através do uso do Algoritmo Genético. O processo da substituição genética dos ninhos abandonados abrange os aspectos genéticos para a geração dos melhores indivíduos, melhorando o equilíbrio entre a intensificação e a

diversificação. A finalidade da metodologia proposta é obter um desempenho satisfatório do algoritmo, ou seja, acelerar a convergência (redução do número total de avaliações da função objetivo) e obter soluções mais precisas.

A estrutura do algoritmo Cuckoo-GRN é apresentada a seguir e, posteriormente, são realizados testes em problemas matemáticos de *benchmark* com o intuito de analisar o método e compará-lo estatisticamente com os métodos CS, AG e PSO.

3.2 Estrutura do algoritmo Cuckoo-GRN

O desenvolvimento do algoritmo proposto fundamenta-se na substituição genética dos ninhos abandonados, onde o número total de ninhos abandonados n_a é definido como:

$$n_a = n_g + n_r. \quad (3.1)$$

Em (3.1), n_g é o número de ninhos abandonados substituídos geneticamente e n_r é o número de ninhos abandonados substituídos aleatoriamente.

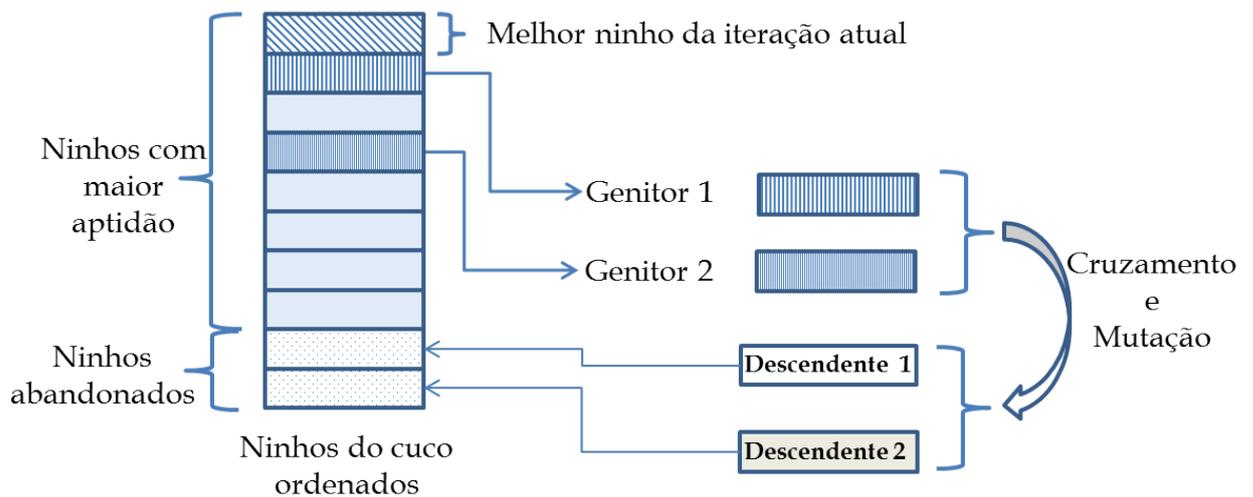
Os ninhos geneticamente substituídos n_g são obtidos usando os conceitos básicos do algoritmo genético, fazendo o uso de *strings* binárias para representar as soluções, e também o uso de operadores genéticos como seleção, mutação e cruzamento. O processo de substituição dos ninhos abandonados, considerando $n_a = n_g = 2$, é ilustrado na Figura 5.

A partir do diagrama da Figura 5, a descrição da substituição genética de ninhos abandonados é feita a partir dos seguintes passos:

1. Normalizam-se os valores de aptidão (avaliação da função objetivo do problema de otimização) calculados para os ninhos da geração atual, e os armazena em variáveis temporárias.
2. Selecionam-se dois genitores com o método da roleta e os representa como *strings* binárias.

3. Executa-se o cruzamento para produzir dois descendentes.
4. Varrem-se todos os bits dos descendentes e executa a negação de bits se uma amostra de uma variável aleatória uniforme (especificamente gerada para cada bit) for menor que (ou igual a) a probabilidade de mutação p_m .
5. Convertem-se os descendentes em seus respectivos conjuntos reais de valores e substituem-se dois dos ninhos abandonados. Se nem todos os ninhos a serem substituídos geneticamente tiverem sido substituídos, volte ao passo 2.

Figura 5 – Diagrama do processo de substituição de ninhos abandonados para $n_a = n_g = 2$.



A implementação computacional do algoritmo Cuckoo-GRN é apresentada no Algoritmo 3 e a substituição genética dos ninhos abandonados é descrita pelas instruções 10 e 11.

Algoritmo 3: O algoritmo Cuckoo-GRN.

```

1 início
2   Função objetivo  $f(\bar{x})$ ,  $\bar{x} = (x_1, x_2, \dots, x_d)^T$  ;
3   Inicialização aleatória da população com  $n$  ninhos do hospedeiro
    $\bar{x}_i (i = 1, 2, \dots, n)$ ;
4   Enquanto ( $t < \text{MáxGeração}$  ou  $\text{CritérioDeParada}$ )
5     Selecionar um cuco aleatoriamente pelos voos de Lévy e avaliar a sua aptidão
    $F_i$ ;
6     Selecionar um ninho aleatoriamente dentre os  $n$  ninhos (um  $j$ -ésimo ninho) e
   avaliar a sua aptidão  $F_j$ ;
7     Se ( $F_i > F_j$ )
8       Substituir o  $j$ -ésimo ninho pela nova solução;
9     Fim do Se
10    Inicializar geneticamente os  $n_g$  ninhos dos ninhos abandonados  $n_a$  (piores);
11    Substituir os  $n_g$  ninhos na população abandonada  $n_a$  com os os ninhos
   inicializados geneticamente;
12    Se ( $n_r > 0$ )
13      Inicializar aleatoriamente os piores ninhos restantes  $n_r = n_a - n_g$ 
14    Fim do Se
15    Classificar as soluções e encontrar a melhor solução global atual;
16  Fim do Enquanto;
17  Resultados pós-processamento;
18 fim

```

O uso da roleta e da mutação não garante que melhores indivíduos sejam sempre gerados. No entanto, a probabilidade de produzir soluções de melhor qualidade é maior se comparada com a substituição aleatória de ninhos abandonados adotada no CS, desde

que p_m e n_g sejam adequadamente ajustados, tal como é estudado na seção seguinte. A substituição genética dos ninhos abandonados aumenta o equilíbrio entre a intensificação e a diversificação, uma vez que o uso de conceitos genéticos produz regularmente melhores indivíduos. Evidentemente, n_r pode ser definido como zero (nenhum ninho precisa ser substituído aleatoriamente), já que os voos de Lévy e a mutação genética fornecem diversificação naturalmente.

3.3 Problemas matemáticos de *benchmark*

Nesta seção, problemas matemáticos de *benchmark* são otimizados de forma a identificar faixas de valores para p_m e n_g , para o Cuckoo-GRN, que garantam equilíbrio aprimorado entre a intensificação e a diversificação em relação ao CS original, AG e PSO. Testes foram realizados em duas funções matemáticas de *benchmark* muito utilizadas na literatura em problemas de otimização (YANG; DEB, 2009): a função de Easom e de De Jong.

A função de Easom dada por:

$$f(x, y) = \cos(x)\cos(y)\exp[-(x - \pi)^2 - (y - \pi)^2] \quad (3.2)$$

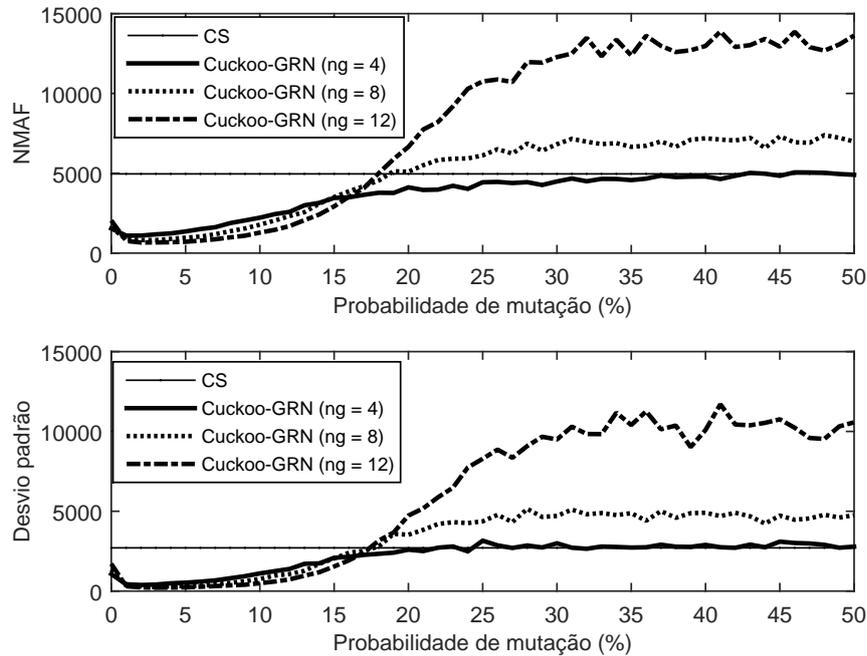
possui um máximo global de $f^*(x, y) = 1$ em (π, π) .

A função de De Jong é dada por:

$$f(x, y) = x^2 + y^2. \quad (3.3)$$

A função (3.3) tem um mínimo global de $f^*(x, y) = 0$ em $(0, 0)$.

O algoritmo proposto é implementado no MATLAB e para analisar o desempenho do método, foram realizados 500 execuções independentes com diferentes valores de n_g e p_m . A tolerância adotada nas simulações é de 10^{-4} para ambas funções e o espaço de busca é definido numa faixa de $[-100, 100]$ para x e y . O número médio de avaliações da função objetivo (NMAF) e o desvio padrão das avaliações da função objetivo são calculadas para medir o desempenho do algoritmo proposto. Os resultados são comparados com

Figura 7 – Função de teste de De Jong (*Cuckoo Search* e Cuckoo-GRN).

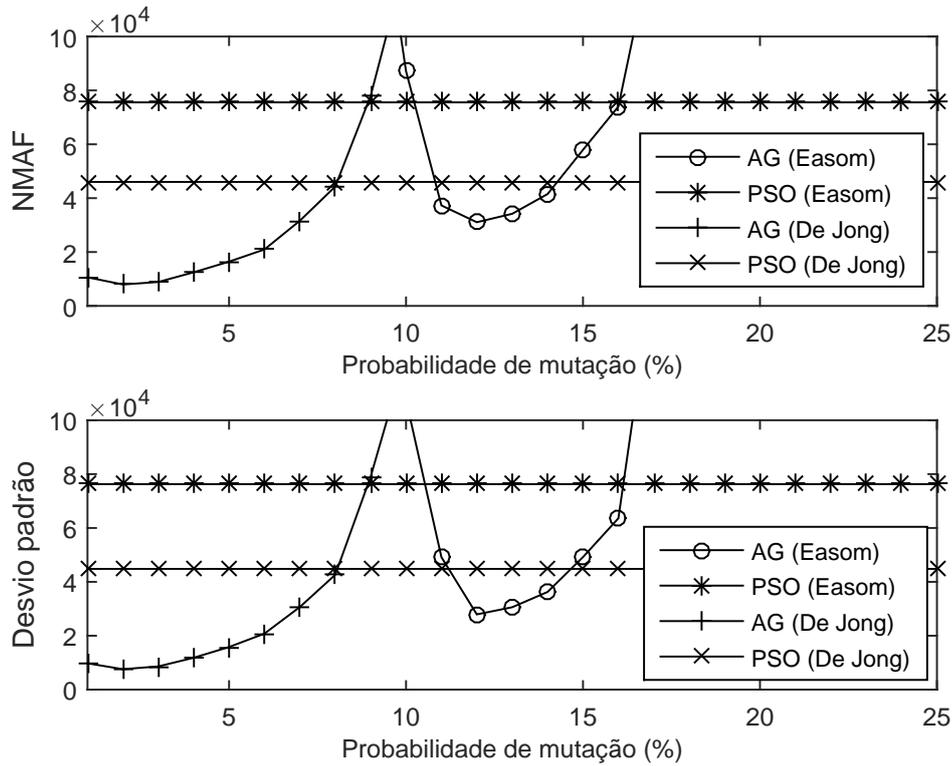
Com intuito de validar o método proposto, outros algoritmos, tais como AG e PSO, também foram testados com as funções de Easom e de De Jong, conforme os resultados ilustrados na Figura 8. O AG e o PSO apresentam o valor do NMAF pelo menos dez vezes maior do que o Cuckoo-GRN para a função de De Jong.

Em relação à função de Easom, o NMAF mínimo é obtido para o AG com $p_m = 12\%$, resultando um valor de aproximadamente $3,1 \times 10^4$. Esse desempenho médio é próximo de um quinto do observado na Figura 6 para o Cuckoo-GRN. O desempenho da PSO é mais do que uma ordem de magnitude inferior que o mínimo NMAF do Cuckoo-GRN obtido para a função de Easom. Esse comportamento também é visto de forma similar no valor do desvio padrão.

Através da Figura 8 é possível observar que os menores valores de NMAF e desvio padrão para o AG e o Cuckoo-GRN são obtidos em torno das mesmas faixas de valores da probabilidade de mutação, dependendo das funções de *benchmark* consideradas. Isso

mostra que o equilíbrio adequado entre intensificação e diversificação está diretamente associado à substituição genética de ninhos abandonados, produzindo o melhor desempenho do Cuckoo-GRN.

Figura 8 – Funções de teste de Easom e de De Jong (AG e PSO).



Os melhores valores de NMAF, desvio padrão e taxa de acerto são mostrados na Tabela 3 com o AG, PSO, CS e Cuckoo-GRN (considerando $p_m = 14\%$ e $n_g = 8$ para a função de Easom e $p_m = 2\%$ e $n_g = 12$ para a função de De Jong). Após vários testes realizados com o Cuckoo-GRN, considerando um conjunto de 16 ninhos, a faixa sugerida dos parâmetros podem ser: $5 \leq p_m \leq 15$ e $8 \leq n_g \leq 12$.

Tabela 3 – Resultados estatísticos para as funções de teste de *benchmark*.

Função	Easom			De Jong		
Método	NMAF	Desvio padrão	Taxa de acerto	NMAF	Desvio padrão	Taxa de acerto
PSO	75.558	73.268	97,3%	46.024	44.808	99,6%
AG	31.060	27.916	98,2%	7.936	7.577	99,8%
	$p_m = 12\%$			$p_m = 2\%$		
CS	14.779	7.393	100%	4.961	2.707	100%
Cuckoo-GRN	6.159	4.214	100%	663	230	100%
	$p_m = 14\%, n_g = 8$			$p_m = 2\%, n_g = 12$		

De acordo com a Tabela 3, os melhores do NMAF e do desvio padrão foram obtidos a partir dos valores de p_m e n_g iguais a 2% e 12, respectivamente, para a função De Jong. Para ilustrar o comportamento dos ninhos do Cuckoo-GRN, foi realizada uma simulação com $p_m = 2\%$ e $n_g = 12$, onde foram necessárias 17 iterações para obter a solução ótima (0,0) da função de De Jong. No algoritmo Cuckoo-GRN, os ninhos são inicializados aleatoriamente, conforme a Figura 9(a). Na iteração 2, Figura 9(b), nota-se que alguns valores dos ninhos se localizam numa área em torno do valor ótimo e alguns mais distantes. Na iteração 8, Figura 9(c), a maioria dos ninhos se concentram próximos ao valor ótimo. E, a solução é encontrada na iteração 17, Figura 9(d). Um exemplo de 20 passos do voo de Lévy é mostrado na Figura 10 com o movimento inicial em (-1.06, 3.76), onde é possível observar as características da intensificação e da diversificação do algoritmo.

Figura 9 – Comportamento dos ninhos do Cuckoo-GRN para a função De Jong com $p_m = 2\%$ e $n_g = 12$. (a) Iteração 1, (b) Iteração 2, (c) Iteração 8 e (d) Iteração 17.

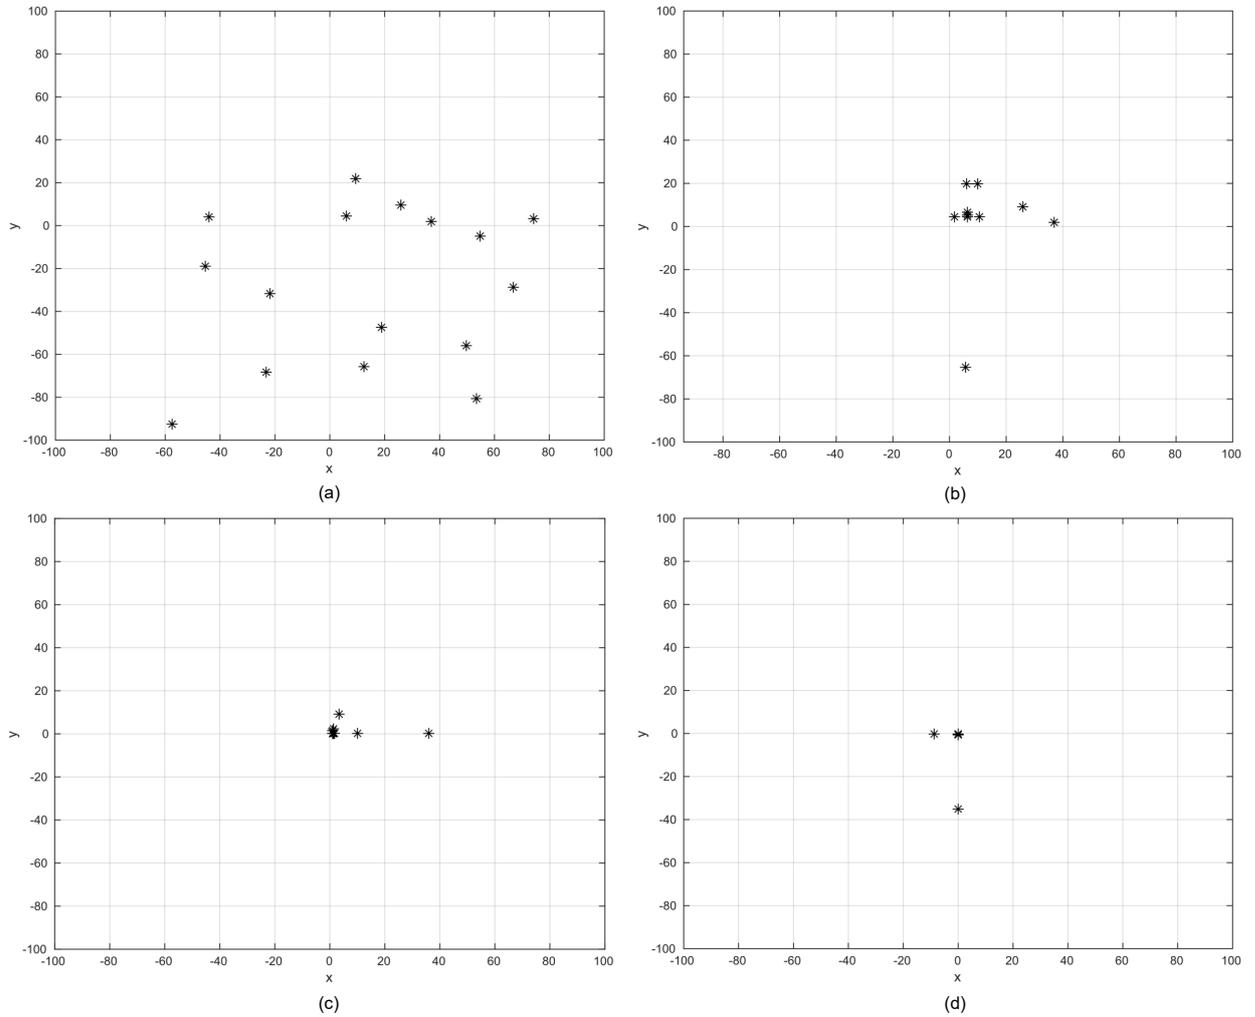
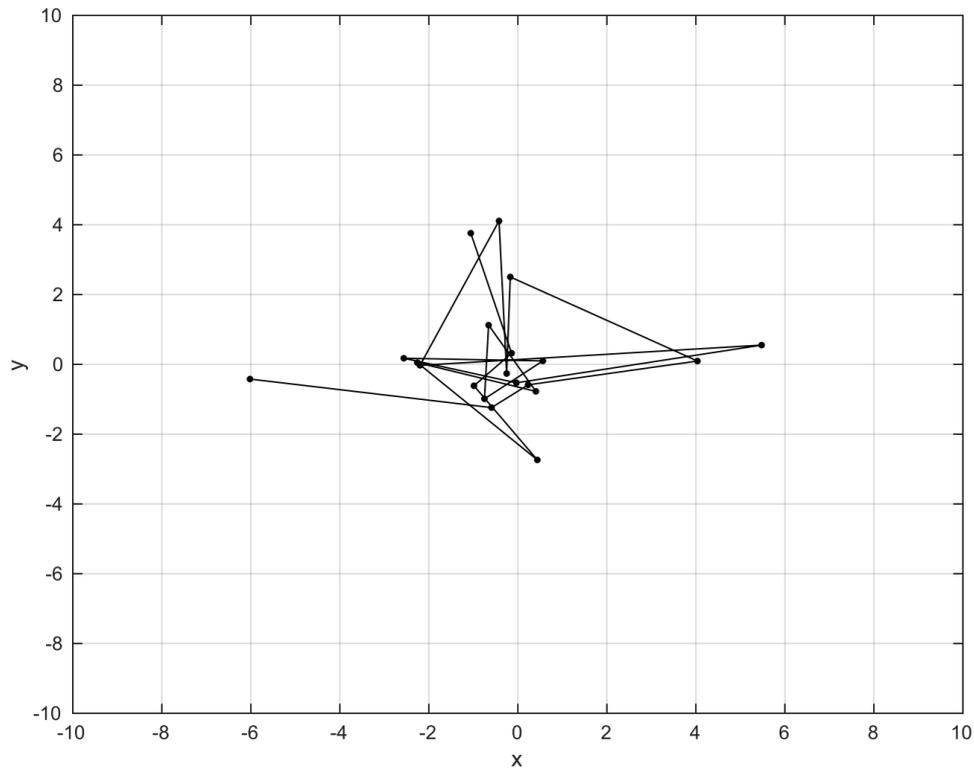


Figura 10 – Exemplo de 20 passos do voo de Lévy.



Conforme mostram os resultados apresentados nesta seção, existem faixas de valores para p_m e n_g que produzem equilíbrio aprimorado entre a intensificação e a diversificação para o Cuckoo-GRN em relação ao AG, PSO e CS. Dessa forma, a metodologia proposta é estatisticamente consistente, mostrando-se superior aos referidos métodos de otimização quando aplicado às funções de *benchmark* Easom e De Jong. Portanto, pode-se dizer que a metodologia proposta (Cuckoo-GRN) está devidamente validada.

3.4 Conclusões do capítulo

O algoritmo proposto Cuckoo-GRN foi apresentado neste capítulo. Inicialmente, a estrutura do Cuckoo-GRN foi descrita, onde os ninhos abandonados do CS são obtidos através da implementação do AG com a finalidade de melhorar o equilíbrio entre a intensificação e a diversificação. Posteriormente, duas funções matemáticas de *benchmark*,

função de Easom e De Jong, foram usadas para validação, análise estatística e comparação do método proposto com o CS, AG e PSO. Os resultados mostraram que o Cuckoo-GRN possui um melhor desempenho (menor valor de NMAF e desvio padrão) do que o CS, AG e PSO para as funções matemáticas testadas. É importante salientar que, através dos resultados obtidos, foi possível observar que o equilíbrio adequado entre intensificação e diversificação do Cuckoo-GRN está diretamente associado à substituição genética de ninhos abandonados.

No próximo capítulo, o método Cuckoo-GRN é aplicado em um problema de maior complexidade (multiobjetivo): alocação de unidades de GD em sistemas de distribuição para redução de perdas ativas e melhoria do perfil de tensão. Os valores adequados de p_m e n_g para este problema também são estudados.

4 Definição do problema e resultados

4.1 Introdução

Neste capítulo serão apresentados o problema a ser otimizado com o uso do método proposto Cuckoo-GRN e os resultados obtidos. A metodologia será testada utilizando os sistemas de distribuição de 33 barras (KASHEM et al., 2000) e de 119 barras (ZHANG; FU; ZHANG, 2007).

4.2 Definição do problema

A necessidade da capacidade de geração de energia elétrica cada vez maior tem resultado em um crescente interesse na utilização de unidades de geração distribuída (GD). Diversas são as vantagens na rede elétrica com a inserção de GD, tais como redução nos custos do transporte de energia, redução nas perdas de potência ativa, aumento na confiabilidade e melhoria no perfil de tensão. Contudo, essa inclusão de unidades de GD de forma inadequada pode causar impactos no sistema. No planejamento de sistemas de distribuição é importante destacar os seguintes aspectos para a implantação de GD: a localização, a capacidade e o número de unidades.

Nesse contexto, neste trabalho é proposto o algoritmo Cuckoo-GRN, descrito na seção 3.2 e, além disso, a aplicação do método para obter os valores ótimos dos parâmetros da unidade de geração distribuída para avaliar os impactos da GD em um sistema de distribuição. Com a aplicação do Cuckoo-GRN, são calculados a melhor localização, capacidade e fator de potência da GD com os seguintes objetivos: minimizar as perdas de potência ativa e melhorar o perfil de tensão do sistema. A função a ser otimizada e que represente esses objetivos é descrita a seguir, juntamente com as restrições de igualdade e desigualdade às quais estará sujeita.

4.2.1 Função objetivo

A definição matemática do problema multiobjetivo de interesse é expressa por (SAHA; MUKHERJEE, 2016; CHAKRAVORTY; DAS, 2001)

$$F = w_1F_1 + w_2F_2 + w_3F_3, \quad (4.1)$$

que é a função objetivo empregada na otimização dos parâmetros da unidade de GD, visando a minimização dos objetivos F_1 , F_2 e F_3 . Em (4.1), w_1 , w_2 e w_3 são os pesos relativos aos objetivos F_1 , F_2 e F_3 , respectivamente, que são definidos a seguir.

Vale ressaltar que no cálculo da função objetivo (4.1), as funções F_1 , F_2 e F_3 foram normalizadas para evitar problemas de escala.

4.2.1.1 Minimização de perdas de potência ativa

A inclusão de unidades de GD apresenta como uma das vantagens a redução de perdas ativas no sistema de distribuição. A primeira parcela da função objetivo (4.1) se refere à otimização dos valores do dimensionamento e da localização da GD de modo a minimizar as perdas ativas, podendo ser expressa por (4.2)

$$F_1 = \sum_{m=1}^N G_m [V_i^2 + V_j^2 - 2V_iV_j \cos \theta_{ij}]. \quad (4.2)$$

Em (4.2), G_m é a condutância do ramo m que conecta as barras i a j ; as magnitudes de tensão nas barras i e j são representadas por V_i e V_j , respectivamente; o ângulo $\theta_{ij} = \theta_i - \theta_j$, em que θ_i e θ_j são ângulos de tensão das barras i e j , respectivamente; N é o número total de ramos no sistema de distribuição.

4.2.1.2 Desvio de tensão

A segunda parcela da função objetivo (4.3) está relacionada à minimização do desvio de tensão nas barras do sistema de distribuição (SAHA; MUKHERJEE, 2016). O desvio é expresso através da relação entre a tensão na barra e um valor especificado de tensão (para este caso, adotou-se a tensão nominal, ou seja, 1,0 p.u.). A magnitude de tensão é um

importante fator para avaliar a segurança do sistema. A minimização do desvio contribui para a melhoria no perfil de tensão de sistemas de distribuição.

$$F_2 = \sum_{i=1}^{N_b} (V_i - V_{nom})^2. \quad (4.3)$$

4.2.1.3 Índice de estabilidade de tensão

O último termo que compõe a função objetivo deste trabalho está associado ao índice de estabilidade de tensão (IET). Este índice indica o nível de estabilidade de tensão nas barras do sistema. Quanto menor for este índice em uma barra, mais sensível será com relação ao colapso de tensão (CHAKRAVORTY; DAS, 2001). O cálculo de IET é conforme

(4.4)

$$IET_i = V_j^4 - 4(P_i x_{ij} - Q_i r_{ij})^2 - 4(P_i r_{ij} + Q_i x_{ij})V_j^2, \quad (4.4)$$

em que $i = 2, 3, 4, \dots, N_b$; x_{ij} e r_{ij} são, respectivamente a reatância e a resistência da linha entre as barras i e j ; e P_i e Q_i são a potência ativa e reativa das cargas localizadas na barra i .

É importante observar que, diferentemente dos valores de perdas ativas e desvio de tensão, o índice de estabilidade de tensão deve ser maximizado, pois quanto maior for o valor de IET, mais estável será o sistema com relação à tensão. Contudo, a função objetivo (4.1) é um problema de minimização e, desse modo, o termo F_3 adotado será

$$F_3 = IET^{-1}. \quad (4.5)$$

4.2.2 Restrições

Na implementação do algoritmo Cuckoo-GRN, foram consideradas as seguintes restrições de igualdade e desigualdade para a obtenção dos valores ótimos da GD: balanço de potência, limites de tensão, capacidade da GD e fator de potência (FP).

4.2.2.1 Restrições de balanço de potência

As restrições de igualdade das equações de fluxo de potência representam o balanço de potência ativa e reativa em todas as barras como mostra (4.6) e (4.7). Assim, tem-se

$$P_{gi} - P_{di} = V_i \sum_{j \in K} V_j (G_{ij} \cos \theta_{ij} + B_{ij} \sin \theta_{ij}), \quad \forall i = 1, 2, \dots, N_b \quad (4.6)$$

e

$$Q_{gi} - Q_{di} = V_i \sum_{j \in K} V_j (G_{ij} \sin \theta_{ij} - B_{ij} \cos \theta_{ij}), \quad \forall i = 1, 2, \dots, N_b, \quad (4.7)$$

onde K é o conjunto de barras adjacentes à barra i (incluindo a barra i), N_b é o número total de barras no sistema de distribuição, P_{gi} e Q_{gi} são as potências ativa e reativa dos geradores na barra i , P_{di} e Q_{di} são as potências ativa e reativa da demanda na barra i e, G_{ij} e B_{ij} são as partes real e imaginária, respectivamente, da matriz admitância nodal.

4.2.2.2 Restrições dos limites de tensão

A tensão V_i na barra i deve variar entre as tensões mínima e máxima permitidas, ou seja,

$$V_i^{min} \leq V_i \leq V_i^{max}. \quad (4.8)$$

Neste estudo, são adotados os valores 0,90 e 1,05 p.u., respectivamente, para as tensões V_i^{min} e V_i^{max} em (4.8).

4.2.2.3 Restrição da capacidade de potência da GD

Neste trabalho, a potência ativa da unidade de GD (P_{GD}) não deve exceder a demanda total do sistema P_D . Portanto, nos cálculos, admite-se a restrição de capacidade de potência da GD

$$\sum P_{GD} \leq P_D. \quad (4.9)$$

Se a condição (4.9) não for obedecida, pode ocorrer fluxo de potência reverso.

4.2.2.4 Restrições do fator de potência

Diferentes tipos de GDs podem ser modelados, incluindo fontes renováveis e não renováveis, e podem fornecer ou absorver potência reativa (lead/lag) da rede, ou também operar com fator de potência unitário (potência reativa zero). Este trabalho considera que o FP das GDs (FP_{GD}) pode variar de acordo com

$$FP_{GD}^{min} \leq FP_{GD} \leq FP_{GD}^{max}. \quad (4.10)$$

Em (4.10) $FP_{GD}^{min} = -0,95$ e $FP_{GD}^{max} = 0,95$.

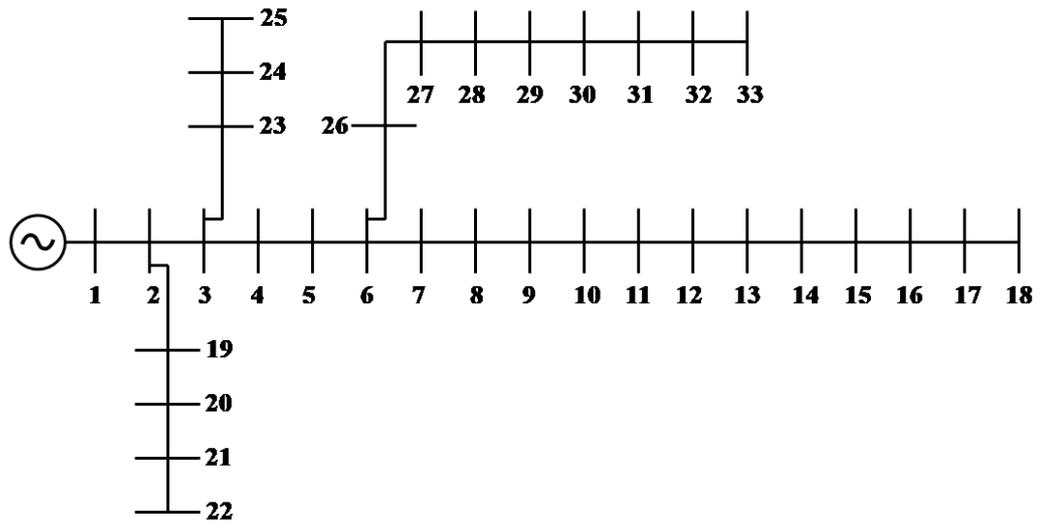
4.3 Resultados

O algoritmo proposto é implementado no MATLAB, onde o software MATPOWER (ZIMMERMAN; MURILLO-SÁNCHEZ; THOMAS, 2011) é utilizado para resolver o problema do fluxo de potência. A metodologia proposta é testada em dois sistemas de distribuição, o sistema de 33 barras e o de 119 barras, sendo que a função objetivo é concebida para a minimização das perdas de potência ativa e para a melhoria na estabilidade de tensão e no perfil de tensão das barras. Os parâmetros adotados nas simulações são $n = 16$, $\alpha = 1$ e $\lambda = 1,5$. Além disso, todas as variáveis genéticas utilizadas são representadas por 25 *bits*, fornecendo uma resolução numérica satisfatória para o problema.

4.3.1 Sistema de 33 barras: otimização da localização e do dimensionamento da GD

O sistema de distribuição radial de 33 barras com nível de tensão de 12,66 kV utilizado neste trabalho é ilustrado na Figura 11 (KASHEM et al., 2000). As potências ativa e reativa da carga total são 3.720 kW e 2.300 kVar, respectivamente, e as perdas de potência ativa sem a instalação de GDs são de 211 kW.

Figura 11 – Sistema de distribuição de 33 barras.



Com a finalidade de comparar o Cuckoo-GRN com outros algoritmos de otimização, é assumido que os geradores distribuídos operam com fator de potência unitário (apenas a potência ativa é gerada e nenhuma potência reativa é produzida ou consumida). A função de avaliação é calculada através de (4.1), com $w_1 = 1$, $w_2 = 0$ e $w_3 = 0$ e, portanto, somente as perdas de potência ativa são minimizadas. Neste caso, são alocados diferentes números de GDs na rede usando o método proposto Cuckoo-GRN. Os resultados são comparados com outros métodos disponíveis na literatura, incluindo fator de sensibilidade de perdas (HUNG; MITHULANANTHAN, 2013), método analítico aprimorado (HUNG; MITHULANANTHAN, 2013), fluxo de potência exaustivo (HUNG; MITHULANANTHAN, 2013), fluxo de potência ótimo analítico (MAHMOUD; YORINO; AHMED, 2016), abordagem analítica (NAIK; KHATOD; SHARMA, 2015) e algoritmo inteligente *water drop* (PRABHA et al., 2015). Os resultados são apresentados na Tabela 4 e a comparação é feita em relação à localização e capacidade da GD.

Tabela 4 – Comparação entre diferentes métodos para o sistema de 33 barras, considerando fator de potência unitário da GD.

Número de GDs	Método	Barra	Capacidade da GD (kW)	Perdas (kW)
1	Fator de sensibilidade de perdas	18	743	146,82
	Método analítico aprimorado	6	2601	111,11
	Fluxo de potência exaustivo	6	2601	111,11
	Abordagem analítica	6	2480	104,08
	FPO analítico	6	2590	111,02
	Algoritmo inteligente <i>water drop</i>	6	2490	111,01
	Cuckoo-GRN	29	2306,76	100,23
2	Fator de sensibilidade de perdas	18	720	100,69
		33	900	
	Método analítico aprimorado	6	1800	91,63
		14	720	
	Fluxo de potência exaustivo	12	1020	87,63
		30	1020	
	Abordagem analítica	6	2480	92,48
		16	410	
	FPO analítico	13	852	87,17
		30	1158	
Cuckoo-GRN	15	972,66	78,81	
	29	1748,70		
3	Fator de sensibilidade de perdas	18	720	85,07
		33	810	
		25	900	
	Método analítico aprimorado	6	900	81,05
		12	900	
		31	720	
	Fluxo de potência exaustivo	13	900	74,27
		30	900	
		24	900	
	Abordagem analítica	6	1730	79,51
		16	530	
		25	770	
	FPO analítico	13	798	72,79
		24	1099	
		30	1050	
	Algoritmo inteligente <i>water drop</i>	9	600,30	85,78
	16	300		
	30	1011,2		
Cuckoo-GRN	8	996,87	70,06	
	25	1180,65		
	32	843,76		

Os resultados da Tabela 4 mostram que o algoritmo proposto, Cuckoo-GRN, obteve melhor desempenho na redução de perdas quando comparado a outros métodos de otimização. Com a inclusão de apenas uma GD de 2.306,76 kW na barra 29, o Cuckoo-GRN obteve uma redução de perdas de potência ativa de 52,5% (100,23 kW). Além disso, observa-se que com o aumento de número de unidades de GD, houve também uma significativa redução de perdas ativas. Para a alocação de duas e três GDs, utilizando o Cuckoo-GRN, ocorreu uma diminuição nas perdas de 62,5 e 66,8% para cada caso, respectivamente.

Dado que o Cuckoo-GRN é um algoritmo meta-heurístico bio-inspirado, foi necessário analisar estatisticamente o desempenho do método. Foram realizadas 500 execuções independentes com os algoritmos Cuckoo-Search e Cuckoo-GRN para a obtenção da localização e dimensionamento ótimos de uma única GD no sistema de 33 barras, operando com fator de potência unitário. Para analisar o impacto que os parâmetros do algoritmo possuem no seu desempenho, as simulações foram realizadas com $n_a = 4$ para o CS e, para o Cuckoo-GRN, foram adotados diferentes valores de probabilidade de mutação ($0\% \leq p_m \leq 13\%$), ninhos abandonados ($4 \leq n_a \leq 12$) e ninhos abandonados substituídos geneticamente ($2 \leq n_g \leq 12$).

As Figuras 12 e 13 mostram os valores do número médio de avaliações da função objetivo necessários para atingir a solução ótima para o CS e o Cuckoo-GRN. Na Figura 12 são mostrados os resultados do Cuckoo-GRN com $n_a = 4$ e na Figura 13, do Cuckoo-GRN com $n_a = 5$, adotando diferentes valores de n_g e n_r ($n_a = n_g + n_r$). Através desses resultados, é possível observar que o algoritmo CS requer uma média de 913,08 avaliações da função objetivo. Esse número diminui consideravelmente quando se utiliza o Cuckoo-GRN, independentemente dos valores de p_m , n_g e n_r . Por exemplo, na Figura 12, há uma redução de 38,51% no valor do NMAF (de 913,08 para 561,44) quando o Cuckoo-GRN é aplicado, com $p_m = 4\%$, $n_g = 2$ e $n_r = 2$, mostrando uma convergência melhor do que o CS. Outro importante aspecto notado é que, utilizando o Cuckoo-GRN, o NMAF é reduzido significativamente quando o valor de n_g aumenta de 2 para 4, considerando p_m igual a 0, 12 e 13%.

Além disso, nota-se que os menores valores de NMAF da Figura 12 são para o caso do Cuckoo-GRN com $n_g = 4$ e $n_r = 0$ se comparados a outros casos com $n_a = 4$. O mesmo comportamento é observado na Figura 13 em que o caso com $n_g = 5$ e $n_r = 0$ apresenta menores valores de NMAF do que o caso com $n_g = 4$ e $n_r = 1$. Outras simulações foram realizadas mostrando esse mesmo comportamento, ou seja, para valores fixos de n_a , reduzindo o valor de n_r , também reduz o valor de NMAF.

Figura 12 – NMAF para o CS e Cuckoo-GRN com $n_a = 4$ e diferentes valores de p_m .

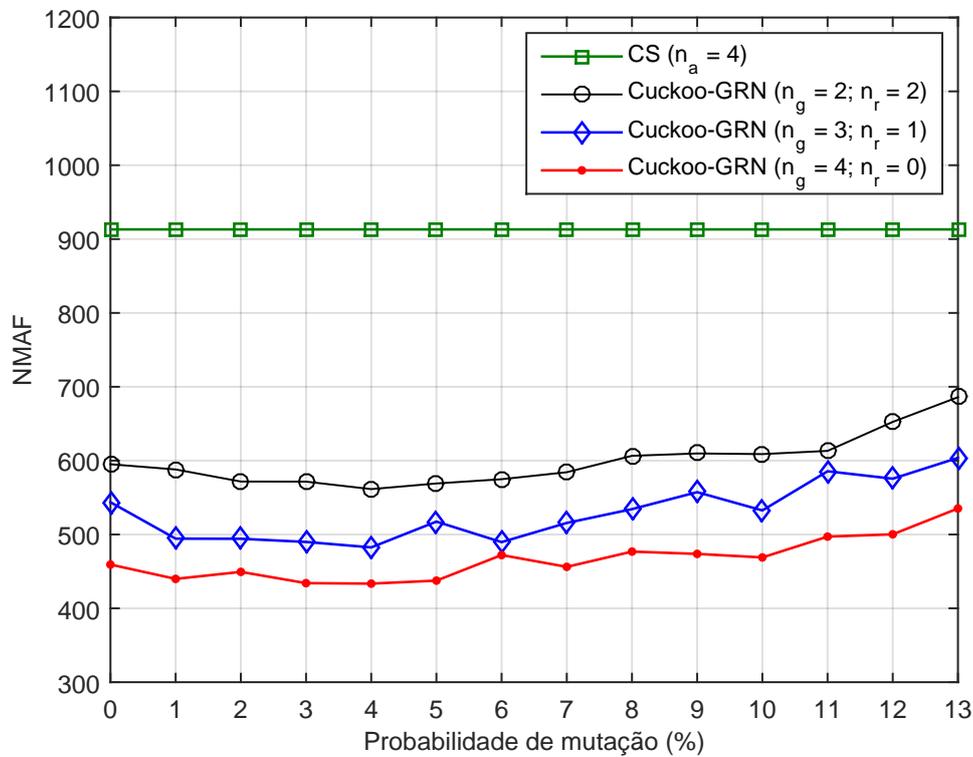
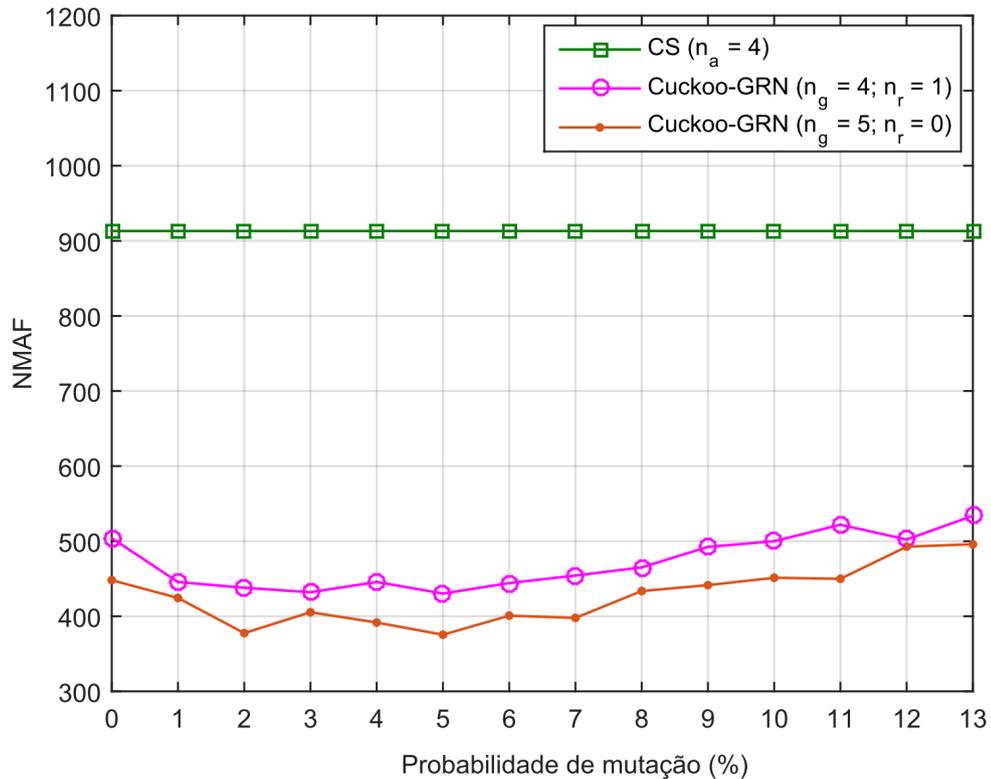
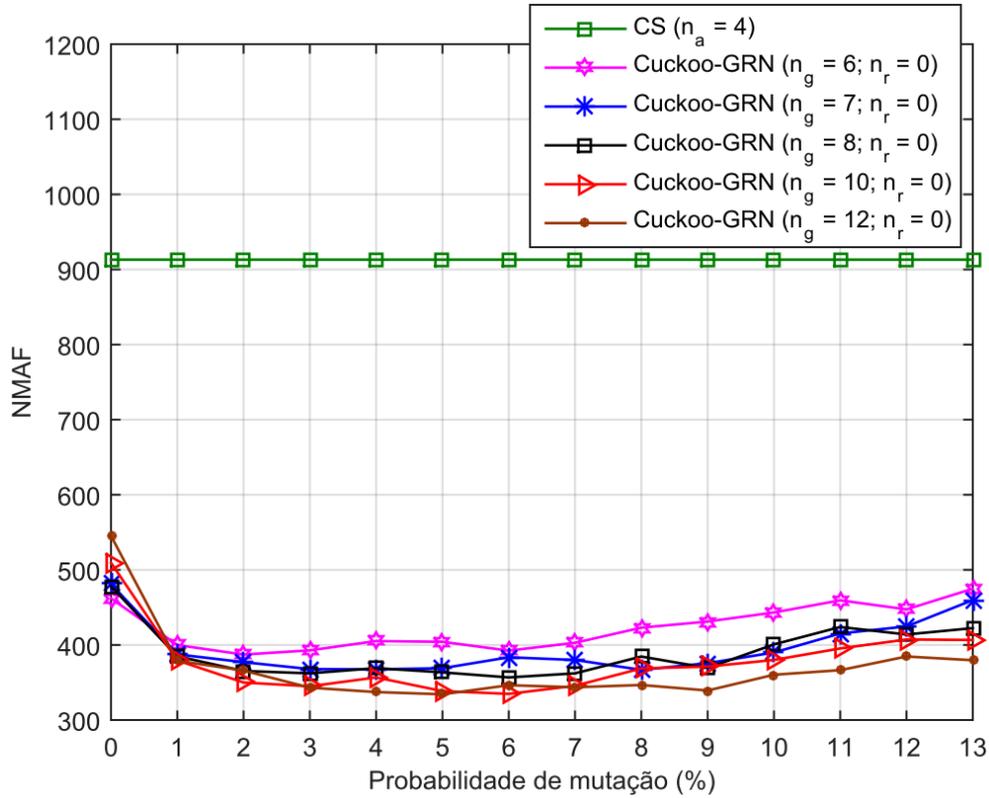


Figura 13 – NMAF para o CS com $n_a = 4$ e Cuckoo-GRN com $n_a = 5$ e diferentes valores de p_m .



A partir dos resultados analisados, outros testes foram simulados considerando $n_r = 0$ e $n_a = n_g$ ($6 \leq n_g \leq 12$), conforme a Figura 14. Esses testes mostram que a variação do NMAF é pequena quando $0 \leq p_m \leq 3$ para os casos em que $6 \leq n_g \leq 12$, ou seja, houve uma pequena redução do NMAF de um caso para outro ($n_g = 6$ até $n_g = 12$). Contudo, essa redução é mais relevante para $p_m \geq 4$ devido ao fato do ajuste da probabilidade de mutação equilibrar melhor a intensificação e a diversificação.

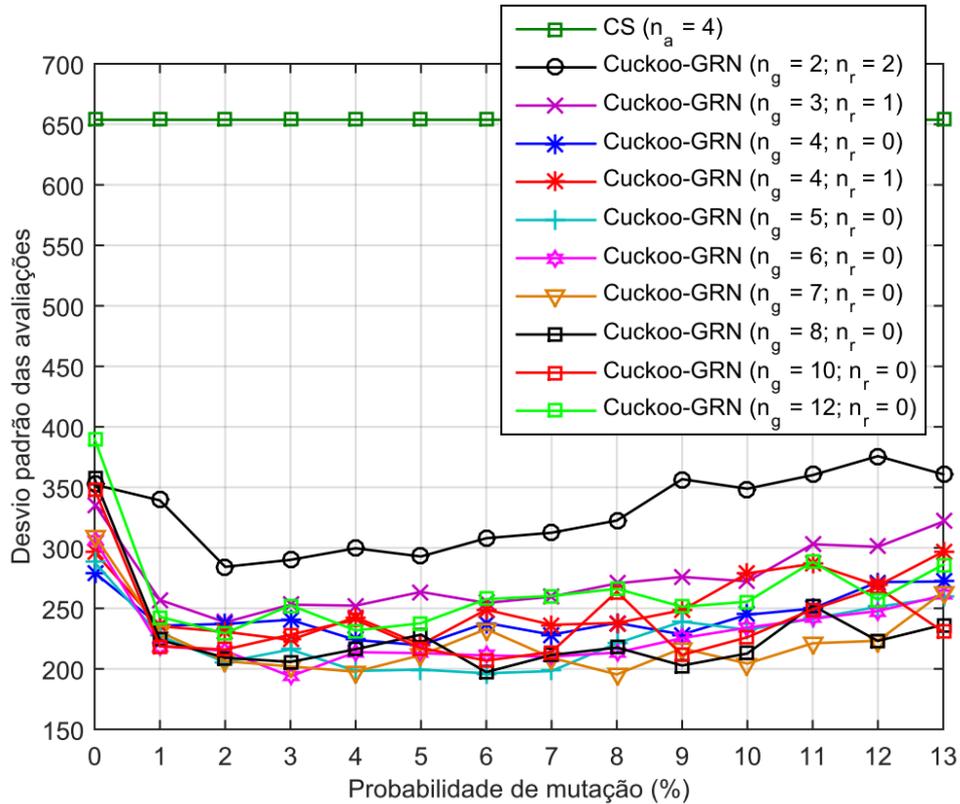
Figura 14 – NMAF para o CS com $n_a = 4$ e Cuckoo-GRN com $6 \leq n_a \leq 12$ e diferentes valores de p_m .



O desvio padrão das avaliações para o CS e o Cuckoo-GRN são ilustrados na Figura 15. Os resultados mostram que o desvio padrão diminui de forma significativa quando utiliza-se o algoritmo proposto Cuckoo-GRN, independentemente dos valores adotados para os parâmetros p_m , n_g e n_r .

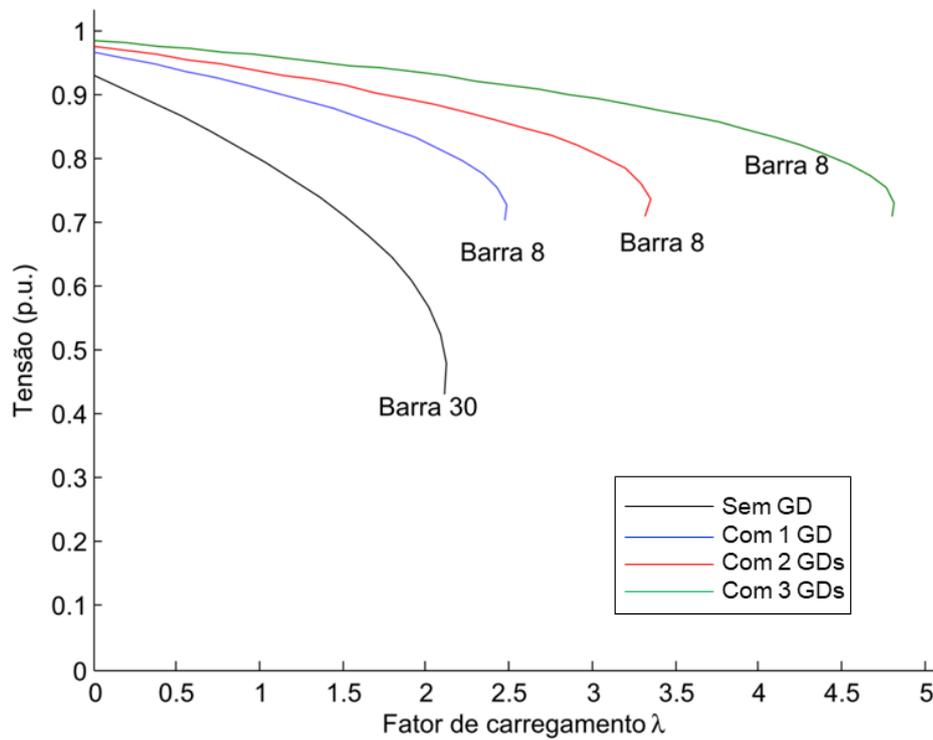
Após realizar uma análise estatística dos resultados, o melhor conjunto obtido de parâmetros do Cuckoo-GRN foi $n_a = n_g = 12$, $n_r = 0$ e $p_m = 5\%$. Para este caso, o NMAF foi reduzido de 63,39% com relação ao CS e o desvio padrão foi igual a 237,7.

Figura 15 – Desvio padrão das avaliações para diferentes valores de $n_a = 4$ e p_m .



A Figura 16 mostra as curvas PV antes e depois da alocação ótima da GD no sistema. É possível observar que, sem a GD, o ponto de máximo carregamento da curva é menor do que com a inserção da GD. Além disso, à medida que o número de GD aumenta, o ponto de máximo carregamento aumenta. Isso mostra que para o sistema de 33 barras, a inserção de unidades de geração distribuída contribui na melhoria da estabilidade de tensão do sistema.

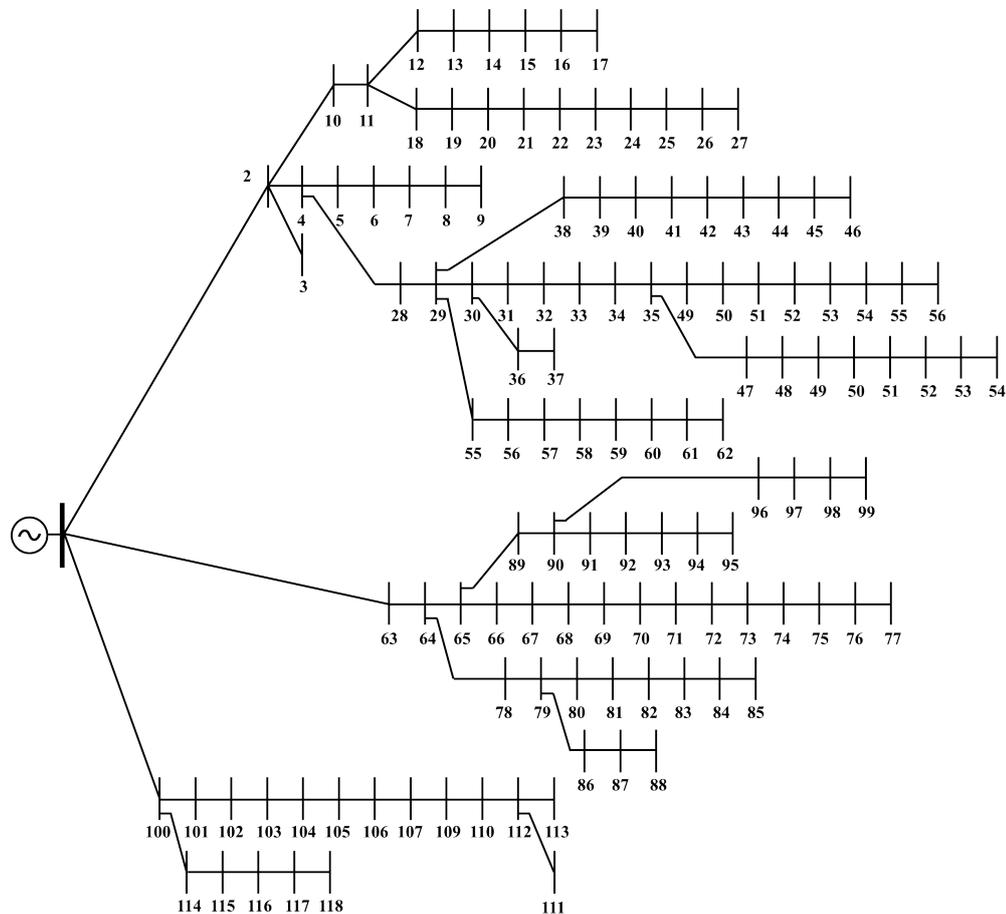
Figura 16 – Curvas PV do sistema 33 barras antes e depois da inserção de GD.



4.3.2 Sistema de 119 barras

O algoritmo proposto também foi testado em um sistema maior, o sistema de distribuição de 119 barras (Figura 17), composto por 118 chaves seccionadoras e 15 chaves de interconexão. Os parâmetros do sistema são dados em (ZHANG; FU; ZHANG, 2007). As condições de carga total ativa e reativa são de 22.709,7 kW e 17.041,1 kVAr, respectivamente, e as perdas totais de potência ativa são de 1.296 kW.

Figura 17 – Sistema de distribuição de 119 barras.



Para avaliar o desempenho do Cuckoo-GRN em relação a outros métodos, foram estudados dois cenários com o uso do sistema de 119 barras:

Cenário 1: Otimização multiobjetivo visando minimização de perdas e desvio de tensão, e maximização do índice de estabilidade de tensão para a localização e o dimensionamento da GD. Número de GDs consideradas igual a 3, 4 e 5 com fator de potência fixo igual a 1 e 0,95. Função objetivo (4.1) com pesos $w_1 = 1$, $w_2 = 0,60$ e $w_3 = 0,35$ (SAHA; MUKHERJEE, 2016).

Cenário 2: Otimização mono-objetivo visando minimização de perdas para localização, dimensionamento e fator de potência da GD. Função objetivo (4.1) com pesos

$$w_1 = 1, w_2 = 0 \text{ e } w_3 = 0.$$

4.3.2.1 Cenário 1 - Otimização multiobjetivo visando minimização de perdas e desvio de tensão, e maximização do IET

Para avaliar o desempenho estatístico do método proposto, foram realizadas 500 execuções independentes do Cuckoo-GRN e do CS original, ou seja, cada algoritmo foi simulado 500 vezes isoladamente. Os algoritmos PSO e AG também foram simulados para comparar o desempenho entre os métodos. Os parâmetros do Cuckoo-GRN utilizados em todas as simulações foram $n_a = n_g = 12$, $n_r = 0$ e $p_m = 5\%$. Este parâmetros foram definidos com base na análise estatística da Seção 4.3.1. No AG, a probabilidade de mutação utilizada foi de 3%.

Na Figura 18, são mostrados os resultados da otimização de três GDs em termos do dimensionamento e localização, considerando o fator de potência igual a 0,95. A média das avaliações da função objetivo em função do número de avaliações da função objetivo é apresentada para cada método de otimização (Cuckoo-GRN, CS, AG e PSO). Estatisticamente, observa-se que em 4.000 avaliações, o Cuckoo-GRN foi o único método que gerou a média das avaliações da função objetivo abaixo de 0,45. Também é importante notar que um resultado próximo a esse valor foi atingido em somente 1.000 avaliações. Em 4.000 avaliações, o CS é capaz de atingir um resultado um pouco menor do que 0,46, seguido por AG e PSO (ambos com valores próximos a 0,48).

Quando o fator de potência das GDs é alterado para 1, são observados na Figura 19 comportamentos de convergência semelhantes aos da Figura 18. Em 1.000 avaliações, a média das avaliações da função objetivo do método proposto é igual a 0,47. Já os métodos CS, AG e PSO obtém os valores de 0,478, 0,492 e 0,503, respectivamente, em 4.000 avaliações.

Figura 18 – Otimização de três GDs com fator de potência igual a 0,95.

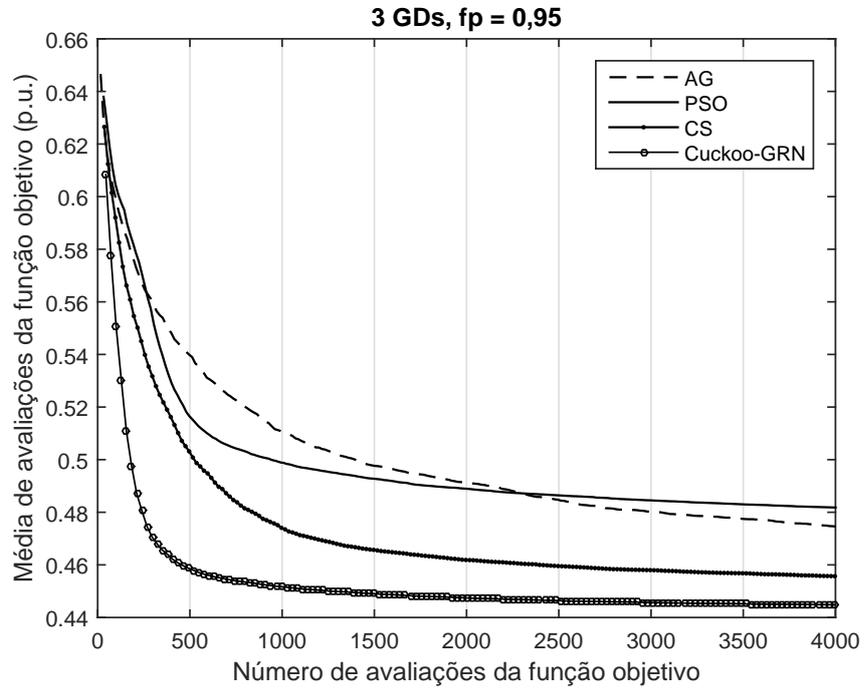
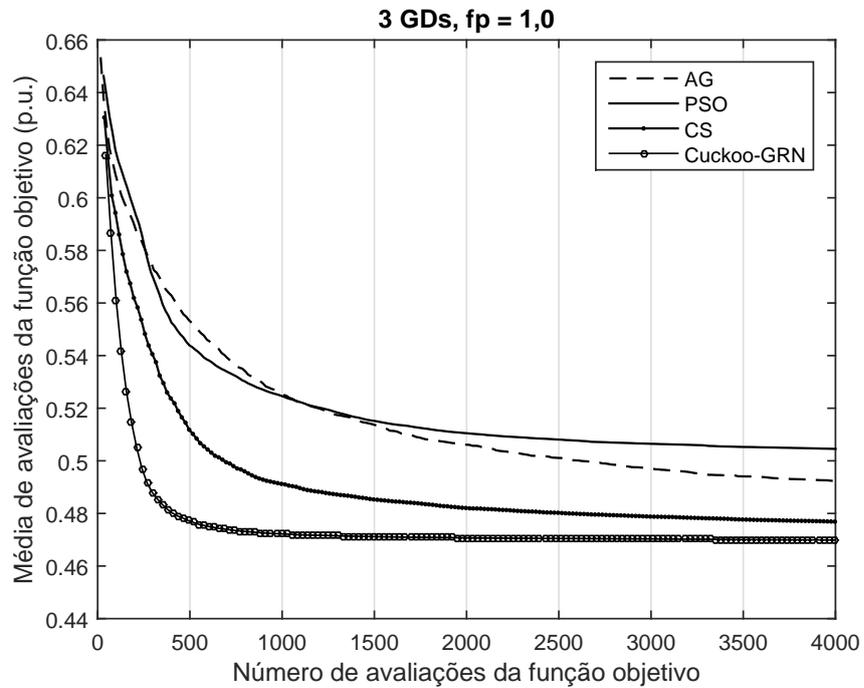


Figura 19 – Otimização de três GDs com fator de potência igual a 1,0.



Quando considera-se a localização e dimensionamento ótimos de quatro GDs simultaneamente no sistema, novamente o Cuckoo-GRN conseguiu atingir a convergência mais rápida do que CS, PSO e AG, fornecendo também os menores valores da média de avaliações tanto com o fator de potência igual a 0,95 (Figura 20) quanto 1 (Figura 21). Em 1.500 avaliações, o Cuckoo-GRN convergiu para 0,438 e 0,46, considerando fator de potência igual a 0,95 e 1, respectivamente, enquanto que o CS, PSO e AG convergiram para 0,45, 0,457 e 0,459 (FP igual a 0,95) e 0,47, 0,471 e 0,478 (FP igual a 1) com 4.000 avaliações.

Figura 20 – Otimização de quatro GDs com fator de potência igual a 0,95.

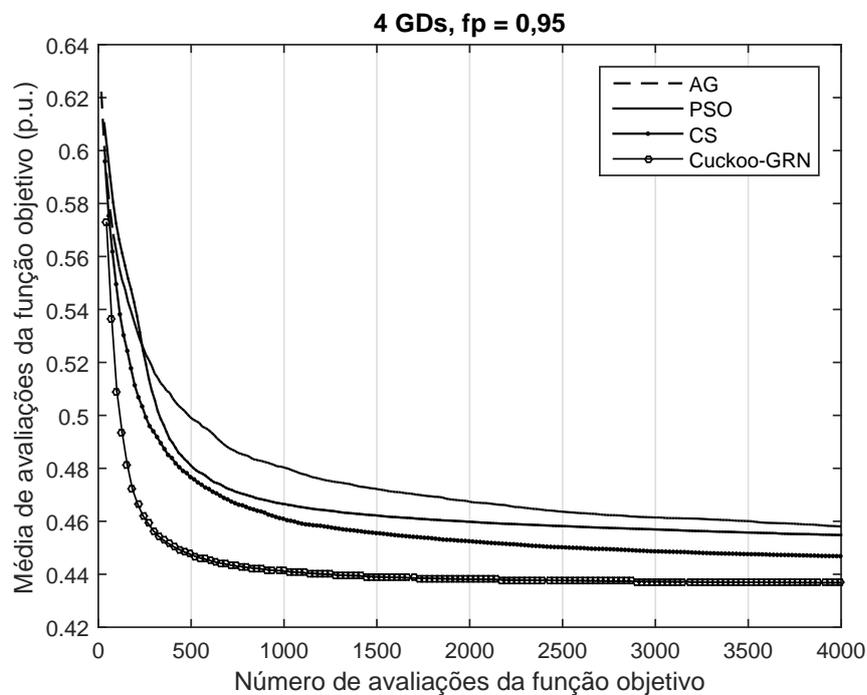
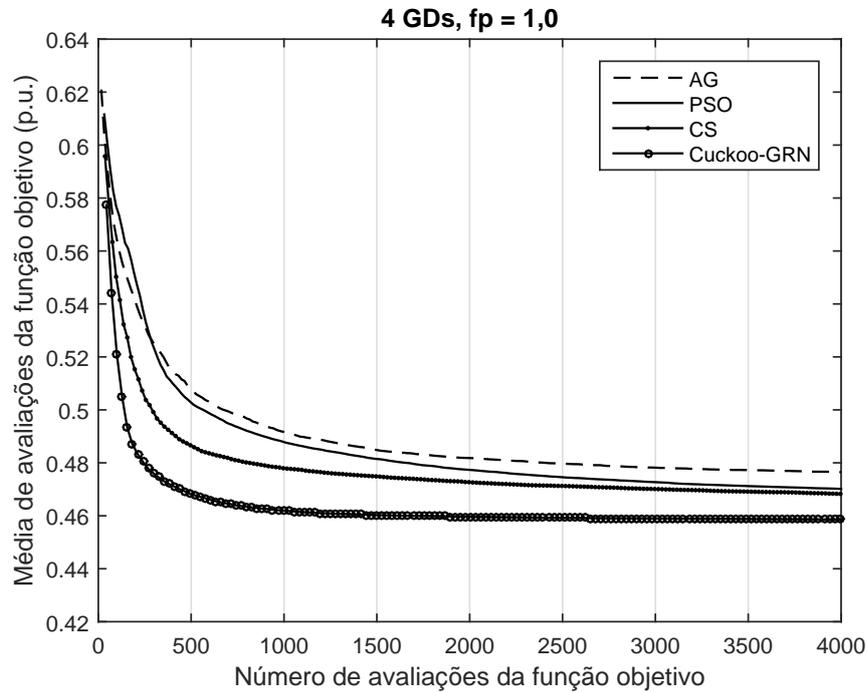


Figura 21 – Otimização de quatro GDs com fator de potência igual a 1,0.



No último caso, em que os parâmetros de cinco GDs são otimizados simultaneamente, o Cuckoo-GRN também mostrou que o seu desempenho é estatisticamente melhor do que o CS, AG e PSO para ambos valores de fator de potência, como ilustrado nas Figuras 22 e 23. Essa constante tendência estatística do Cuckoo-GRN é uma consequência da capacidade aprimorada de intensificação fornecida ao *Cuckoo Search* pela substituição genética de ninhos.

Com o aumento do número de GDs no processo de otimização, o valor da função objetivo é reduzido (as perdas ativas de potência e o perfil de tensão são melhorados). Esta característica é observada nas Figuras de 18 a 23.

Figura 22 – Otimização de cinco GDs com fator de potência igual a 0,95.

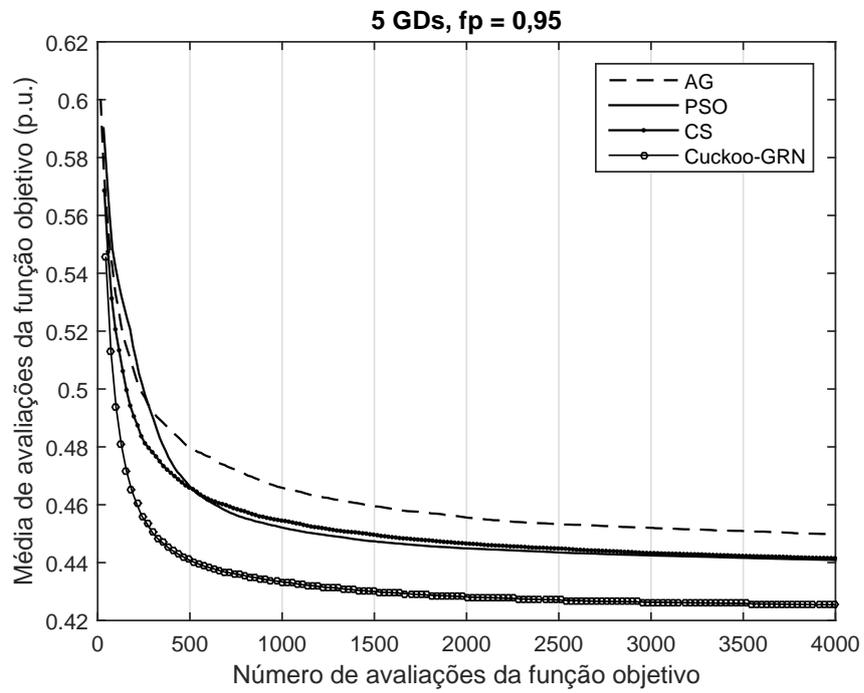
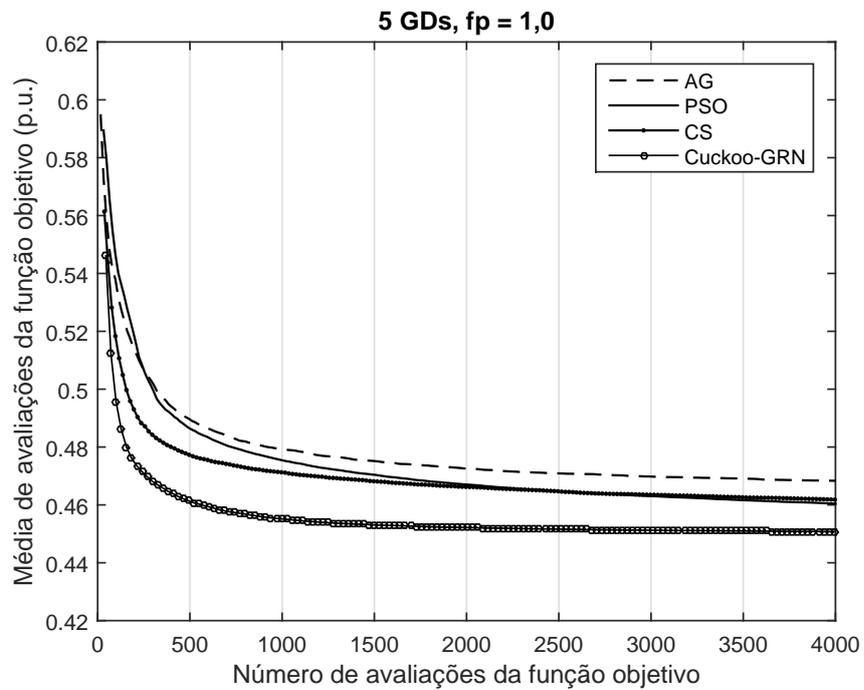


Figura 23 – Otimização de cinco GDs com fator de potência igual a 1,0.



As melhores soluções encontradas para cada método de otimização são apresentadas na Tabela 5. A Tabela 5 mostra os parâmetros da GD (quantidade, localização e capacidade), perdas ativas, desvio de tensão, IET e as soluções com as melhores avaliações e o desvio padrão da função objetivo com o uso do AG, PSO, CS e Cuckoo-GRN. Cada método de otimização foi simulado individualmente em 500 execuções, considerando o fator de potência igual a 0,95.

Na Tabela 5, nota-se que o Cuckoo-GRN obtém as melhores (menores) avaliações da função objetivo: 0,4435, 0,4344 e 0,4188, para a otimização dos parâmetros de 3, 4 e 5 GDs, respectivamente. Em todas as simulações (500 execuções), embora outros métodos tenham calculado avaliações próximas ao do Cuckoo-GRN, a frequência de obtenção desses valores é consideravelmente pequena (aproximadamente 5%). Por outro lado, o Cuckoo-GRN apresentou uma frequência de 90% em 500 execuções com número de avaliações limitado a 4.000. Este comportamento pode ser observado nas Figuras 18 a 23 e também na última coluna da Tabela 5 (desvio padrão da avaliação da função objetivo). Além disso, deve-se perceber que na maioria das execuções do Cuckoo-GRN, as soluções apresentadas na Tabela 5 foram alcançadas com menos de 1.500 avaliações da função. Isso não ocorreu no AG, PSO e CS, onde são necessárias mais de 3.000 avaliações para obter os resultados da Tabela 5.

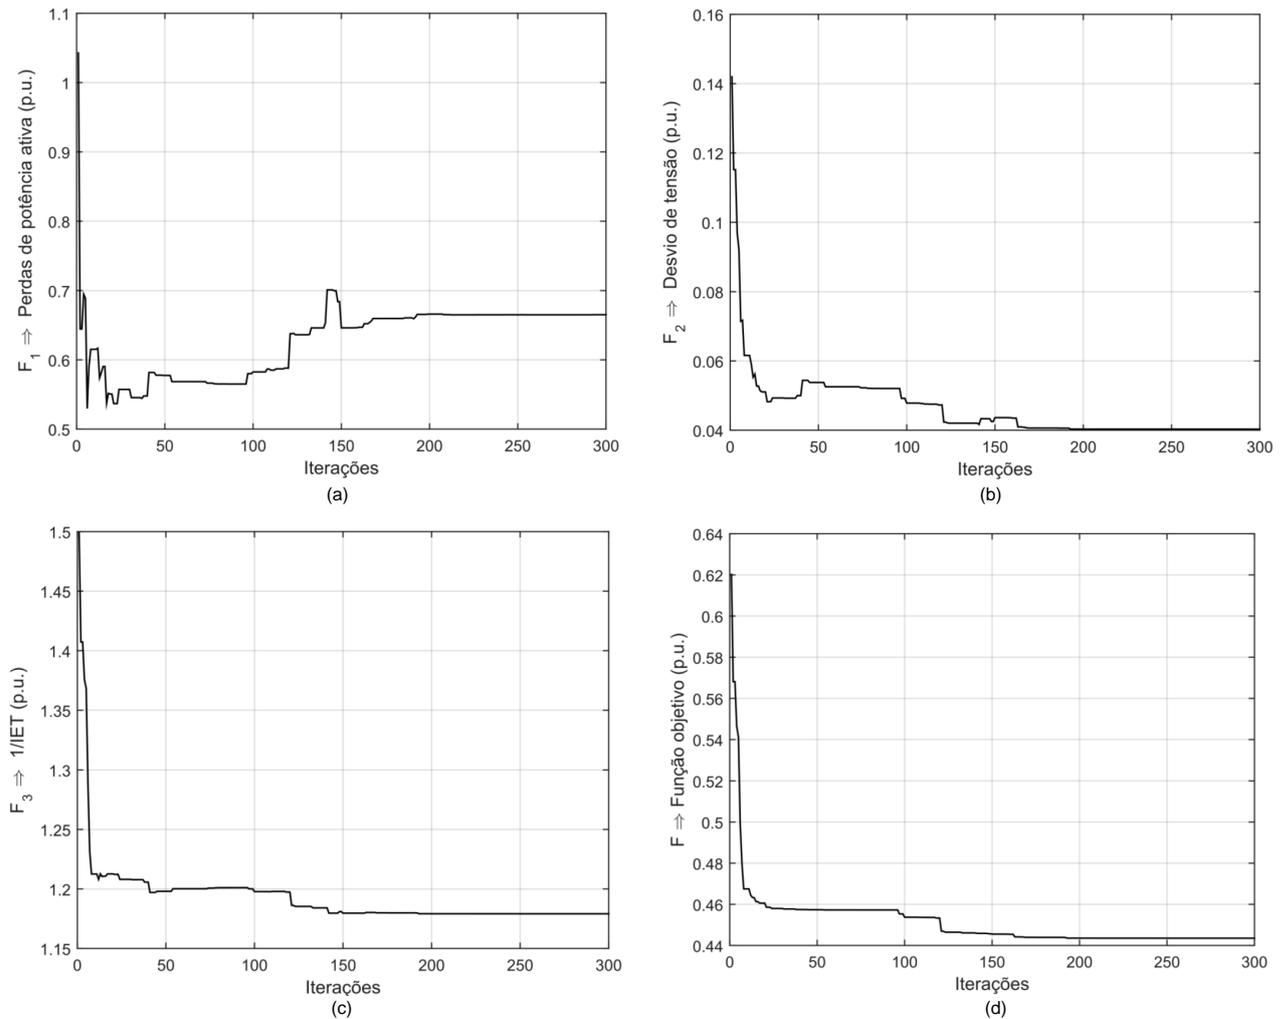
O algoritmo proposto Cuckoo-GRN obteve, para os casos de 3, 4 e 5 GDs otimizadas, os menores valores de desvio de tensão (0,0402, 0,0279 e 0,0186) e os maiores índices de estabilidade de tensão (0,8481, 0,8481 e 0,8691). Embora as perdas calculadas por Cuckoo-GRN não sejam mínimas, os valores obtidos estão entre os mais baixos.

Tabela 5 – Comparação entre os métodos AG, PSO, CS e Cuckoo-GRN para a otimização de 3, 4 e 5 unidades de GDs do sistema de 119 barras.

Núm. de GDs	Método	Barra	Capacidade da GD (MW)	Perdas ativas (pu)	Desvio de tensão (pu)	IET	Melhor solução (pu)	Desvio padrão
3	AG	47	4,0989	0,00524	0,0557	0,8160	0,4676	0,002386
		72	3,7520					
		106	5,1359					
	PSO	69	5,4181	0,00699	0,0491	0,8389	0,4536	0,006249
		104	6,2905					
		50	4,5001					
	CS	34	6,5338	0,00671	0,0420	0,8464	0,4454	0,002283
		69	5,8602					
		107	4,5218					
	Cuckoo-GRN	34	6,8100	0,00668	0,0402	0,8481	0,4435	0,000462
109		4,0292						
69		6,0502						
4	AG	48	5,6912	0,00514	0,0391	0,8421	0,4442	0,004117
		106	4,8691					
		74	2,3011					
		99	2,7216					
	PSO	69	5,8982	0,00564	0,0394	0,8470	0,4425	0,002836
		30	3,9795					
		50	3,6463					
		110	3,9809					
	CS	73	3,0285	0,00490	0,0320	0,8460	0,4378	0,002549
		35	6,3018					
111		4,1521						
90		2,9800						
Cuckoo-GRN	78	4,9800	0,00498	0,0279	0,8481	0,4344	0,000974	
	70	3,7775						
	109	4,0085						
	34	6,8096						
5	AG	69	4,7761	0,00715	0,0337	0,8660	0,4315	0,005856
		47	6,6391					
		80	5,4117					
		107	5,6300					
		4	6,7871					
	PSO	79	4,7659	0,00490	0,0213	0,8540	0,4275	0,004350
		70	3,9901					
		47	5,4683					
		39	4,0866					
		107	4,2960					
CS	41	2,8951	0,00660	0,0254	0,8682	0,4250	0,005105	
	34	6,3963						
	69	6,0833						
	90	3,0258						
	108	4,5543						
Cuckoo-GRN	73	2,5022	0,00497	0,0186	0,8691	0,4188	0,001128	
	65	6,8076						
	34	6,7899						
	40	3,2991						
	108	4,3608						

Para o caso da inserção de 3 GDs e fator de potência igual a 0,95, o desempenho de uma simulação (um ensaio) do Cuckoo-GRN com relação às funções F_1 (perdas de potência ativa), F_2 (desvio de tensão), F_3 (1/IET) e F (função objetivo) é mostrado na Figura 24. Adotou-se como critério de parada 300 iterações, $n_g = 12$, $p_m = 5\%$. Os pesos w_1 , w_2 e w_3 são iguais a 1, 0,6 e 0,35, respectivamente. Os valores ótimos calculados da localização das GDs foram as barras 34, 69 e 109 com capacidade de 6,81, 6,05 e 4,03 p.u., respectivamente.

Figura 24 – Desempenho do Cuckoo-GRN para o sistema de 119 barras com 3GDs e FP = 0,95. Funções: (a) F_1 , (b) F_2 , (c) F_3 e (d) $F = w_1F_1 + w_2F_2 + w_3F_3$.



Para o problema de otimização de cinco GDs, os intervalos de tempo de processamento médio necessários para concluir uma única iteração de Cuckoo-GRN, CS, PSO e AG foram de 0,329, 0,231, 0,181 e 0,164 s, respectivamente. Contudo, para cada método, o número de avaliações da função objetivo foi de 28, 20, 16 e 16 por iteração, respectivamente. Isso resultou em um tempo de processamento adicional no Cuckoo-GRN, 28 avaliações por iteração, causado pela substituição genética dos ninhos. Dado que durante o processo de avaliação da função objetivo é utilizado o MATPOWER para a solução do fluxo de carga e que o número de avaliações por iteração em cada método é diferente, com a finalidade de comparação, foi calculada uma razão entre o tempo médio de processamento por iteração e o número de avaliações por iteração. Dessa forma, esse cálculo do tempo médio por avaliação resultou em 0,0118, 0,0116, 0,0113 e 0,0103 s para o Cuckoo-GRN, CS, PSO e AG, respectivamente. Comparado ao CS, o Cuckoo-GRN necessita 0,2 ms adicional por avaliação da função objetivo. Em comparação com PSO e GA, o método proposto requer 0,5 e 1,5 ms extra por avaliação. Devido à convergência média rápida do Cuckoo-GRN, que é demonstrada neste trabalho, essa pequena diferença associada à substituição genética de ninhos pode ser considerada desprezível, principalmente quando o cálculo da avaliação da função objetivo necessita de grandes esforços computacionais.

Todos os cálculos das otimizações multiobjetivo foram realizados usando o sistema operacional Slackware Linux 14.0 de 64 bits em uma CPU i5-3330 de 3.0 GHz.

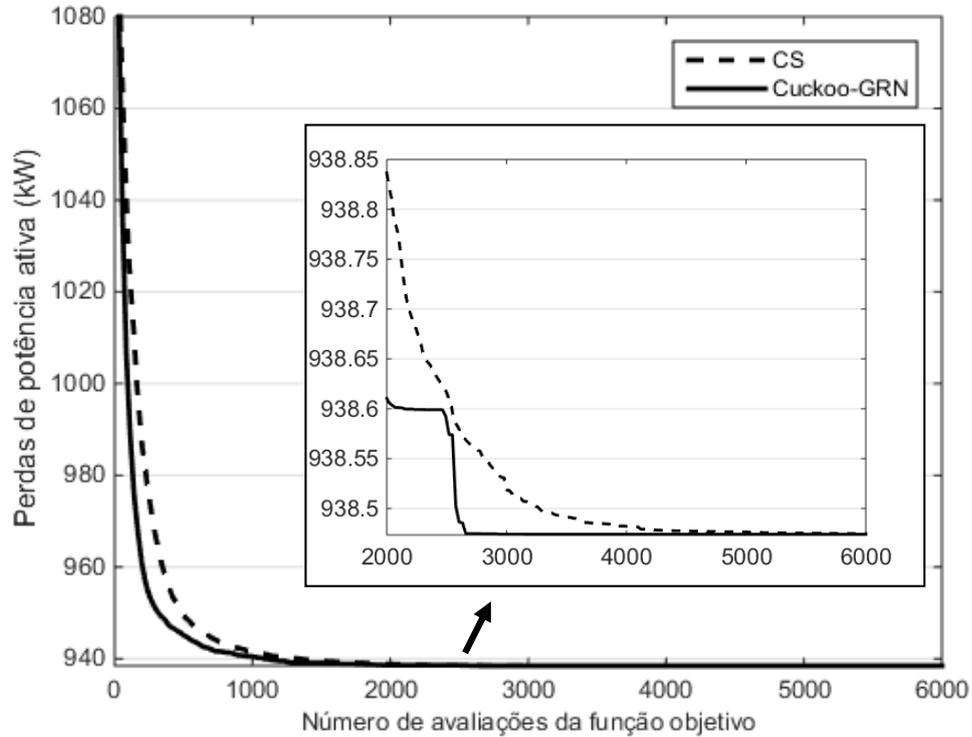
4.3.2.2 Cenário 2 - Otimização mono-objetivo visando minimização de perdas para localização, dimensionamento e fator de potência da GD

Neste cenário, o objetivo é minimizar as perdas de potência ativa do sistema de distribuição de 119 barras. As simulações são realizadas considerando a alocação ótima e o fator de potência de uma GD, podendo variar entre os valores de 0,95 de avanço e 0,95 de atraso (a GD pode gerar ou absorver potência reativa). Ou seja, obtêm-se os valores ótimos de dimensionamento, localização e fator de potência da GD para a

minimização das perdas de potência ativa do sistema ($w_1 = 1$, $w_2 = 0$ e $w_3 = 0$ da função objetivo (4.1)). Para avaliar estatisticamente o desempenho do método proposto, são realizadas simulações com 500 execuções independentes do algoritmo Cuckoo-GRN e o CS. Em todas as simulações, o Cuckoo-GRN é configurado para os parâmetros $n = 16$, $\alpha = 1$, $\lambda = 1,5$, $n_a = n_g = 12$, $n_r = 0$ e $p_m = 5\%$. Além disso, todas as variáveis tratadas geneticamente são representadas através de 25 bits.

A Figura 25 mostra a média das melhores soluções (perdas de potência ativa) calculadas após a realização de um determinado número de avaliações da função objetivo usando os algoritmos CS e Cuckoo-GRN. Esses valores foram obtidos a partir da simulação de 500 execuções independentes de cada algoritmo. Os resultados mostram que, estatisticamente, o desempenho do Cuckoo-GRN é consideravelmente superior ao CS. O método Cuckoo-GRN possibilita uma convergência mais rápida em comparação ao CS, já que foram necessárias apenas 2.660 avaliações da função objetivo para convergir ao valor das perdas de potência ativa igual a 938,474 kW, enquanto o CS necessita de mais de 6.000 avaliações para convergir para esse mesmo valor. Além disso, em 1.120 avaliações de aptidão, o Cuckoo-GRN converge para o valor próximo da solução ótima com perdas de potência igual a 939,90 kW, enquanto que o CS converge para outra solução com maior valor de perdas de potência ativa (943,17 kW) com o mesmo número de avaliações de aptidão. Também é possível observar que em 4.000 avaliações, o CS está próximo de convergir ao valor ótimo de perdas ativas. No cenário anterior, em que o Cuckoo-GRN e o CS são aplicados para otimizar um problema multiobjetivo, percebe-se que o CS não demonstra forte tendência de convergência em 4.000 avaliações da função multiobjetivo. Porém, o algoritmo Cuckoo-GRN converge com no máximo 2.500 avaliações para todos os casos estudados.

Figura 25 – Perfil de convergência média do CS e Cuckoo-GRN ($n_a = n_g = 12$) – 500 execuções independentes.



No *inset* da Figura 25, nota-se a rápida redução das perdas de potência ativa obtidas pela otimização do Cuckoo-GRN entre 2.548 e 2.660 avaliações de aptidão. Isso é, nitidamente, uma consequência da melhoria das características de intensificação do método.

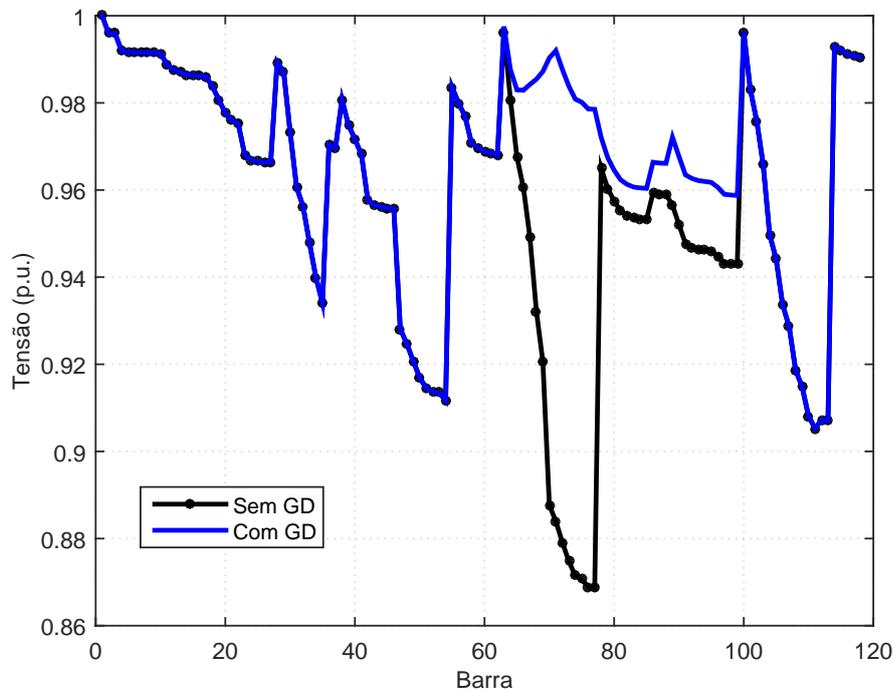
A Tabela 6 mostra o NMAF, desvio padrão e taxa de acerto para o CS e o Cuckoo-GRN, considerando como critério de parada o valor de 938,474 kW com 500 execuções independentes. Na Tabela 6, observa-se que em todas as execuções o Cuckoo-GRN convergiu para o valor ótimo (100% de acerto). Além disso, os valores do NMAF e do desvio terem sido menores para o Cuckoo-GRN do que para o CS.

Tabela 6 – Resultados da simulação para o sistema 119 barras $\lambda = 1,5$, $\alpha = 1$ e critério de parada igual a 938,4744 kW.

Método	NMAF	Desvio padrão	Taxa de acerto
<i>Cuckoo Search</i>	3.131,00	2.609,00	99,66%
Cuckoo-GRN	927,24	585,48	100%

A melhor solução encontrada usando o Cuckoo-GRN foi de 938,474 kW de perdas de potência ativa, com a alocação de uma GD na barra 71 com a capacidade de 3.218,99 kW e fator de potência igual a 0,95 de avanço. A Figura 26 apresenta o perfil de tensão nas barras do sistema obtido antes e depois da alocação ótima da GD no sistema. Antes da inserção da GD, as magnitudes de tensão das barras 71 a 77 eram abaixo de 0,9 p.u., ou seja, eram valores abaixo dos limites aceitáveis. Após a instalação da GD, os valores das magnitudes de tensão em todas as barras do sistema não ultrapassaram os limites permitidos, melhorando o perfil de tensão do sistema.

Figura 26 – Perfil de tensão antes e depois da instalação de uma GD utilizando o algoritmo Cuckoo-GRN.



4.4 Conclusões do capítulo

Um problema de alocação de unidades de geração distribuída com a utilização do algoritmo proposto Cuckoo-GRN foi mostrado neste capítulo. O objetivo é obter a localização, capacidade e fator de potência ótimos da GD, visando a minimização das perdas e do desvio de tensão e, também, maximização do índice de estabilidade do sistema. O método proposto foi testado nos sistemas distribuição de 33 e 119 barras. Os resultados mostraram que nos problemas mono-objetivo e multiobjetivo analisados, o Cuckoo-GRN calculou os melhores resultados que o CS, AG e PSO. Além disso, o Cuckoo-GRN obteve um desempenho estatístico melhor que os métodos CS, AG e PSO para o problema de alocação de GD considerado. A seguir, as conclusões e as propostas para trabalhos futuros serão apresentadas.

5 Conclusões

Nesta tese de doutorado, é proposto um algoritmo de otimização denominado Cuckoo-GRN (Cuckoo Search with Genetically Replaced Nests) que combina as vantagens do Algoritmo Genético no Cuckoo Search, reunindo as estratégias evolutivas do AG tais como seleção, *crossover* e mutação com o comportamento reprodutivo dos cucos. Os ninhos abandonados inicializados aleatoriamente do CS são geneticamente substituídos no Cuckoo-GRN, obtendo um desempenho elevado devido ao equilíbrio ótimo entre a intensificação e diversificação.

Primeiramente, o algoritmo Cuckoo-GRN foi testado em funções matemáticas de *benchmark* com a finalidade de fazer análise e comparação estatística com outros métodos (AG, PSO e Cuckoo Search). Em seguida, o método foi aplicado em um problema de alocação ótima de unidades de geração distribuída em sistemas de distribuição (33 e 119 barras). Para o sistema de 33 barras, o objetivo era determinar a localização e capacidade ótimas da GD (considerando 1, 2 e 3 unidades), minimizando as perdas de potência ativa do sistema. Para o sistema de 119 barras, foram considerados dois cenários: (I) otimização multiobjetivo visando minimização de perdas e desvio de tensão, e maximização do índice de estabilidade de tensão para a localização e o dimensionamento da GD (considerando 3, 4 e 5 unidades); (II) otimização mono-objetivo visando minimização de perdas para localização, dimensionamento e fator de potência de uma GD.

O desempenho do algoritmo Cuckoo-GRN foi comparado com o CS e outras técnicas disponíveis na literatura. Os resultados computacionais e a análise estatística mostram que o Cuckoo-GRN proposto melhora significativamente o CS, proporcionando uma redução considerável no número médio de avaliação da função objetivo e no desvio padrão. A partir dos resultados das simulações, observa-se que o Cuckoo-GRN apresenta melhor desempenho não apenas em termos de convergência, mas também em termos de precisão, pois obteve melhores soluções em comparação com outros métodos de otimização, exigindo

consideravelmente menos avaliações da função objetivo para alcançar a convergência. Além disso, é verificado que, apesar do tempo médio de processamento por avaliação do Cuckoo-GRN ser um pouco maior do que o CS, essa pequena diferença pode ser desconsiderada, pois a convergência do Cuckoo-GRN é consideravelmente mais rápida. Portanto, pode-se constatar que o algoritmo Cuckoo-GRN proposto é, estatisticamente, uma escolha mais adequada em relação ao CS e a outros algoritmos relatados para resolver problemas de otimização multiobjetivos e não-lineares na engenharia.

Com a finalidade de aperfeiçoar o método desenvolvido neste trabalho, sugerem-se as seguintes propostas de trabalhos futuros:

- Aplicar o Cuckoo-GRN em simulações do problema com sistemas de teste de maior dimensão e em sistemas de distribuição reais.
- Realizar novas simulações com diferentes configurações de parâmetros do AG e do CS que estão inseridos no algoritmo proposto (número de ninhos, elitismo etc).
- Investigar novos métodos híbridos baseados no *Cuckoo Search*.

Referências

- ACHARYA, N.; MAHAT, P.; MITHULANANTHAN, N. An analytical approach for DG allocation in primary distribution network. *Electrical Power and Energy Systems*, v. 28, p. 669–678, 2006. Citado 2 vezes nas páginas 21 e 26.
- ACKERMANN, T.; ANDERSSON, G.; SÖDER, L. Distributed generation: a definition. *Electric Power Systems Research*, v. 57, No. 3, p. 195–204, 2001. Citado na página 22.
- Agência Nacional de Energia Elétrica - ANEEL. *Resolução Normativa No. 482, de 17 de abril de 2012*. [S.l.]: Diário Oficial da União, Poder Executivo, Brasília, DF, 19 abr. 2012, Seção 1, pp.53, 2012. Citado na página 23.
- Agência Nacional de Energia Elétrica - ANEEL. *Resolução Normativa No. 687, de 24 de novembro de 2015*. [S.l.]: Diário Oficial da União, Poder Executivo, Brasília, DF, 02 dez. 2015, Seção 1, pp.45, 2015. Citado 2 vezes nas páginas 22 e 24.
- Agência Nacional de Energia Elétrica - ANEEL. *Micro e minigeração distribuída: sistema de compensação de energia elétrica*. [S.l.]: ANEEL, 2016. Citado na página 22.
- AKUMALLA, S.; PEDDAKOTLA, S.; KUPPA, S. A modified cuckoo search algorithm for improving voltage profile and to diminish power losses by locating multi-type FACTS devices. *Journal of Control, Automation and Electrical Systems*, v. 27, No. 1, p. 93–104, 2016. Citado 2 vezes nas páginas 21 e 31.
- AMAN, M. M. et al. Optimal placement and sizing of a DG based on a new power stability index and line losses. *Electric Power Systems Research*, v. 43, p. 1296–1304, 2012. Citado na página 27.
- ANGELIM, J. H. C. *Gerenciamento ótimo de um sistema de armazenamento de energia utilizando reconhecimento simulado*. Tese (Doutorado) — Universidade Federal do Pará, Janeiro 2018. Citado na página 23.
- ANILKUMAR, R.; DEVRIESE, G.; SRIVASTAVA, A. K. Voltage and reactive power control to maximize the energy savings in power distribution system with wind energy. *IEEE Transactions on Industry Applications*, v. 54, No. 1, p. 656–664, 2018. Citado na página 29.
- ASRARI, A.; WU, T.; LOTFIFARD, S. The impacts of distributed energy sources on distribution network reconfiguration. *IEEE Transactions on Energy Conversion*, v. 31, No. 2, p. 606–613, 2016. Citado na página 24.
- Banco de Informações de Geração (BIG). Capacidade de geração do Brasil. *Disponível: <http://www2.aneel.gov.br/aplicacoes/capacidadebrasil/capacidadebrasil.cfm>*. Acessado em: 15/07/19, 2019. Citado na página 24.

- BORGES, C. L. T.; FALCÃO, D. M. Optimal distributed generation allocation for reliability, losses, and voltage improvement. *Electrical Power and Energy Systems*, v. 28, p. 413–420, 2006. Citado na página 28.
- Borges, S. et al. Optimal allocation of wind parks considering Wind and Load uncertainties using Genetic Algorithm. In: *2015 12th International Conference on the European Energy Market (EEM)*. Lisbon (Portugal): [s.n.], 2015. p. 1–5. Citado na página 29.
- BOUSHAKI, S.; KAMEL, N.; BENDJEGHABA, O. A new quantum chaotic cuckoo search algorithm for data clustering. *Expert Systems with Applications*, v. 96, No. 15, p. 358–372, 2018. Citado na página 31.
- CHAKRAVORTY, M.; DAS, D. Voltage stability analysis of radial distribution networks. *Int. J. Electr. Power Energy Syst.*, v. 23, No. 2, p. 129–135, 2001. Citado 2 vezes nas páginas 56 e 57.
- CHECHKIN, A. V.; METZLER R.AND KLAFTER, J.; GONCHAR, V. Y. Introduction to the theory of Lévy flights. In: KLAGES, R.; RADONS, G.; SOKOLOV, I. M. (Ed.). *Anomalous Transport: Foundations and Applications*. Weinheim: John Wiley & Sons Ltd, 2008. cap. 5, p. 129–162. Citado na página 40.
- CHENG, M.; PRAYOGO, D. Symbiotic organisms search: a new metaheuristic optimization algorithm. *Computers and Structures*, v. 139, p. 98–112, 2014. Citado na página 30.
- CHIROMA, H. et al. Bio-inspired computation: Recent development on the modifications of the cuckoo search algorithm. *Applied Soft Computing*, v. 61, p. 149–173, 2017. Citado 2 vezes nas páginas 21 e 31.
- DEB, K. et al. A fast and elitist multiobjective genetic algorithm: NSGA-II. *IEEE Transactions on Evolutionary Computation*, v. 6, No. 2, p. 182–197, 2002. Citado na página 29.
- DEY, N. et al. Optimisation of scaling factors in electrocardiogram signal watermarking using cuckoo search. *International Journal of Bio-Inspired Computation*, v. 5, No. 5, p. 315–326, 2013. Citado na página 38.
- GANDOMI, A. H.; ALAVI, A. H. Krill herd: A new bio-inspired optimization algorithm. *Communications in Nonlinear Science and Numerical Simulation*, v. 17, No. 12, p. 4831–4845, 2012. Citado na página 29.
- GANDOMKAR, M.; VAKILIAN, M.; EHSAN, M. A combination of genetic algorithm and simulated annealing for optimal DG allocation in distribution networks. In: *Canadian Conference on Electrical and Computer Engineering*. Saskatoon (Canada): [s.n.], 2005. v. 1, p. 645–648. Citado na página 28.
- GANDOMKAR, M.; VAKILIAN, M.; EHSAN, M. A genetic-based tabu search algorithm for optimal DG allocation in distribution networks. *Electric Power Components and Systems*, v. 33, No. 12, p. 1351–1363, 2005. Citado na página 28.

- GIL, H. A.; JOOS, G. Models for quantifying the economic benefits of distributed generation. *IEEE Transactions on Power Systems*, v. 23, No. 2, p. 327–335, 2008. Citado na página 24.
- GLOVER, F. A user’s guide to tabu search. *Annual Operational Research*, v. 41, p. 3–28, 1993. Citado na página 28.
- GÖOZEL, T.; HOCAOGLU, M. H. An analytical method for the sizing and siting of distributed generators in radial systems. *Electric Power Systems Research*, v. 79, p. 912–918, 2009. Citado na página 26.
- GÖZEL, T.; EMINOGLU, U.; HOCAOGLU, M. H. A tool for voltage stability and optimization (VS&OP) in radial distribution systems using matlab graphical user interface (GUI). *Simulation Modelling Practice and Theory*, v. 16, p. 505–518, 2008. Citado na página 27.
- HOLLAND, J. H. *Adaptation in natural and artificial systems*. [S.l.]: University of Michigan Press, 1975. Citado na página 33.
- HUNG, D.; MITHULANANTHAN, N. Multiple distributed generator placement in primary distribution networks for loss reduction. *IEEE Transactions on Industrial Electronics*, v. 60, No. 4, p. 1700–1708, 2013. Citado 3 vezes nas páginas 20, 27 e 60.
- HUNG, D.; MITHULANANTHAN, N.; BANSAL, R. C. Analytical expressions for DG allocation in primary distribution networks. *IEEE Transactions on Energy Conversion*, v. 25, No. 3, p. 814–820, 2010. Citado 3 vezes nas páginas 21, 26 e 27.
- International Renewable Energy Agency. *Renewable energy highlights*. [S.l.]: IRENA, 2019. Citado na página 23.
- JORDEHI, A. R. Allocation of distributed generation units in electric power systems: A review. *Renewable and Sustainable Energy Reviews*, v. 56, p. 893–905, 2016. Citado 4 vezes nas páginas 21, 22, 24 e 25.
- KALAAM, R. N. et al. Optimisation of controller parameters for grid-tied photovoltaic system at faulty network using artificial neural network-based cuckoo search algorithm. *IET Renewable Power Generation*, v. 11, No. 12, p. 1517–1526, 2017. Citado na página 31.
- KANSAL, S.; KUMAR, V.; TYAGI, B. Optimal placement of different type of DG sources in distribution networks. *Electrical Power Energy System*, v. 53, p. 752–760, 2013. Citado 2 vezes nas páginas 21 e 29.
- KASHEM, M. A. et al. A novel method for loss minimization in distribution networks. In: *IEEE International Conference on Electric Utility Deregulation and Restructuring and Power Technologies*. London (England): [s.n.], 2000. p. 251–256. Citado 3 vezes nas páginas 31, 55 e 59.

- KHODIER, M. Optimisation of antenna arrays using the cuckoo search algorithm. *IET Microwaves, Antennas & Propagation*, v. 7, No. 6, p. 458–464, 2013. Citado na página 38.
- KRAMER, O. *Genetic Algorithm Essentials*. [S.l.]: Springer International Publishing, 2017. Citado 3 vezes nas páginas 33, 34 e 36.
- KROPOSKI, B.; SEN, P. K.; MALMEDAL, K. Optimum sizing and placement of distributed and renewable energy sources in electric power distribution systems. In: *IEEE Industry Application Society Annual Meeting - IAS*. Houston (USA): [s.n.], 2009. p. 1–10. Citado na página 20.
- LOPES, J. P. et al. Integrating distributed generation into electric power systems. *Electric Power Systems Research*, v. 77, p. 1189–1203, 2007. Citado na página 22.
- LOZANO, M.; GARCÍA-MARTÍNEZ, C. Hybrid metaheuristics with evolutionary algorithms specializing in intensification and diversification: Overview and progress report. *Computers & Operations Research*, v. 37, No. 3, p. 481–497, 2010. Citado na página 43.
- MAHMOUD, K.; YORINO, N.; AHMED, A. Optimal distributed generation allocation in distribution systems for loss minimization. *IEEE Transactions on Power Systems*, v. 31, No. 2, p. 960–969, 2016. Citado 2 vezes nas páginas 20 e 60.
- MAN, K. F.; TANG, K. S.; KWONG, S. Genetic algorithms: concepts and applications [in engineering design]. *IEEE Transactions on Industrial Electronics*, v. 43, No. 5, p. 519–534, 1996. Citado na página 33.
- MARELI, M.; TWALA, B. An adaptive cuckoo search algorithm for optimisation. *Applied Computing and Informatics*, v. 14, No. 2, p. 107–115, 2018. Citado na página 31.
- MELANIE, M. *An introduction to genetic algorithms*. [S.l.]: MIT Press, 1998. Citado na página 34.
- MORADI, M.; ABEDINI, M. A combination of genetic algorithm and particle swarm optimization for optimal DG location and sizing in distribution systems. *Electrical Power and Energy Systems*, v. 34, No. 1, p. 66–74, 2012. Citado 4 vezes nas páginas 22, 25, 29 e 30.
- MORAVEJ, Z.; AKHLAGHI, A. A novel approach based on cuckoo search for DG allocation in distribution network. *International Journal of Electrical Power & Energy Systems*, v. 44, p. 672–679, 2013. Citado 3 vezes nas páginas 21, 30 e 38.
- NAFAR, M. PSO based optimal placement of DGs in distribution systems considering voltage stability and short circuit level improvement. *Journal of Basic and Applied Scientific Research*, v. 2, No. 1, p. 703–709, 2012. Citado na página 29.
- NAIK, S. G.; KHATOD, D. K.; SHARMA, M. P. Sizing and Siting of Distributed Generation in Distribution Networks for Real Power Loss Minimization using Analytical Approach. In: *International Conference on Power, Energy and Control (ICPEC)*. Sri Ranganalatchum Dindigul (India): [s.n.], 2013. p. 740–745. Citado na página 27.

- NAIK, S. G.; KHATOD, D. K.; SHARMA, M. P. Analytical approach for optimal siting and sizing of distributed generation in radial distribution networks. *IET Generation, Transmission & Distribution*, v. 9, No. 3, p. 209–220, 2015. Citado 3 vezes nas páginas 20, 27 e 60.
- NATARAJAN, M.; RAMADOSS, B.; LAKSHMANARAO, L. Optimal location and sizing of MW and MVAR based DG units to improve voltage stability margin in distribution system using a chaotic artificial bee colony algorithm. *International Transactions on Electrical Energy Systems*, v. 27, No.4, p. 1–14, 2016. Citado na página 30.
- NETO, M. C. A. et al. Bioinspired multiobjective synthesis of X-band FSS via general regression neural network and cuckoo search algorithm. *Microwave Optical Technology Letters*, v. 57, p. 2400–2405, 2015. Citado na página 38.
- NGUYEN, T. T.; TRUONG, A.; PHUNG, T. A novel method based on adaptive cuckoo search for optimal network reconfiguration and distributed generation allocation in distribution network. *Electrical Power and Energy Systems*, v. 78, p. 801–815, 2016. Citado na página 30.
- ONU no Brasil - ONUBR. *Glossário de termos do Objetivo de Desenvolvimento Sustentável 7: Assegurar o acesso confiável, sustentável, moderno e a preço acessível a energia para todas e todos*. [S.l.]: Organização das Nações Unidas, 2018. Citado na página 23.
- PAVLYUKEVICH, I. Lévy flights, non-local search and simulated annealing. *Journal of Computational Physics*, v. 226, No. 2, p. 1830–1844, 2007. Citado na página 40.
- Pereira, K. et al. A multiobjective optimization technique to develop protection systems of distribution networks with distributed generation. *IEEE Transactions on Power Systems*, v. 33, No. 6, p. 7064–7075, 2018. Citado na página 29.
- Pesaran H.A, M.; HUY, P. D.; RAMACHANDARAMURTHY, V. K. A review of the optimal allocation of distributed generation: Objectives, constraints, methods, and algorithms. *Renewable and Sustainable Energy Reviews*, v. 75, p. 293–312, 2017. Citado na página 21.
- POPOVIĆ, D. H. et al. Placement of distributed generators and reclosers for distribution network security and reliability. *Electrical Power and Energy Systems*, v. 27, p. 398–408, 2005. Citado na página 28.
- PRABHA, D. R. et al. Optimal location and sizing of distributed generation unit using intelligent water drop algorithm. *Sustainable Energy Technologies and Assessments*, v. 11, p. 106–113, 2015. Citado na página 60.
- PRAKASH, P.; KHATOD, D. K. Optimal sizing and siting techniques for distributed generation in distribution systems: A review. *Renewable and Sustainable Energy Reviews*, v. 57, p. 111–130, 2016. Citado 4 vezes nas páginas 20, 21, 22 e 24.

- PRASAD, S.; KUMAR, D. M. V. Optimal allocation of measurement devices for distribution state estimation using multiobjective hybrid PSO–Krill Herd Algorithm. *IEEE Transactions on Instrumentation and Measurement*, v. 66, No. 8, p. 2022–2035, 2017. Citado na página 29.
- RAZAVI, S. E. et al. Impact of distributed generation on protection and voltage regulation of distribution systems: A review. *Renewable and Sustainable Energy Reviews*, v. 105, p. 157–167, 2019. Citado 2 vezes nas páginas 20 e 25.
- SAHA, S.; MUKHERJEE, V. Optimal placement and sizing of DGs in RDS using chaos embedded SOS algorithm. *IET Generation, Transmission & Distribution*, v. 10, No. 14, p. 3671–3680, 2016. Citado 3 vezes nas páginas 30, 56 e 68.
- SALGOTRA, R.; SINGH, U.; SAHA, S. New cuckoo search algorithms with enhanced exploration and exploitation properties. *Expert Systems With Applications*, v. 95, p. 384–420, 2018. Citado na página 40.
- SAMBALIAH, K. S. A review on optimal allocation and sizing techniques for dg in distribution systems. *International Journal of Renewable Energy Research (IJRER)*, v. 8, No. 3, p. 1236–1256, 2018. Citado 2 vezes nas páginas 22 e 25.
- SARASWATHI, M.; MURALI, G. B.; DEEPAK, B. B. V. L. Optimal path planning of mobile robot using hybrid cuckoo search-bat algorithm. *Procedia Computer Science*, v. 133, p. 510–517, 2018. Citado na página 31.
- SEDGHI, M.; AHMADIAN, A.; GOLKAR, M. A. Optimal storage planning in active distribution network considering uncertainty of wind power distributed generation. *IEEE Transactions on Power Systems*, v. 31, No. 1, p. 304–316, 2016. Citado na página 29.
- SHARMA, A.; SINGH, B.; WANG, R. DG Integration with Power Quality Improvement Feature for Smart Grid. In: *Fifth International Conference on Soft Computing for Problem Solving*. Singapore: [s.n.], 2016. p. 901–913. Citado na página 25.
- SHENG, W. et al. Optimal placement and sizing of distributed generation via an improved nondominated sorting genetic algorithm II. *IEEE Transactions on Power Delivery*, v. 30, No. 2, p. 569–578, 2015. Citado 2 vezes nas páginas 21 e 28.
- SINGH, B.; SHARMA, J. A review on distributed generation planning. *Renewable and Sustainable Energy Reviews*, v. 76, p. 529–544, 2017. Citado 2 vezes nas páginas 20 e 25.
- SIVANANDAM, S. N.; DEEPA, S. N. *Introduction to genetic algorithms*. [S.l.]: Springer, 2008. Citado na página 35.
- SULTANA, S.; ROY, P. Multi-objective quasi-oppositional teaching learning based optimization for optimal location of distributed generator in radial distribution systems. *Electrical Power and Energy Systems*, v. 63, p. 534–545, 2014. Citado na página 30.

- VINOTHKUMAR, K.; SELVAN, M. Fuzzy embedded genetic algorithm method for distributed generation planning. *Electric Power Components and Systems*, v. 39, No. 4, p. 1351–1363, 2011. Citado na página 29.
- VIRAL, R.; KHATOD, D. K. Optimal planning of distributed generation systems in distribution system: A review. *Renewable and Sustainable Energy Reviews*, v. 16, p. 5146–5165, 2012. Citado na página 22.
- WANG, C.; NEHRIR, M. H. Analytical approaches for optimal placement of distributed generation sources in power systems. *IEEE Transactions on Power Systems*, v. 19 (4), p. 2068–2076, 2004. Citado na página 25.
- WANG, T.; MESKIN, M.; GRINBERG, I. Enhancement of Voltage Profile in Unbalanced Distribution Systems with Variable Loads. In: *2017 Ninth Annual IEEE Green Technologies Conference (GreenTech)*. Denver (USA): [s.n.], 2017. p. 276–282. Citado na página 30.
- YANG, X. S. *Engineering optimization: an introduction with metaheuristic applications*. [S.l.]: John Wiley and Sons, USA, 2010. Citado na página 43.
- YANG, X. S. *Nature-inspired metaheuristic algorithms*. [S.l.]: Luniver Press, UK, 2010. Citado 2 vezes nas páginas 20 e 43.
- YANG, X. S.; DEB, S. Cuckoo search via Lévy flights. In: *World Congress on Nature and Biologically Inspired Computing - NaBIC*. Coimbatore (India): [s.n.], 2009. p. 210–214. Citado 7 vezes nas páginas 21, 30, 38, 39, 40, 43 e 47.
- YANG, X. S.; DEB, S. Engineering optimisation by cuckoo search. *Int. J. Mathematical Modelling and Numerical Optimisation*, v. 1 (4), p. 330–343, 2010. Citado na página 40.
- YANG, X. S.; DEB, S. Cuckoo search: recent advances and applications. *Neural Computing and Applications*, v. 24 (1), p. 169–174, 2014. Citado na página 39.
- YARAHMADI, M.; SHAKARAMI, M. R. An analytical and probabilistic method to determine wind distributed generators penetration for distribution networks based on time-dependent loads. *International Journal of Electrical Power & Energy Systems*, v. 103, p. 404–413, 2018. Citado na página 28.
- ZHANG, D.; FU, Z.; ZHANG, L. An improved ts algorithm for loss-minimum reconfiguration in large-scale distribution systems. *Electric Power Systems Research*, v. 77, p. 685–694, 2007. Citado 3 vezes nas páginas 31, 55 e 67.
- ZIMMERMAN, R. D.; MURILLO-SÁNCHEZ, C. E.; THOMAS, R. J. Matpower: Steady-state operations, planning and analysis tools for power systems research and education. *IEEE Transactions on Power Systems*, v. 26, No. 1, p. 12–19, 2011. Citado na página 59.