

Análise Comparativa das Meta-heurísticas *Particle Swarm Optimization* e *Differential Evolution* Aplicadas à Reconfiguração de Redes de Distribuição de Energia Elétrica

Liliane A. P. M. R. Costa, Yanick R. Gomes, Edmarcio A. Belati, Thiago F. Duarte
Center for Engineering, Modeling and Applied Social Sciences,
Federal University of ABC - UFABC
SP, Brazil

resende.costa@ufabc.edu.br, yanick.rodolfo@ufabc.edu.br, edmarcio.belati@ufabc.edu.br, thiago.duarte@ufabc.edu.br

Resumo—As redes de distribuição de energia elétrica desempenham um papel fundamental na garantia do fornecimento eficiente e confiável de energia aos consumidores. Diversas ações podem ser adotadas para proporcionar uma operação mais eficiente e econômica, como a Reconfiguração de Redes de Distribuição Distribution Network Reconfiguration (DNR). No entanto, a complexidade inerente ao problema de DNR nessas redes exige abordagens avançadas de otimização. Neste trabalho, propõe-se uma análise comparativa entre duas meta-heurísticas, *Particle Swarm Optimization* (PSO) e *Differential Evolution* (DE), no contexto da DNR. O objetivo é determinar qual dessas técnicas oferece melhor desempenho em termos do número de iterações, tempo médio de convergência e qualidade das soluções obtidas, quando comparadas sob as mesmas premissas iniciais. Para isso, serão utilizados os sistemas de 33 e 70 barras amplamente empregados na literatura. Os resultados deste estudo não apenas fornecerão uma compreensão sobre a escolha e aplicação de meta-heurísticas na otimização de redes de distribuição de energia elétrica, como também apresentarão possíveis direções para pesquisas futuras.

Palavras-chaves: Reconfiguração de Rede de Distribuição; Meta-heurísticas; Otimização por Enxame de Partículas; Evolução Diferencial

I. INTRODUÇÃO

A Reconfiguração da Rede de Distribuição (RRD) é um problema clássico da engenharia elétrica, amplamente estudado desde a proposta inicial de [1]. Esse processo consiste na alteração da topologia da rede por meio da operação de chaves seccionadoras, com o objetivo de minimizar perdas técnicas, melhorar o perfil de tensão e aumentar a confiabilidade do sistema [2]. Entretanto, a complexidade combinatória do problema cresce exponencialmente com o número de chaves de interconexão, gerando um espaço de busca de 2^n soluções possíveis, onde n é o número de chaves. Em função disso, diversos pesquisadores têm explorado diferentes abordagens para solucioná-lo, tornando-o um campo de estudo amplamente investigado [2], [3] e [4].

Diversas abordagens são apresentadas na literatura especializada, como *Metaheuristics: From Design to Implementation* de [5], que apresenta diversas abordagens que englobam mais de 100 meta-heurísticas, incluindo variantes e combinações de métodos amplamente utilizados. Esses algoritmos podem ser classificados em diferentes categorias, sendo a maioria inspirada em processos naturais. Entre as principais, destacam-se: *Flower Pollination Algorithm* (FPA), *Firefly Algorithm* (FA) e *Lilly Pad Jumping Algorithm* (LPJA); comportamento coletivo de enxames, como o *PSO*, *Bird Swarm Algorithm* (BSA) e *Fruit Fly Optimization Algorithm* (FFOA); fenômenos físicos, como o *Artificial Bee Colony* (ABC) e *Whale Optimization Algorithm* (WOA); e comportamento humano, como o *Group Search Optimization* (GSO) e *Social Learning Optimization* (SLO) [6].

A meta-heurística DE, proposta por [7], é inspirada nos princípios da evolução biológica, especialmente nos mecanismos de seleção, mutação e recombinação genética. Seu funcionamento baseia-se na geração de novas soluções a partir da combinação de indivíduos da população atual, promovendo uma exploração eficiente e diversificada do espaço de busca. As operações de mutação e cruzamento são responsáveis por criar soluções potencialmente superiores, enquanto a seleção orienta o processo evolutivo, preservando os melhores indivíduos [7].

Por sua vez, a meta-heurística PSO, desenvolvida por [8], é inspirada no comportamento social de cardumes e bandos, que se orientam mutuamente em busca de alimento. O algoritmo modela esse comportamento através de um enxame de partículas que exploram o espaço de busca, ajustando suas posições com base na melhor solução individual já encontrada e na melhor solução identificada pelo grupo. Esse mecanismo garante um equilíbrio dinâmico entre a exploração de novas regiões e a intensificação em torno das melhores soluções encontradas, favorecendo a convergência para o ótimo global [8].

A maioria dos estudos sobre o problema de RRD concentra-

se em comparações baseadas predominantemente no tempo computacional [9]. Além disso, ao avaliar diferentes meta-heurísticas, é comum que aspectos importantes, como índices de acerto, características de convergência e outros critérios de desempenho, não sejam considerados, resultando em análises parciais [4]. Frequentemente, as meta-heurísticas inicializam a população de forma aleatória dentro do espaço de busca, o que pode impactar significativamente o processo de convergência, tornando-o mais ou menos eficiente. Como diferencial e uma das principais contribuições deste trabalho, propõe-se uma estrutura de programação que assegura condições iniciais consistentes para ambos os algoritmos analisados, possibilitando uma comparação mais justa e rigorosa.

Este estudo propõe uma análise detalhada das meta-heurísticas DE e PSO aplicadas ao problema de RRD, com o objetivo de avaliar criticamente como cada uma dessas abordagens lida com as particularidades e desafios inerentes ao problema em questão. A escolha dessas meta-heurísticas justifica-se pela sua ampla utilização e pelo desempenho comprovado em problemas de natureza semelhante, além do interesse em comparar sistematicamente seu desempenho no contexto específico da RRD. Ambas têm sido amplamente aplicadas em estudos anteriores, como evidenciado pela extensa literatura sobre o tema [3], [10], [11], [12], [13], [14], [15].

Este artigo realiza uma análise aprofundada de diversos aspectos relacionados ao desempenho das meta-heurísticas, incluindo a iteração média, fluxos de carga e o tempo médio até a convergência.

Este trabalho está estruturado da seguinte forma: a Seção 1 aborda a RRD; na Seção 2 são apresentadas as meta-heurísticas utilizadas; a Seção 3 descreve a metodologia de solução; a Seção 4 apresenta as análises dos resultados; e, por fim, a Seção 5 apresenta as conclusões do estudo.

II. DESCRIÇÃO DAS META-HEURÍSTICAS UTILIZADAS

Nesta seção, são descritas as duas meta-heurísticas utilizadas no desenvolvimento deste trabalho: PSO e DE. Ambas integram a classe dos algoritmos evolutivos baseados em populações, amplamente reconhecidos na literatura pelo seu desempenho consistente na resolução de problemas de otimização complexos, especialmente aqueles definidos por espaços de busca de elevada dimensionalidade, não lineares e não diferenciáveis.

A. Particle Swarm Optimization

O algoritmo PSO foi desenvolvido por Kennedy e Eberhart [8], inspirado principalmente no comportamento coletivo de cardumes de peixes e bandos de pássaros durante a busca por alimento. No PSO, as partículas (ou indivíduos) beneficiam-se tanto de sua própria experiência quanto da experiência compartilhada pelos demais membros do enxame, aprimorando progressivamente suas soluções ao longo do processo de busca. Cada partícula pode ajustar sua posição com base em três componentes: a memória individual da melhor posição já encontrada; o fator cognitivo, que representa a tendência da

partícula a retornar à sua melhor posição; e o fator social, que reflete a atração pela melhor posição identificada pelo grupo. Assim, cada agente $X_i = (x_{1,i}, x_{2,i}, \dots, x_{D,i})$ no PSO é uma solução candidata, evoluindo no espaço de busca com uma determinada velocidade $V_i = (v_{1,i}, v_{2,i}, \dots, v_{D,i})$, sendo D a dimensão do problema. Durante o processo iterativo, a velocidade da partícula i é atualizada conforme a Equação (1), enquanto a posição da partícula é atualizada conforme a Equação (2). Neste trabalho, adota-se um peso de inércia variável, que é gradualmente reduzido ao longo do tempo (medido em iterações do algoritmo), conforme proposto em [16]. O cálculo do peso de inércia usado neste artigo está descrito na Equação (3).

$$V_i^{t+1} = \omega V_i^t + r_1 c_1 (P_i - X_i^t) + r_2 c_2 (P_g - X_i^t) \quad (1)$$

$$X_i^{t+1} = X_i^t + V_i^{t+1} \quad (2)$$

$$\omega = \omega_{max} - \frac{(\omega_{max} - \omega_{min})}{Iter_{max}} \cdot iter \quad (3)$$

em que:

- V_i^t - velocidade da i -ésima partícula na t -ésima iteração;
- ω - coeficiente de inércia, que controla a influência da velocidade anterior da partícula na nova velocidade;
- ω_{max} e ω_{min} - valores máximos e mínimos do peso de inércia;
- r_1 e r_2 - números aleatórios uniformemente distribuídos entre 0 e 1;
- c_1 e c_2 - coeficientes de aprendizado que controlam a influência da melhor posição da partícula P_i e da melhor posição global P_g na atualização da velocidade;
- $Iter_{max}$ - número máximo de interações;
- P_i - melhor posição histórica da i -ésima partícula;
- P_g - melhor posição global encontrada por qualquer partícula no enxame até o momento;
- X_i^t - posição atual de i -ésima partícula na t -ésima iteração.

B. Differential Evolution

O algoritmo DE, proposto por [7], inclui três etapas fundamentais em seu processo evolutivo: mutação, cruzamento e seleção.

1) **Mutação** : A partir da definição de uma população inicial, o DE realiza a mutação, na qual os vetores são modificados para gerar novos indivíduos denominados vetores mutantes. Esse processo consiste na adição da diferença entre dois indivíduos selecionados aleatoriamente da população a um terceiro indivíduo, também escolhido aleatoriamente, seguindo uma distribuição uniforme [17]. A operação de mutação pode ser formalmente descrita pela Equação (4):

$$M_j^{(t)} = X_{r1}^{(t)} + F \left(X_{r2}^{(t)} - X_{r3}^{(t)} \right) \quad (4)$$

em que:

- M_j^t - vetor mutante j na iteração (ou geração) t ;

X_{r1}^t , X_{r1}^t e X_{r1}^t - indivíduos selecionados aleatoriamente da população na t -ésima iteração;

F - constante real contida no intervalo $[0, 2]$.

2) **Cruzamento**: Após a etapa de mutação, realiza-se o cruzamento para gerar um novo vetor, denominado vetor de teste e representado por $U_j^t = (u_{1,j}^t, u_{2,j}^t, \dots, u_{D,j}^t)$. Esse cruzamento ocorre entre o vetor-alvo $X_j^t = (x_{1,j}^t, x_{2,j}^t, \dots, x_{D,j}^t)$ e o vetor mutante $M_j^t = (m_{1,j}^t, m_{2,j}^t, \dots, m_{D,j}^t)$, utilizando uma probabilidade de cruzamento Cr , cujo valor varia entre 0 e 1, e um número aleatório $rand_j$, gerado no intervalo $[0, 1]$. O vetor U_j^t é determinado conforme a Equação (5).

$$u_{i,j}^{(t)} = \begin{cases} m_{i,j}^{(t+1)}, & \text{se } rand_j \leq Cr \\ x_{i,j}^{(t)}, & \text{caso contrário} \end{cases} \quad (5)$$

3) **Seleção**: A seleção ocorre por meio da comparação entre o custo do vetor de teste e o custo do vetor-alvo. Caso o custo do vetor de teste seja inferior ao do vetor-alvo, este será substituído pelo vetor de teste na próxima geração (ou iteração). Caso contrário, o vetor-alvo permanecerá inalterado. Essa condição é formalizada pela Equação (6), conforme apresentado a seguir:

$$X_j^{(t+1)} = \begin{cases} U_j^{(t)}, & \text{se } f(U_j^{(t)}) \leq f(X_j^{(t)}) \\ X_j^{(t)}, & \text{caso contrário} \end{cases} \quad (6)$$

As operações de mutação, cruzamento e seleção, que compõem a fase de evolução, são executadas repetidamente até que um critério de parada predefinido seja satisfeito.

III. METODOLOGIA DE SOLUÇÃO

O Problema de RRD geralmente visa à minimização das perdas de energia e a melhoria do perfil de tensão nos barramentos, respeitando as restrições do sistema. Esse problema pode ser formalizado pela Equação (7):

$$\text{Minimizar } P_P = \sum_{i=1}^{n_l} \beta_i R_i I^2 \quad (7)$$

em que:

P_P — perdas totais de potência ativa do sistema na configuração;

I — corrente elétrica que circula no ramo i ;

n_l — número de linhas da rede;

R_i — resistência no ramo i ;

β_i — variável binária que representa a chave de interconexão na linha i .

A função objetivo do problema representado pela Equação (7) está sujeita às seguintes restrições:

1) **Restrições de Fluxo de Carga**: Incluem-se, nesse conjunto de restrições, os balanços de potência ativa e reativa dos nós do sistema em estudo, expressos pelas Equações (8) e (9):

$$PG_k - PC_k = V_k \sum_{m \in k} V_m (G_{km} \cos \theta_{km} + B_{km} \sin \theta_{km}) \quad (8)$$

$$QG_k - QC_k = V_k \sum_{m \in k} V_m (G_{km} \sin \theta_{km} - B_{km} \cos \theta_{km}) \quad (9)$$

em que:

PG_k, QG_k — potências ativa e reativa geradas na barra k , respectivamente;

PC_k, QC_k — potências ativa e reativa consumidas na barra k , respectivamente;

V_k, V_m — magnitudes das tensões nodais nas barras k e m , respectivamente;

G_{km}, B_{km} — partes real e imaginária do elemento da matriz admitância ($Y = G + jB$);

θ_{km} — diferença angular entre as barras k e m .

2) **Restrição de Magnitude de Tensão**: Como parte das restrições do problema, a magnitude da tensão nos nós deve situar-se dentro de limites operacionais adequados, a fim de garantir a estabilidade do sistema. Assim, foram considerados os níveis estabelecidos pela Agência Nacional de Energia Elétrica (ANEEL), que determinam a faixa de operação adequada para redes de distribuição com tensão nominal entre 1 kV e 69 kV [18]. Essa condição é expressa pela Equação (10), que define os níveis máximos e mínimos de tensão admitidos em cada nó:

$$V^{\min} \leq V_k \leq V^{\max} \quad (10)$$

3) **Radialidade do Sistema**: O Sistema de Distribuição geralmente opera de forma radial, com a energia fluindo do ponto central de alimentação para as extremidades, sem formar malhas ou loops fechados. A imposição da restrição de radialidade visa simplificar as operações e o controle do sistema [19]. Contudo, ao considerarmos as possíveis configurações, dadas por 2^n , o problema torna-se intrinsecamente complexo, especialmente em sistemas de médio ou grande porte. Durante o processo de reconfiguração da rede, com objetivos como a minimização de perdas ou a melhoria do perfil de tensão, é fundamental garantir que a topologia permaneça radial. Essa consideração evidencia a necessidade de reduzir o espaço de busca das configurações do sistema a ser analisado. Vale destacar que, para cada possibilidade do sistema, existem duas configurações associadas: 0 para chave fechada e 1 para chave aberta. Conhecendo-se a quantidade de chaves que podem estar abertas, representada por D na Equação (11), é possível compreender melhor a dinâmica do sistema. Uma análise mais aprofundada sobre essa variável e suas implicações pode ser encontrada em [20].

$$D = n_l - n_b + 1 \quad (11)$$

Em que: n_l representa o número de linhas, e n_b , o número de barras. O número de chaves definido pela Equação (11) coincide com o número de malhas que o sistema apresenta quando todas as chaves estão fechadas, o que pode ser representado pela Equação (12).

$$VM_n = [C1_n, C2_n, \dots, CDm_n] \quad (12)$$

em que:

VM_n — vetor que representa a malha n da rede, considerando todas as chaves fechadas;
 Dm — dimensão da malha m ;
 CDm_n — chave m da malha n .

Na busca pela solução, apenas uma chave é aberta em cada malha. A radialidade do sistema é garantida por meio dessa imposição, sendo implementada com as técnicas propostas neste artigo.

A. Algoritmo de Solução

Nesta seção, apresenta-se um fluxograma que organiza a execução dos dois métodos utilizados para comparar o desempenho de cada técnica. Para garantir uma análise justa, foi considerada a mesma população inicial. Os passos empregados são resumidos no fluxograma apresentado na Figura 1. Os parâmetros de cada técnica foram determinados empiricamente.




Figura 1. Fluxograma de algoritmo de solução

IV. ANÁLISES DOS RESULTADOS

As análises foram realizadas em dois sistemas: o de 33 barras e o de 70 barras.

1) *Sistema de 33 barras*: O sistema de 33 barras e 37 linhas, proposto por [21], opera com uma tensão nominal de 12,66 kV. O sistema possui 32 chaves de interconexão normalmente fechadas e 5 chaves de interconexão abertas, formando cinco malhas quando todas as chaves estão fechadas.

2) *Sistema de 70 barras*: O sistema de 70 barras, utilizado inicialmente por [22], apresenta uma tensão base de 12,66 kV e uma potência base de 10 MVA.

A Tabela I apresenta os dados do sistema antes e após a reconfiguração, com base na literatura [23]. Para este sistema, a reconfiguração ótima proporciona uma redução de 31,15% no sistema de 33 barras e de 54,82% no sistema de 70 barras. Os mesmos valores encontrados na literatura foram considerados como solução ótima.

Tabela I
RESULTADOS ANTES E APÓS A RECONFIGURAÇÃO

Sistema	Descrição	Inicial	Final
33 barras	Chaves abertas	33 - 34 - 35 - 36 - 37	7 - 9 - 14 - 32 - 37
	Tensão mínima (pu)	0,913	0,938
	Perdas técnicas (kW)	208,48	139,55
70 barras	Chaves abertas	70 - 71 - 72 - 73 - 74	15 - 56 - 62 - 70 - 71
	Tensão mínima (pu)	0,973	0,982
	Perdas técnicas (kW)	20,87	9,43

Todas as simulações foram realizadas em um computador com processador Intel® Core™ i7 @ 1.8 GHz, 8 GB de memória RAM, sistema operacional Windows 11 Home (64 bits), disco rígido de 1 TB, SSD de 256 GB, utilizando o software GNU Octave.

A. Análise Comparativa

Após a validação das técnicas, realizaram-se análises comparativas entre os algoritmos DE e PSO, utilizando populações de 30, 60 e 90 indivíduos para os sistemas de 33 e 70 barras. Cada configuração foi executada por 30 rodadas. O número máximo de iterações foi fixado em 80 para a população de 30 indivíduos, e em 100 para as demais.

Os parâmetros utilizados foram definidos empiricamente: para o DE, taxa de crossover de 0,9 e fator de mutação de 0,8; para o PSO, limites de velocidade de ± 6 , taxas de inércia máxima e mínima de 0,9 e 0,4, respectivamente, e constantes de aceleração de 1,5 e 1,8.

A Tabela II apresenta os resultados comparativos, incluindo o número de acertos, o número médio de iterações até a convergência, o tempo médio de execução e o número médio de avaliações de fluxo de carga por rodada. Embora o número máximo de iterações tenha sido previamente definido, conforme ilustram as Figuras 3 e 4, os algoritmos frequentemente convergiram antes desse limite. Para isso, adotou-se como critério de convergência a estabilização da função objetivo, o processo é interrompido quando a variação entre os melhores valores consecutivos se mantém abaixo de um limiar pré-estabelecido por um número mínimo de iterações. Esse mecanismo evita execuções desnecessárias, promovendo maior eficiência computacional.

1) *Sistema de 33 barras*:: Analisando os valores obtidos, observa-se que o algoritmo DE apresentou desempenho superior em todas as análises realizadas, quando comparado ao algoritmo PSO, para o sistema de 33 barras, conforme pode ser verificado na Tabela II.

Considerando o sistema de 33 barras, a Figura 2 apresenta o gráfico comparativo entre o PSO e o DE em relação à convergência, utilizando uma população de 30 indivíduos.

Outro ponto importante a ser destacado é o tempo gasto até a convergência: ao comparar o DE com o PSO, no caso com 90 indivíduos, verifica-se que o DE converge, em média, para a solução ótima em aproximadamente metade do tempo necessário pelo PSO.

Os resultados comparativos estão apresentados na Tabela II.

Tabela II
ANÁLISES DOS ALGORITMOS PARA OS SISTEMAS DE 33 E 70 BARRAS

Análises	Indivíduos	33 barras		70 barras	
		PSO	DE	PSO	DE
Acertos em 30 rodadas	30	12	29	28	30
Número médio de iterações até a convergência	30	59,40	26,56	43,20	43,36
Tempo médio gasto até a convergência	30	8,92	4,75	9,41	26,28
Número médio de Fluxo de Carga (FC) até a convergência	30	1782	797	1296	1301
Acertos em 30 rodadas	60	22	29	28	30
Número médio de iterações até a convergência	60	57,53	23,83	46,96	30,33
Tempo médio gasto até a convergência	60	7,46	3,82	32,39	26,77
Número médio de FC até a convergência	60	3452	1430	2218	1819
Acertos em 30 rodadas	90	22	30	29	30
Número médio de iterações até a convergência	90	45,33	22,13	51,06	27,43
Tempo médio gasto até a convergência	90	6,48	3,58	46,04	13,35
Número médio de FC até a convergência	90	4080	1992	4596	2469




Figura 2. Perdas para 30 indivíduos — sistema de 33 barras




Figura 4. Número de iterações até a convergência para 30 indivíduos — sistema de 70 barras




Figura 3. Número de iterações até a convergência para 30 indivíduos — sistema de 33 barras




Figura 5. Perdas para 30 indivíduos — sistema de 70 barras

2) Sistema de 70 barras:

3) *Análise geral:* De forma geral, o algoritmo DE apresentou vantagens notáveis, como pode ser observado na Tabela II. Assim, ao escolher entre os dois métodos, é importante avaliar quais dos aspectos comparados são mais relevantes para a aplicação em questão. Notavelmente, o algoritmo DE demonstrou um desempenho superior em todos os aspectos avaliados para o sistema de 33 barras e também se destacou para os casos com 60 e 90 indivíduos no sistema de 70 barras. Em síntese, podem-se destacar os seguintes pontos:

- **Eficiência em tempo:** O DE apresentou uma eficiência superior em termos de tempo na maioria dos casos

analisados, indicando uma melhor utilização dos recursos computacionais, especialmente em situações onde a otimização do tempo é uma prioridade.

- **Número de FC e iterações:** O DE exigiu menos iterações para alcançar a convergência na maioria dos cenários avaliados, demonstrando sua capacidade de encontrar soluções mais rapidamente e com menor custo computacional, quando comparado ao PSO.
- **Precisão de acertos:** O DE obteve um número de acertos significativamente maior em comparação ao PSO, mesmo quando aplicado a populações com menor número de indivíduos. Esse resultado sugere que o DE é capaz de

encontrar soluções de alta qualidade, independentemente do tamanho do grupo de indivíduos.

Na Tabela II, são comparados os desempenhos dos sistemas de 33 e 70 barras utilizando os algoritmos DE e PSO. Para o sistema de 33 barras, o DE superou o PSO em todos os indivíduos. No sistema de 70 barras, o PSO mostrou-se mais eficiente em termos de iteração, fluxo de carga e tempo para 30 indivíduos. Entretanto, para 60 e 90 indivíduos, o DE demonstrou um melhor desempenho, conforme apresentado na Tabela II.

V. CONCLUSÃO

A análise comparativa entre os algoritmos PSO e DE para problemas de RRD revelou resultados consistentes com aqueles previamente encontrados na literatura. Ambos os algoritmos foram capazes de alcançar as mesmas soluções consideradas ótimas em estudos anteriores.

É importante destacar que, nas análises realizadas, o PSO apresentou-se como menos eficiente. Embora tenha demonstrado um desempenho satisfatório no sistema de 70 barras com 30 indivíduos conforme detalhado na Tabela II, sua eficácia foi consideravelmente inferior em cenários com populações de 60 e 90 indivíduos, quando comparado ao DE.

Por outro lado, o DE destacou-se pela sua maior precisão nos resultados finais, característica fundamental em aplicações que demandam soluções altamente confiáveis e consistentes. Entre os aspectos mais relevantes observados, destacam-se o tempo de convergência e a elevada taxa de acertos obtida pelo DE.

Dessa forma, para os sistemas de 33 e 70 barras analisados neste trabalho, o DE apresentou desempenho mais robusto e confiável na resolução do problema de RRD. Contudo, a extensão desses resultados para outros tipos de redes ou aplicações na área de engenharia elétrica requer análises adicionais. A escolha do método mais adequado deve considerar os objetivos específicos de cada aplicação, equilibrando a otimização do tempo, os recursos computacionais disponíveis e a precisão desejada, conforme discutido nesta análise.

AGRADECIMENTOS

Os autores agradecem à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior -Brasil (CAPES) - Código de Financiamento 001; Projeto Universal nº407244/2023-9, nº408898/2021-6; Conselho Nacional de Desenvolvimento Científico e Tecnológico(CNPq); e ao INCT-INNERGE.

REFERÊNCIAS

- [1] A. Merlin and H. Back, "Search for a minimal-loss operating spanning tree configuration in an urban power distribution system," in *Proc. 5th Power System Computation Conf.*, Cambridge, UK, vol. 5, pp. 1–18, 1975.
- [2] C. Gerez et al., "Distribution Network Reconfiguration Using Selective Firefly Algorithm and a Load Flow Analysis Criterion for Reducing the Search Space," *IEEE Access*, vol. 7, 2019, doi: 10.1109/ACCESS.2019.2918480.
- [3] A. Tiguercha, A. A. Ladjici, and M. Boudour, "Optimal radial distribution network reconfiguration based on multi objective differential evolution algorithm," in *IEEE Manchester PowerTech*, pp. 1–6, 2017, doi: 10.1109/PTC.2017.7980932.
- [4] Y. R. Gomes et al., "Análise das Meta-heurísticas SOS e PSO Aplicadas ao Problema de Reconfiguração de Rede de Distribuição de Energia Elétrica," in *IEEE INDUSCON*, pp. 997–1004, 2023, doi: 10.1109/INDUSCON58041.2023.10374727.
- [5] El-Ghazali Talbi, "Metaheuristics: From Design to Implementation," Wiley, Hoboken, NJ, 2009. <https://www.wiley.com/enus/Metaheuristics3A+From+Design+to+Implementation> p-9780470278581.
- [6] X.-S. Yang, "Nature-inspired metaheuristic algorithms: Success and new challenges," *Int. J. Appl. Metaheuristic Comput.*, vol. 1, no. 1, pp. 1–20, 2010.
- [7] R. Storn and K. Price, "Differential Evolution—a simple and efficient adaptive scheme for global optimization over continuous spaces," *Int. Comput. Sci. Inst.*, Berkeley, 1995.
- [8] J. Kennedy and R. Eberhart, "Particle swarm optimization," in *Proc. ICNN'95*, vol. 4, pp. 1942–1948, 1995, doi: 10.1109/ICNN.1995.488968.
- [9] L. I. Silva, E. A. Belati, and I. C. Silva Junior, "Heuristic Algorithm for Electrical Distribution Systems Reconfiguration Based on Firefly Movement Equation," *IEEE Lat. Am. Trans.*, vol. 14, no. 2, 2016, doi: 10.1109/TLA.2016.7437219.
- [10] J.-P. Chiou, C.-F. Chang, and C.-T. Su, "Variable scaling hybrid differential evolution for solving network reconfiguration of distribution systems," *IEEE Trans. Power Syst.*, vol. 20, no. 2, pp. 668–674, 2005, doi: 10.1109/TPWRS.2005.846096.
- [11] M. N. M. Nasir et al., "A distribution network reconfiguration based on PSO: Considering DGs sizing and allocation evaluation for voltage profile improvement," in *Proc. IEEE Student Conf. on Research and Development*, pp. 1–6, 2014, doi: 10.1109/SCORED.2014.7072981.
- [12] H. Wu, P. Dong, and M. Liu, "Distribution Network Reconfiguration for Loss Reduction and Voltage Stability With Random Fuzzy Uncertainties of Renewable Energy Generation and Load," *IEEE Trans. Ind. Inform.*, vol. 16, no. 9, pp. 5655–5666, 2020, doi: 10.1109/TII.2018.2871551.
- [13] C.-T. Su and C.-S. Lee, "Network reconfiguration of distribution systems using improved mixed-integer hybrid differential evolution," *IEEE Trans. Power Deliv.*, vol. 18, no. 3, pp. 1022–1027, 2003, doi: 10.1109/TPWRD.2003.813641.
- [14] K. Sureshkumar and P. Vijayakumar, "Distribution network reconfiguration for loss minimisation using differential evolution algorithm," *ARPN J. Eng. Appl. Sci.*, vol. 10, pp. 2861–2866, 2015.
- [15] B. Kumar, B. K. Saw, and A. K. Bohre, "Distribution Network Reconfiguration and Multi Renewable DG Planning based on MOFF approach using PSO Technique," in *Proc. IEEE ICMICA*, pp. 1–6, 2020, doi: 10.1109/ICMICA48462.2020.9242915.
- [16] J. Xin, G. Chen, and Y. Hai, "A Particle Swarm Optimizer with Multi-stage Linearly-Decreasing Inertia Weight," in *2009 Int. Joint Conf. on Computational Sciences and Optimization*, vol. 1, pp. 505–508, 2009, doi: 10.1109/CSO.2009.420.
- [17] Rocha, Natália Caixeta and Saramago, Sezimária de Fátima Pereira, Estudo de algumas estratégias de evolução diferencial, Congresso de Matemática Aplicada e Computacional, CMAC Sudeste, 2011.
- [18] AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA – ANEEL. Resolução nº 505, de 26 de novembro de 2001. Conformidade dos níveis de tensão em regime permanente nos sistemas de energia elétrica. Disponível em: <http://www.aneel.gov.br/>.
- [19] R. Sellami, R. Neji, and T. Bouktir, "Enhancing Radial Distribution Network Performance by Optimal Reconfiguration with PSO Algorithm," in *16th Int. Multi-Conf. on Systems, Signals Devices (SSD)*, pp. 180–186, 2019, doi: 10.1109/SSD.2019.8893158.
- [20] C. Gerez, "Reconfiguração de Sistemas de Distribuição de Energia Elétrica Usando o Algoritmo do Vaga-lume," Dissertação de Mestrado, UFABC, 2017. [Online]. Available: <https://biblioteca.ufabc.edu.br>.
- [21] M. E. Baran and F. F. Wu, "Network Reconfiguration in Distribution Systems for Loss Reduction and Load Balancing," *IEEE Trans. Power Deliv.*, vol. 6, no. 4, pp. 396–402, 1989.
- [22] H.-D. Chiang and R. Jean-Jumeau, "Optimal network reconfigurations in distribution systems. II. Solution algorithms and numerical results," *IEEE Trans. Power Deliv.*, vol. 5, no. 3, pp. 1568–1574, 1990, doi: 10.1109/61.58002.
- [23] L. I. Silva, E. A. Belati, C. Gerez, and I. C. Silva Junior, "Reduced search space combined with particle swarm optimization for distribution system reconfiguration," *Electrical Engineering*, 2020, doi: 10.1007/s00202-020-01150-z.