

Um Estudo Comparativo de Metaheurísticas para Planejamento da Geração Distribuída

Mariana R. B. Alencar. Benemar A. Souza. Washington L. A. Neves

*Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal de Campina Grande
Campina Grande, PB (email: mariana.alencar@ee.ufcg.edu.br)*

Abstract: For the purpose of performance comparison, three metaheuristics are applied to optimally locate distributed generators in order to minimize the total power losses in a distribution system. The computational effort, the lowest value found for the objective function and the dispersion of the solutions are the metrics used. The results showed a slight superiority of the Cuckoo search algorithm compared to the genetic algorithm and the dragonfly algorithm. As a result, the complete distributed generation planning problem, that is, determining the generators optimal locations and sizes in the distribution network, is solved using the Cuckoo search algorithm.

Resumo: A propósito de comparação de desempenho, três metaheurísticas são aplicadas para localização ótima de geradores distribuídos com o objetivo de minimizar as perdas totais de potência em um sistema de distribuição. Os critérios de esforço computacional, menor valor encontrado para a função objetivo e dispersão das soluções são as métricas utilizadas. Os resultados mostraram leve superioridade do algoritmo de busca Cuco em comparação ao algoritmo genético e ao algoritmo de libélula. Em razão disso, o problema completo do planejamento da geração distribuída, qual seja, de determinar as localizações e dimensionamentos ótimos dos geradores na rede de distribuição é resolvido empregando-se a busca Cuco.

Keywords: Optimization methods; genetic algorithm; cuckoo search algorithm; dragonfly algorithm; distribution system; distributed generation.

Palavras-chaves: Métodos de otimização; algoritmo genético; algoritmo de busca cuco; algoritmo de libélula; sistema de distribuição; geração distribuída.

1. INTRODUÇÃO

Embora em vários países a geração distribuída (GD) já tenha alcançado participação significativa na capacidade instalada total, no Brasil sua difusão é um fenômeno recente. As diretrizes regulatórias do país sobre microgeração distribuída foram publicadas pela primeira vez em 2012, com a Resolução Normativa ANEEL nº 482/2012. O documento definiu o que constitui a microgeração, tornando-a legal e o sistema de créditos na conta de energia como esquema de incentivo (Gianelloni et al. 2017).

A adoção de sistemas de geração própria teve um início tímido, mas começou a se popularizar. Em 2016 houve um salto de mais de quatro vezes no número de instalações, terminando o ano com 81 MW instalados, distribuídos em 7,7 mil unidades. Apesar do crescimento recente, essa modalidade de geração ainda é insignificante no Brasil, havendo espaço para se desenvolver muito mais na próxima década (EPE, 2017).

As unidades de GD posicionadas de forma correta reduzem perdas do sistema e levam a melhorias no perfil de tensão, confiabilidade do sistema, estabilidade de tensão e qualidade da energia elétrica. Além de uma significativa redução em investimentos em transmissão e distribuição (Prakash & Khatod, 2016).

Em seu estudo de revisão, Abdmouleh et al. (2017) afirmam que as concessionárias de energia podem enfrentar novos problemas de aumento das perdas do sistema causados principalmente pela

seleção inadequada da localização e tamanho das unidades geradoras. Ao incluir técnicas de otimização no planejamento da geração distribuída, as concessionárias podem tratar adequadamente dos problemas de perdas, confiabilidade e qualidade da energia.

O estudo de Pesaran et al. (2017) mostrou que grande parte dos trabalhos que empregam métodos de otimização para o planejamento da geração distribuída têm como objetivo a minimização das perdas de potência ativa e melhoria do perfil de tensão. Outros objetivos encontrados na literatura mais frequentemente são: minimização das perdas reativas, maximização da capacidade de geração distribuída e objetivos financeiros.

As técnicas de otimização convencionais que mais são empregadas ao planejamento da geração distribuída são: técnicas analíticas, busca exaustiva, programação linear inteira mista, programação não-linear inteira mista, fluxo de potência ótimo e técnicas probabilísticas (Ehsan & Yang, 2018).

Além das técnicas mencionadas acima, os métodos de busca inteligente ou heurísticos são largamente utilizados para resolver o problema do planejamento da geração distribuída. Os métodos heurísticos aceleram o processo de encontrar uma solução ótima ou quase ótima. Simplicidade é a principal vantagem de tais métodos. No entanto, podem sacrificar exatidão e precisão (Abdmouleh et al., 2017).

Metaheurísticas as mais diversas são empregadas ao problema que é tema deste trabalho: algoritmos genéticos, têmpera simulada, busca tabu, otimização por enxame de partículas, otimização de colônia de formigas, busca harmônica, algoritmo de colônia artificial de abelhas, busca cuco, algoritmo dos vagalumes, dentre muitos outros (Pesaran et al., 2017; Abdmouleh et al., 2017; Ehsan & Yang, 2018). Sendo assim, a escolha pelos métodos a serem comparados poderia ter sido outra, no entanto, AG foi escolhido por ser um método consolidado na literatura, BC por ser um método com pouquíssimos parâmetros a serem ajustados e AL por ter quase todos os parâmetros modificados durante o processo de otimização, sem a intervenção do usuário.

Pesquisa bibliográfica revelou que poucos trabalhos realizam estudos comparativos de métodos de otimização aplicados a sistemas de distribuição de grande porte. Coelho et al (2017) propõem um novo método chamado Otimização de Guerra, o empregam em sistema de 69 e 476 barras e o comparam com mais quatro métodos de otimização.

Este artigo é uma contribuição para melhorar esta situação, na medida em que diz respeito a um estudo comparativo entre três metaheurísticas para solucionar o problema de localização ótima de geradores distribuídos em um sistema de distribuição de 400 barras.

2. ENUNCIADO DO PROBLEMA

Supondo que seja de interesse das distribuidoras de energia a instalação de geradores distribuídos para atendimento dos consumidores e que com isso as perdas de potência sejam minimizadas, o problema aqui tratado pode ser enunciado como: determinar em quais das n barras de uma rede de distribuição, m geradores devem ser localizados e quais devem ser suas capacidades para que a redução das perdas totais de potência seja máxima.

As perdas totais de potência ativa na rede de distribuição é o somatório das perdas em cada trecho:

$$\Delta P = \sum_{i=1}^n \Delta P_i. \quad (1)$$

Para rede radial, as perdas de potência ativa no trecho i se expressam do seguinte modo:

$$\Delta P_i = R_i \frac{P_i^2 + Q_i^2}{V_i^2}, \quad (2)$$

sendo V_i a tensão da barra final do trecho i cuja resistência é R_i . P_i e Q_i são os fluxos de potência ativa e reativa, respectivamente, no fim do trecho i , cujas expressões são:

$$P_i = P_{L_i} + \sum_{k \in \Omega_i} P_k + \Delta P_k \quad (3)$$

$$Q_i = Q_{L_i} + \sum_{k \in \Omega_i} Q_k + \Delta Q_k \quad (4)$$

P_{L_i} e Q_{L_i} são, respectivamente, as cargas ativa e reativa instaladas na barra i . Ω_i é o conjunto de todos os trechos que se originam na

barra i . Nos trechos terminais, o fluxo é a própria carga instalada em suas barras finais, pois neles, Ω_i é um conjunto vazio ($\Omega_i = \emptyset$).

O cálculo das perdas é necessariamente iterativo, pois conforme a expressão (2), elas dependem da tensão na barra final do trecho, V_i , que por sua vez depende das perdas ΔP_i . Entretanto, Alencar et al. (2018) constataram que apenas a primeira iteração era suficiente, em estudos de planejamento, pois os valores aproximados das perdas totais, assim determinados, no que chamaram *Método da Soma de Potência Rápido*, não comprometia os resultados da localização ótima dos geradores.

Como é usual para sistemas de distribuição, adota-se aqui o modelo da potência constante para cargas e geradores. De modo que os geradores são tidos como cargas negativas de valores iguais às suas respectivas capacidades nominais e as expressões (3) e (4) dos fluxos de potência ativa e reativa são reescritas do seguinte modo:

$$P_i = P_{L_i} - P_{G_i} + \sum_{k \in \Omega_i} P_k + \Delta P_k \quad (5)$$

$$Q_i = Q_{L_i} - Q_{G_i} + \sum_{k \in \Omega_i} Q_k + \Delta Q_k \quad (6)$$

O número e as potências dos geradores, P_G e Q_G , a serem instalados na rede de distribuição são dados, de modo que o problema é um problema de otimização combinatória típico.

Um único gerador pode se instalar em qualquer das barras do alimentador e que as tensões em todas elas devem se manter nos limites:

$$0,95 \text{ p. u.} \leq V_i \leq 1,05 \text{ p. u.} \quad (7)$$

As duas restrições acima são consideradas mediante aplicação de função de penalidade, que reduz a fitness das soluções que as violam.

3. ALGORITMOS DE OTIMIZAÇÃO

Uma breve apresentação dos métodos de otimização comparados é feita nesta seção, destacando-se algumas de suas particularidades.

3.1 Algoritmo Genético (AG)

Algoritmo genético (AG) é a tradução do conceito biológico de evolução em códigos computacionais. Como faz parte de vários sistemas inteligentes, AG é frequentemente associado à área de inteligência artificial, que visa a construção de métodos que imitam e até superam a inteligência humana (Kramer, 2017). Sendo assim, AG é um algoritmo de busca inspirado nos conceitos de genética e seleção natural, como seleção, cruzamento, mutação e herança.

Segundo Abdmouleh et al. (2017), AG é considerado a técnica de otimização mais empregada na resolução do problema de localização e dimensionamento da GD.

Evangelopoulos e Georgilakis (2014) usam AG para determinar a localização ótima de GD renovável com o objetivo de minimizar os custos. Ganguly e Samajpati (2015)

usam um AG adaptativo para instalar geradores distribuídos, em sistemas de pequeno porte, considerando incertezas na carga e geração. Alencar et al. (2018) empregam um AG para estimar a localização ótima de geradores fotovoltaicos para a minimização das perdas anuais de energia, considerando incertezas na carga e geração.

Qualquer solução do problema que se quer resolver por AG é tida como um indivíduo, identificado por um cromossomo, ou cadeia de gene (unidade básica de informação). Cada indivíduo tem sua própria aptidão, que é uma métrica da qualidade da solução quanto a atender o objetivo do problema. De modo resumido, o AG compreende as seguintes etapas:

1. Criação da população inicial de forma aleatória, sendo cada um dos indivíduos da população uma solução possível para o problema;
2. Avaliação de cada indivíduo da população a partir do cálculo da função objetivo;
3. Seleção dos indivíduos para geração de outros novos;
4. Cruzamento dos indivíduos selecionados e mutação;
5. Seleção dos indivíduos mais aptos para continuarem na população e eliminação dos menos aptos;
6. Se o critério de parada for atendido, conclusão do processo. Caso contrário, retornar à etapa 2.

3.2 Algoritmo de Busca Cuco (BC)

Entre muitas características interessantes dos pássaros cucos, uma marcante é que algumas espécies se envolvem no chamado parasitismo de ninhada. As fêmeas de cuco colocam ovos nos ninhos de outra espécie para que os pássaros hospedeiros choquem e alimentem seus filhotes. O plano é frustrado se o ovo do intruso é descoberto pela ave hospedeira, que o descarta. Para aumentar as chances de ter um novo cuco e reduzir a probabilidade de abandono dos ovos pelas aves hospedeiras, os cucos (fêmeas, machos e jovens) usam várias estratégias (Ouaarab et al., 2014).

Na concepção do algoritmo de busca Cuco (BC), Yang e Deb (2009) utilizaram três regras idealizadas: 1) Cada cuco põe um ovo por vez e o coloca em um ninho escolhido aleatoriamente; 2) Os melhores ninhos com ovos de alta qualidade são levados às próximas gerações; 3) O número de ninhos hospedeiros disponíveis é fixo, e o ovo posto por um cuco é descoberto pelo pássaro hospedeiro com uma probabilidade $p_a \in [0, 1]$.

Caso seja descoberto, o pássaro hospedeiro pode descartar o ovo ou abandonar o ninho e construir outro. Por simplicidade, a última suposição pode ser aproximada pela fração p_a dos ninhos que são substituídos por novos ninhos (Yang e Deb, 2009).

Na busca Cuco, um cuco procura por novos ninhos por meio de voos de Lévy, que representam um modelo de caminhadas aleatórias caracterizadas por seus comprimentos de passo que obedecem a uma lei de distribuição de potência (Ouaarab et al., 2014).

Diferentemente de AG, não se encontram tantos trabalhos que empregam busca Cuco no problema de planejamento da GD.

Buaklee e Hongesombut (2013) aplicam BC para localização e dimensionamento ótimos de GD com o objetivo de minimizar as perdas de potência ativa. Khoa et al. (2017) propõem um algoritmo de busca Cuco para encontrar as localizações e os dimensionamentos ótimos de várias unidades de GD em redes de distribuição. Swief et al. (2018) utilizam BC para localizar dispositivos de proteção e instalar geradores distribuídos para melhorar a confiabilidade do sistema. Os trabalhos citados acima utilizam sistemas de distribuição de pequeno a médio porte.

Basicamente, BC pode ser resumido nos seguintes passos:

1. Geração aleatória da população inicial de n ninhos hospedeiros;
2. Avaliação dos ninhos da população inicial a partir do cálculo da função objetivo;
3. Obtenção de um cuco aleatoriamente por voos de Lévy;
4. Avaliação da qualidade do ninho por meio da função objetivo;
5. Determinação aleatória de um ninho j ;
6. Comparação das funções objetivo dos ninhos e substituição do antigo ninho pelo novo, caso seja uma solução melhor;
7. Abandono de uma fração p_a dos piores ninhos e construção de novos ninhos;
8. Ordenação dos ninhos para encontrar o melhor ninho atual;
9. Se o critério de parada for atingido, conclusão do processo. Caso contrário, retornar à etapa 3.

Apesar de ter mais etapas do que AG, BC conta com a vantagem de ter poucos parâmetros a serem ajustados e que não influenciam tanto no desempenho do algoritmo como em AG.

3.3 Algoritmo de Libélula (AL)

As libélulas são pequenos predadores que caçam quase todos os outros insetos menores na natureza. Fato interessante sobre elas é seu comportamento de enxame raro. Elas se locomovem por dois motivos: caça e migração. Sendo assim, os enxames podem ser estático (de alimentação) ou dinâmico (migratório). No enxame estático, as libélulas formam pequenos grupos e voam para frente e para trás sobre uma pequena área para caçar suas presas voadoras, como borboletas e mosquitos. No enxame dinâmico, muitas libélulas se agrupam para migrar em uma direção por longas distâncias (Mirjalili, 2015).

O comportamento das libélulas acompanha os princípios de separação, alinhamento, coesão, distração do inimigo e atração por comida. Cada libélula do enxame corresponde a uma solução no espaço de busca. A separação se refere à prevenção de colisão estática de indivíduos, e é calculada por:

$$S_i = - \sum_{n=1}^N x_i - x_n, \quad (8)$$

sendo x_i a posição do indivíduo atual, x_n a posição do n -ésimo indivíduo vizinho e N o número de vizinhanças.

O alinhamento se refere à correspondência de velocidade dos indivíduos com outros indivíduos na vizinhança e é dado por:

$$A_i = \frac{\sum_{n=1}^N V_n}{N}, \quad (9)$$

sendo V_n , a velocidade do n -ésimo indivíduo da vizinhança.

A coesão refere-se à tendência dos indivíduos em manter um centro de massa da vizinhança e é expressa por:

$$C_i = \frac{\sum_{n=1}^N x_n}{N} - x_i, \quad (10)$$

sendo x_i , a posição do indivíduo atual, x_n , a posição do n -ésimo indivíduo vizinho e N , o número de vizinhanças.

A atração por comida refere-se a tendência dos indivíduos de irem na direção onde há mais comida e é dada por:

$$F_i = x_{comida} - x_i, \quad (11)$$

sendo x_i a posição do indivíduo atual e x_{comida} a posição da fonte de alimento.

A distração indica a evasão na presença de um predador e é calculada por:

$$E_i = x_{inimigo} + x_i, \quad (12)$$

sendo x_i a posição do indivíduo atual e $x_{inimigo}$ a posição do inimigo.

Para atualizar a posição das libélulas e simular seus movimentos, dois vetores são considerados, passo (Δx) e posição (x_i). O vetor passo mostra a direção do movimento das libélulas e se expressa do seguinte modo:

$$\Delta x_{t+1} = (sS_i + aA_i + cC_i + fF_i + eE_i) + w\Delta x_t, \quad (13)$$

sendo s , a , c , f , e , w , os pesos de separação, alinhamento, coesão, atração, distração e de inércia, respectivamente. S_i , A_i , C_i , F_i e E_i indicam a separação, o alinhamento, a coesão, a fonte de alimento e a posição do inimigo do i -ésimo indivíduo. t é o contador de iteração. Depois de calcular o vetor passo, os vetores de posição são atualizados:

$$x_{t+1} = x_t + \Delta x_{t+1}. \quad (14)$$

As libélulas necessitam mudar seus pesos adaptativamente para a mudança da exploração global para exploração local do espaço de busca. A fonte de alimento e o inimigo são escolhidos dentre as melhores e piores soluções que o exame inteiro encontrou (Mirjalili, 2015).

Por se tratar de uma metaheurística relativamente nova, foram encontrados poucos trabalhos que empregam AL no problema de localização ou dimensionamento ótimos de GD. Suresh e Belwin (2018) usam AL para determinar o dimensionamento ideal da GD para minimização das perdas de potência em sistemas de 15, 33 e 69 barras. Arulraj e Kumarappan (2018) aplicam AL para instalar GD e capacitores em rede de

distribuição com o objetivo de minimizar as perdas de potência reativa do sistema de 33 barras. Saleh et al. (2018) comparam algoritmo de otimização de baleia, algoritmo de libélula e algoritmo de otimização de mariposa para identificar as localizações e dimensionamentos ótimos de GD em sistema radial de distribuição para minimização das perdas de potência.

De forma geral, AL pode ser resumido assim:

1. Geração aleatória da população inicial de n libélulas e avaliação delas a partir do cálculo da função objetivo;
2. Atualização da fonte de comida (melhor solução) e inimigo (pior solução);
3. Atualização dos pesos de separação, alinhamento, coesão, fatores de comida e inimigo;
4. Cálculo da separação, alinhamento, coesão, atração por comida e distração do inimigo;
5. Atualização do raio de vizinhança;
6. Teste se uma libélula tem ao menos uma libélula vizinha e atualizar vetores de velocidade e posição;
7. Verificação e correção das novas posições baseada nos limites da variáveis;
8. Se o critério de parada for atingido, o processo é concluído. Caso contrário, retorna-se à etapa 2.

Assim como BC, AL conta com a vantagem de ter poucos parâmetros a serem ajustados pelo usuário, uma vez que os pesos são autoajustados repetidamente ao longo da execução do algoritmo.

4. APLICAÇÃO

4.1 Dados e Hipóteses

A fim de comparar os três métodos de otimização apresentados na seção anterior para resolver o problema da localização ótima de GD, o sistema de 400 barras encontrado em Pereira (2009) foi selecionado, por ser um sistema de grande porte real. Se trata de uma rede primária da cidade de Indiana (SP), operando na tensão nominal de 11,4 kV, com características de rede mista (urbana e rural).

Os primeiros testes têm o intuito apenas de determinar a localização ótima dos geradores. São considerados instalar 3, 6 e 9 geradores de potências nominais fixas. A potência nominal instalada foi escolhida mediante o critério do nível de penetração da GD. Em todos os casos, a capacidade total a ser instalada em GD se limitou a 20% da carga instalada.

4.2 Detalhes dos Algoritmos de Otimização

Para que a comparação, que é o propósito deste trabalho nos dois primeiros estudos de caso, seja completamente isenta, os

Tabela 1. Valores dos parâmetros dos algoritmos nos três estudos de caso

Algoritmo	Parâmetro	Caso I	Caso II	Caso III
AG	Tamanho da população	80	100	120
	Tipo de cruzamento	Ponto único	Ponto duplo	Ponto duplo
	Taxa de cruzamento	80%	70%	70%
	Taxa de mutação	10%	10%	10%
	Número de gerações	100	250	700
BC	Número de ninhos	80	100	120
	Probabilidade de descobrimento	35%	35%	50%
	Número de gerações	100	200	700
BL	Número de libélulas	80	100	120
	Número de iterações	100	250	800

parâmetros comuns às três metaheurísticas são os mesmos para:

- tipo de codificação das soluções: decimal;
- soluções iniciais (população, ninhos ou libélulas no início de cada execução);
- número de soluções por iteração (cromossomos em AG, ninhos em BC e libélulas em AL);
- critério de parada: número máximo de iterações.

Os parâmetros próprios de cada algoritmo são mostrados na tabela 1 e foram escolhidos por experimentação, mediante testes, até os melhores valores serem encontrados para cada um dos casos.

Embora o sistema seja grande, a codificação em alfabeto decimal permite a solução ser registrada em um vetor pequeno, de comprimento igual ao número de geradores a serem instalados na rede. O valor do k -ésimo elemento do vetor-solução é o número da barra em que o k -ésimo gerador é instalado.

A ordem dos geradores é qualquer, porém previamente estabelecida. Por exemplo, para o problema de se instalar dois geradores de 50 kW, três de 100 kW e um de 200 kW, uma solução possível seria a que é mostrada na figura 1. Tal solução seria instalar os geradores de 50 kW nas barras 203 e 98, os de 100 kW nas barras 323, 200 e 283, e o de 200 kW na barra 154.

Como os três métodos de otimização contam com componentes aleatórias, os resultados não serão sempre os mesmos. Portanto, cada algoritmo foi executado vinte vezes para solucionar o problema tratado em cada um dos casos estudados.

1	2	3	4	5	6
203	98	323	200	283	154
50 kW	50 kW	100 kW	100 kW	100 kW	200 kW

Fig. 1 Uma solução possível para o problema de localização de geradores em rede de distribuição

4.3 Resultados do Caso I

Para o primeiro caso, três geradores de potências nominais iguais a 100 kW, 200 kW e 300 kW devem ser localizados. O espaço de busca corresponde a combinação de 400 elementos, 3 a 3: um total de 10.586.800 soluções possíveis. Os resultados são apresentados na tabela 2, cuja coluna mais à direita é dos tempos médios de execução de cada algoritmo, dado em segundos. Como se vê, os três métodos tiveram eficácia, pois resolveram muito bem o problema de planejamento.

Tabela 2. Perdas totais de potência ativa com a localização ótima de 3 geradores (caso I)

Método	Média (kW)	Desvio Padrão (kW)	Menor valor (kW)	Maior valor (kW)	Tempo (s)
AG	86,898	0,0101	86,890	86,93	73,5
AL	86,900	0,0089	86,890	86,929	66,5
BC	86,893	0,0028	86,890	86,898	71,2

O sistema sem geração distribuída tem perdas de potência ativa totais iguais a 142,8 kW. As soluções ótimas encontradas correspondem a reduções de perdas da ordem de 39%. A solução ótima obtida por todos os algoritmos foi instalar os geradores de 100 kW, 200 kW e 300 kW nas barras 366, 390 e 334, respectivamente, levando a perdas iguais a 86,89 kW.

Apesar de todos os algoritmos terem encontrado a mesma solução ótima, é possível afirmar que AG e AL são equivalentes para o primeiro caso e o melhor algoritmo é o da Busca Cuco, pois apresentou os menores valores de média e de desvio padrão dos valores da função objetivo, nas soluções encontradas. Mesmo no critério do tempo de processamento, que não é o principal em aplicações desta natureza, a Busca Cuco teve desempenho intermediário entre os concorrentes. As curvas de convergência para uma execução dos três algoritmos são mostradas na figura 2.

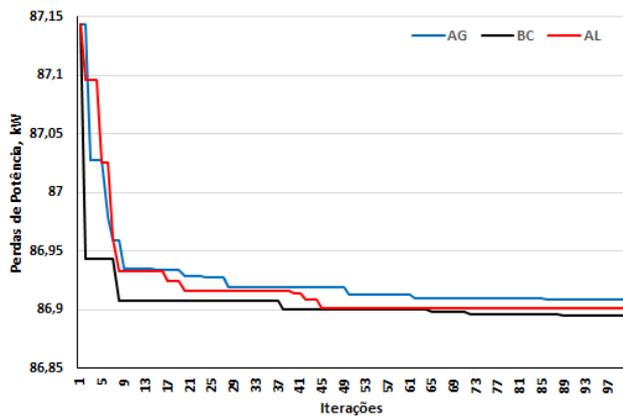


Fig. 2 Curvas de convergência de uma execução dos algoritmos para o caso I.

Além da redução das perdas de potência, a inserção de GD melhora consideravelmente o perfil de tensão do sistema, como pode ser visto na figura 3. Observa-se que o sistema sem GD tinha tensões abaixo do aceitável (0,95 pu) e, após a instalação de GD, as tensões em todas as barras passaram a ter níveis adequados.

4.4 Resultados do Caso II

O segundo estudo de caso corresponde a localizar seis geradores, dois de 50 kW, três de 100 kW e um de 200 kW. Para tal situação o espaço de busca aumenta consideravelmente: $5,5 \cdot 10^{12}$ possíveis soluções. As soluções encontradas são mostradas na figura 4.

Neste caso, os três algoritmos encontraram soluções que levam à mesma redução de perdas, da ordem de 39%.

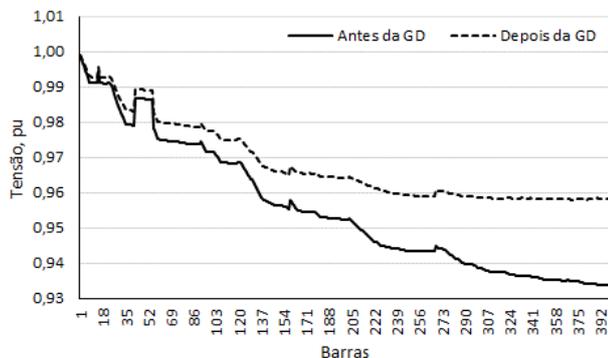


Fig. 3 Perfil de tensão antes e depois da inserção de 3 GD.

método	1	2	3	4	5	6	ΔP , kW
AG	316	373	366	382	399	334	86,800
BC	337	382	365	373	398	325	86,805
AL	314	366	373	382	399	334	86,803
	50 kW	50 kW	100 kW	100 kW	100 kW	200 kW	

Fig. 4 Soluções do problema de localizar 6 geradores na rede de distribuição de 400 barras (caso II).

método	1	2	3	4	5	6	7	8	9	ΔP , kW
AG	330	339	315	382	392	399	366	373	334	86,782
BC	330	339	316	363	366	373	382	399	334	86,783
AL	375	381	316	339	373	382	366	399	334	86,784
	25 kW	25 kW	50 kW	50 kW	50 kW	50 kW	100 kW	100 kW	150 kW	

Fig. 5 Soluções do problema de localizar 9 geradores na rede de distribuição de 400 barras (caso III).

Tabela 3. Perdas totais de potência ativa com a localização ótima de 6 geradores (caso II)

Método	Média (kW)	Desvio Padrão (kW)	Menor valor (kW)	Maior valor (kW)	Tempo (s)
AG	86,818	0,010	86,800	86,845	116,9
AL	86,823	0,013	86,803	86,842	115,35
BC	86,815	0,005	86,805	86,824	134

A tabela 3 é a síntese dos resultados encontrados empregando-se os três algoritmos. Os resultados foram muito semelhantes e é possível concluir que AG e BC foram os mais adequados para o problema pois AG encontrou o menor valor da função objetivo em menor tempo e BC obteve o menor valor médio e menor desvio padrão da função objetivo. AL encontrou um valor mínimo quase tão bom quanto AG mas obteve maiores valores de média e desvio padrão que os demais algoritmos.

4.5 Resultados do Caso III

No último caso comparativo, referente à localização de nove geradores, o número de soluções possíveis é $6,6 \cdot 10^{17}$. Espaço de busca tão grande, faz com que o número máximo de iterações, que foi o critério de parada adotado nos casos anteriores, seja elevado. Para evitar que o processo seja demasiadamente demorado, um segundo critério foi usado, de modo que a execução finda quando o primeiro deles é alcançado. Este segundo critério é a homogeneidade do conjunto de soluções corrente. Ou seja, se o desvio padrão da *fitness* das soluções for inferior a uma tolerância especificada, antes de atingir o número máximo de iterações, a execução é finalizada.

A solução ótima para o problema é mostrada na figura 5 e o resumo dos resultados encontrados pelos três algoritmos estão na tabela 4.

Os valores mínimos encontrados foram muito próximos, sendo que BC alcançou média e desvio padrão menores do que AG e AL em um tempo um pouco mais elevado. Ainda assim, é possível concluir que BC se mostrou mais adequado, pela homogeneidade das soluções encontradas.

Por fim, a tabela 5 é a comparação das perdas de potência e das tensões nas barras para os três casos estudados, além do caso base sem geração distribuída.

método	Barras			Geradores			ΔP , kW
BC	246	304	367	16	36	48	63,72

Fig. 6 Solução do problema completo do planejamento da geração distribuída.

Tabela 4. Perdas totais de potência ativa com a localização ótima de 9 geradores (caso III)

Método	Média (kW)	Desvio Padrão (kW)	Menor valor (kW)	Maior valor (kW)	Tempo (s)
AG	86,791	0,005	86,782	86,799	392,8
AL	86,804	0,019	86,784	86,873	461,2
BC	86,787	0,001	86,783	86,789	550,1

Tabela 5. Comparação entre os três casos estudados

Caso	Perdas de potência (kW)	Tensão mínima (pu)	Tensão máxima (pu)
Base	142,770	0,9338	0,9988
I	86,890	0,9579	0,9991
II	86,800	0,9581	0,9991
III	86,782	0,9581	0,9991

As perdas de potência e as tensões praticamente não se alteraram à medida que a capacidade de geração instalada foi sendo mais distribuída. De todo modo, as alterações, embora pouco significativas são como esperadas: com maior número de geradores a redução das perdas aumentam e a tensão mínima se eleva.

4.6 Localização e Dimensionamento Ótimos de GD

Como a BC encontrou em todos os casos, soluções nas quais as perdas foram, em média, menores e com menor desvio padrão, ele pode ser eleito como o melhor dos três algoritmos comparados.

Nesta seção se resolve o problema do planejamento da geração distribuída completo, que compreende a localização e o dimensionamento ótimos de GD, aplicando-se o método da BC e fazendo-se as seguintes considerações:

- O número de geradores a serem instalados é igual a três.
- A potência nominal máxima dos geradores distribuídos é aproximadamente 30% da carga total instalada, o que corresponde a 1MW.
- As potências dos geradores são de valores múltiplos de 10 kW.
- As restrições de tensão continuam as mesmas. Ou seja, as tensões em todas as barras $i, \forall i = 1, 2, \dots, n$ é V_i tal que $0,95 \text{ p. u.} \leq V_i \leq 1,05 \text{ p. u.}$

- Os parâmetros da BC são: probabilidade de descobrimento de 50%, número de ninhos igual a 80 e número máximo de iterações igual a 500.

A solução ótima encontrada por BC foi instalar geradores de 160 kW, 360 kW e 480 kW nas barras 246, 304 e 367, respectivamente, conforme a figura 6. Assim, as perdas totais de potência ativa são reduzidas em 55,37%, ficando em 63,72 kW.

5. CONCLUSÃO

Para fins comparativos, o problema da localização ótima de geradores distribuídos em rede de distribuição de grande porte para minimização das perdas totais de potência ativa foi resolvido mediante três metaheurísticas reconhecidas na literatura. Os algoritmos de busca Cuco e genético obtiveram melhores resultados que o algoritmo de libélula, sendo que BC ainda se mostrou melhor que AG por ter encontrado soluções para as quais os valores da função objetivo foram menores, em média, e menos dispersos, ou seja, de desvio padrão menor.

Os parâmetros dos algoritmos têm forte influência no desempenho do método de otimização. Portanto, a qualidade dos resultados encontrados, muitas vezes, depende da experiência do usuário em escolher os valores de tais parâmetros. Neste quesito, as metaheurísticas BC e AL são melhores que a AG, pois tem poucos parâmetros a serem ajustados.

Para o primeiro caso estudado, de menor porte, foi possível comprovar por meio da busca exaustiva que a solução encontrada pelos algoritmos de otimização era o ótimo global do problema. A mesma conclusão não foi estendida para os outros estudos de caso porém com o grande número de execuções é provável que se tenha chegado ao ótimo global ou muito próximo.

Por fim, o problema foi estendido ao dimensionamento ótimo dos geradores, sendo resolvido apenas por BC por ter sido o melhor algoritmo testado. É perceptível que o problema se torna ainda maior, uma vez que o espaço de busca cresce ainda mais. No entanto, o torna mais realista, na medida em que além da localização dos geradores, em problemas práticos, é preciso saber suas capacidades para que o objetivo seja atendido.

Como o foco do presente trabalho é a aplicação de métodos de otimização ao planejamento da geração distribuída, o modelo de carga utilizado foi bastante simplificado. Além disso, as fontes renováveis de energia são uma realidade nas redes de distribuição, tais fontes são de natureza intermitentes. Sendo assim, para dar continuidade ao trabalho é interessante incorporar a aleatoriedade da demanda de carga e também da geração de energia, a fim de dotar o problema de maior nível de realidade.

REFERÊNCIAS

- Abdmouleh, Z., Gastli, A., Ben-Brahim, L., Haouari, M. e Al-Emadi, N. A. (2017). Review of optimization techniques applied for the integration of distributed generation from renewable energy sources. *Renewable Energy*, volume (113), 266-280.
- Alencar, M. R. B., Souza, J. S., Souza, B. A. e Neves, W. L. A. (2018). Estimação de onde instalar painéis fotovoltaicos para aumentar a eficiência energética de redes elétricas. *XXII Congresso Brasileiro de Automática*.

- Arulraj, R. e Kumarappan, N. (2018). Simultaneous multiple DG and capacitor installation using dragonfly algorithm for loss reduction and Loadability improvement in distribution system. (2 *2018 International Conference on Power, Energy, Control and Transmission Systems (ICPECTS)*).
- Buaklee, W. e Hongesombut, K. (2013). Optimal DG allocation in a smart distribution grid using cuckoo search algorithm. *IEEE Conference on Electrical Computer Telecomm and Information Technology*, 1-6.
- Coelho, F. C. R., Da Silva Junior, I. C., Dias, B. H., Peres, W. B. (2017). Optimal Distributed Generation Allocation Using a New Metaheuristic. *Journal of Control, Automation and Electrical Systems*, volume (29), 91-98.
- Ehsan, A. e Yang, Q. (2018). Optimal integration and planning of renewable distributed generation in the power distribution networks: a review of analytical techniques. *Applied Energy*, volume (210), 44-59.
- EPE [Empresa de Pesquisa Energética] (2017). Plano decenal de expansão de energia 2026. Disponível em: <http://www.epe.gov.br/pt/publicacoes-dados-abertos/publicacoes/Plano-Decenal-de-Expansao-de-Energia-2026>. Acesso em: 02 de junho de 2020.
- Evangelopoulos, V. A. e Georgilakis, P. S. (2014). Optimal distributed generation placement under uncertainties based on point estimate method embedded genetic algorithm. *IET Generation, Transmission & Distribution*, 389-400.
- Ganguly, S. e Samajpati, D. (2015). Distributed Generation Allocation on Radial Distribution Networks Under Uncertainties of Load and Generation Using Genetic Algorithm. *IEEE Transaction on Sustainable Energy*, volume (6), número (3), 688-697.
- Gianelloni, F., Dantas, G.D.A., Alves, J.F., De Castro, N. e Pereira, P. (2017). The distributed electricity generation diffusion impact on the Brazilian distribution utilities. *3rd International Conference on Energy and Environment: bringing together Engineering and Economics*.
- Khoa, T. H., Nallagownden, P., Baharudin, Z. e Dieu, V. N. (2017). One rank cuckoo search algorithm for optimal placement of multiple distributed generators in distribution networks. *2017 IEEE Region 10 Conference (TENCON)*.
- Kramer, O. (2017). *Genetic algorithm essentials*, volume (679). Springer, Cham, Switzerland.
- Mirjalili, S. (2015). Dragonfly algorithm: a new meta-heuristic optimization technique for solving single-objective, discrete, and multi-objective problems. *Neural Comput & Applic.*, 1-21.
- Ouaarab, A., Ahiod, B. e Yang, X-S. (2014). Discrete cuckoo search algorithm for the travelling salesman problem. *Neural Comput & Appl.*, volume (24), 1659-1699.
- Pereira, C. A. N. (2009). Alocação ótima de reguladores de tensão em redes de distribuição de energia elétrica. Dissertação de Mestrado. Universidade Estadual de Campinas.
- Pesaran, H. A. M., Huy, P. D. e Ramachandaramurthy V. K. (2017). A review of the optimal allocation of distributed generation: objectives, constraints, methods, and algorithms. *Renewable and Sustainable Energy Reviews*, volume (75), 293-312.
- Prakash, P. e Khatod, D. K. (2016). Optimal sizing and siting techniques for distributed generation in distribution systems: a review. *Renewable and Sustainable Energy Reviews*, volume (57), 111-130.
- Saleh, A., Mohamed, A., Hemeida, A. e Ibrahim, A. (2018). Comparison of different optimization techniques for optimal allocation of multiple distribution generation. *2018 International Conference on Innovative Trends in Computer Engineering (ITCE)*.
- Suresh, M. C. V. e Belwin, E. J. (2018). Optimal DG placement for benefit maximization in distribution networks by using dragonfly algorithm. *Renewables: Wind, Water, and Solar*, volume (5), número (4).
- Swief, R. A., Abdel-Salam, T. S. e El-Amary, N. H. (2018). Photovoltaic and wind turbine integration applying Cuckoo search for probabilistic reliable optimal placement. *Energies*, volume (11), número (139).
- Yang, X-S. e Deb, S. (2009). Cuckoo search via Lévy Flights. *Proceeding of the World Congress on Nature & Biologically Inspired Computing (NaBIC 2009)*.