

# Alocação de Geradores Distribuídos em Sistemas de Distribuição de Energia Elétrica Utilizando Algoritmo GRASP-VNS

Bruno A. R. Silva, Wilington G. Zvietcovich, Francisco R. A. C. Baracho, Laerty J. S. Damião, Laura F. Souza

*Departamento de Engenharia Elétrica, Universidade Federal de Ouro Preto,  
João Monlevade, Minas Gerais, Brasil*

*(bruno.rosa@aluno.ufop.edu.br, wilington@ufop.edu.br, f\_baracho@ufop.edu.br, laerty.damiao@aluno.ufop.edu.br,  
laura.souza1@aluno.ufop.edu.br)*

---

**Abstract:** This paper presents the implementation of the meta-heuristics Greedy Randomized Adaptive Search Procedure (GRASP) and Variable Neighborhood Search (VNS) for the optimal allocation of Distributed Generators (DGs) in radial distribution systems, aiming at reducing power losses and simultaneously improving voltage levels. In this methodology, the GRASP algorithm is used to build possible solutions to the problem, while the VNS is applied to a local search stage, in which a refinement is made in the solution space to improve the convergence of the search process. To validate the technique, the algorithm was used to allocate DGs in the IEEE 33-bus and 135-bus distribution systems. Thus, from the results obtained, it was possible to verify the effectiveness of the methodology in finding good quality solutions with minimal power losses and considerable improvements in the voltage profiles.

**Resumo:** Este trabalho apresenta a implementação das meta-heurísticas, *Greedy Randomized Adaptive Search Procedure* (GRASP) e *Variable Neighborhood Search* (VNS) para a alocação ótima de Geradores Distribuídos (GDs) e seu dimensionamento em redes de distribuição com operação radial, visando a redução das perdas elétricas ativas e, simultaneamente, à melhoria dos níveis de tensão. Nesta metodologia, o algoritmo GRASP é utilizado para a construção de possíveis soluções do problema, enquanto o VNS se aplica à uma etapa de busca local, na qual realiza-se um refinamento no espaço de soluções para aprimorar a convergência do processo de busca. Para validação da técnica, a metodologia foi aplicada em duas redes, uma de 33 barras do IEEE e outra de 135 barras. Dos resultados obtidos, pôde-se verificar a eficácia da metodologia em encontrar soluções de boa qualidade com perdas mínimas e consideráveis melhorias nos perfis de tensão.

**Keywords:** Distributed Generators; Distribution Systems; GRASP; Optimization; VNS.

**Palavras-chaves:** Geradores Distribuídos; GRASP; Otimização; Sistemas de Distribuição; VNS.

---

## 1. INTRODUÇÃO

No Brasil, a maior parte da produção de energia elétrica é tradicionalmente obtida a partir de grandes plantas de geração, distante dos centros de consumo, que fazem parte de um sistema unidirecional da extra-alta e alta tensão para a média e baixa tensão. Entretanto, com o desenvolvimento das tecnologias das fontes renováveis, atrelado às políticas do mercado de energia elétrica, tem-se, aos poucos, viabilizado um novo modelo de geração, conhecido como geração distribuída.

Neste modelo, parte da energia elétrica é gerada e entregue a clientes através de pequenas unidades de geração alocadas próximas aos usuários finais, de modo que os geradores distribuídos (GDs), normalmente pequenas centrais hidroelétricas, parques eólicos ou fotovoltaicos, possam ser aplicados de forma isolada, suprimindo a demanda local de um consumidor específico, ou de forma integrada, fornecendo energia para à rede elétrica (Ha et al., 2017). Desse modo, a

aplicação de pequenos geradores, conectados diretamente ao Sistema de Distribuição de Energia Elétrica (SDEE), pode ser suficiente para atender a demanda de consumo de uma determinada região ou grupo de consumidores.

De acordo com (Gopiya-Naik et al., 2012), a operação de GDs pode afetar a operação de um SDEE de maneira benéfica e/ou prejudicial. Nesse contexto, são benefícios: suporte de reativos para melhoria da tensão; mitigação das perdas elétricas; redução de custos relacionados à transmissão, dentre outros. Por outro lado, pode-se destacar os seguintes pontos negativos: redirecionamento da coordenação de proteção; prejuízos à estabilidade do sistema; injeção de harmônicos no SDEE, dentre outros.

Diante de todos esses impactos, sejam eles benéficos ou prejudiciais, vários trabalhos têm abordado a geração distribuída em SDEEs. Nesse sentido, pode-se verificar na literatura que alguns grupos tratam do impacto dos GDs na Qualidade da Energia Elétrica (QEE) (Lakshmi; Ganguly, 2018; Abubakar et al., 2019); enquanto outros buscam

desenvolver modelos matemáticos para representar GDs de diferentes tipos (por exemplo, eólicos, fotovoltaicos e biomassa) (Gupta, 2016; He et al., 2018). Já outros grupos visam implementar e desenvolver técnicas para definir os melhores locais de instalação de um gerador distribuído (Raut; Mishra, 2020; Sambaiah; Jayabarathi, 2020).

A respeito deste último grupo, no qual se insere este trabalho, muitos avanços são alcançados por meio da aplicação de técnicas de otimização para solucionar problemas de natureza combinatória, com destaque para as heurísticas. Embora os métodos heurísticos sejam intuitivos e simples de implementar, em comparação com métodos de programação numérica, os resultados produzidos por algoritmos heurísticos não são garantidos para serem ótimos (Ng et al, 2000). Surgem assim as técnicas meta-heurísticas para aplicações em problemas de maior complexidade.

Por exemplo, em (Lopez et al., 2019), as técnicas *Tabu Search*, *Scatter Search* e *Ant Colony Algorithm* foram aplicadas e avaliadas para a alocação de GDs em SDEEs radiais, com o objetivo de reduzir as perdas ativas. Os autores indicam a aplicabilidade e o desempenho dessas técnicas no problema em questão. Em (Truong et al, 2019), um novo algoritmo, baseado na meta-heurística *Symbiotic Organisms Search* (SOS), foi implementado para determinar a quantidade, a localização e o dimensionamento ótimo de DGs de SDEEs radiais, de modo a reduzir as perdas elétricas ativas. Já em (Ahmed et al, 2020) utilizou-se um algoritmo recentemente proposto, chamado *Salp Swarm Algorithm* (SSA), para otimizar a alocação de GDs eólicos. Para isso, foram considerados parâmetros relacionados a desvio de tensão, perdas e estabilidade. De acordo com os autores, o SSA tem funcionado de modo eficiente em termos de tempo computacional e características de convergência.

Neste contexto, no presente trabalho se desenvolve uma metodologia híbrida para alocar GDs em um SDEE de modo a minimizar os valores de perdas ativas e melhorar os níveis de tensão. Estas técnicas são a meta-heurística GRASP (do inglês: *Greedy Randomized Adaptive Search Procedure*) e o VNS (do inglês: *Variable Neighborhood Search*). Ambas técnicas têm sido amplamente utilizadas para resolver problemas de otimização combinatória em várias áreas do conhecimento (Feo; Resende, 1995; Loudni; Boizumault, 2008). A metodologia foi validada utilizando duas redes elétrica, uma de 33 barras, do IEEE, e outra de 135 barras.

## 2. FORMULAÇÃO DO PROBLEMA

### 2.1 Alocação de Geradores Distribuídos

A operação de GDs utilizando diferentes tecnologias, neste trabalho gerador tipo PV (Palma et al, 2010), impacta índices de operação das SDEE, mais especificamente as perdas elétricas ativas e os níveis de tensão. Dependendo da sua alocação (barra instalada) e de seu dimensionamento (potência gerada) estes valores mudam. Por exemplo, para o SDEE mostrado na Fig. 1, que tem um GD instalado na barra 7 e opera com potência de geração igual a 400kW, tem-se uma perda na rede de 150kW com tensão mínima de 0,93 p.u. Este

mesmo gerador é conectado na barra 27 trazendo perdas de 170kW e tensão mínima de 0.90 p.u. Ainda mais, considerando que o valor da potência pode alterar, as possibilidades tanto de mudança de barra, quanto de valor de potência gerada traz uma elevada combinação de soluções, o que caracteriza este problema.




Fig. 1 SDEE radial com GD alocada na barra 7.

A respeito das melhorias proporcionadas ao SDEE, vale ressaltar, no entanto, que elas obedecem a uma relação não-linear, de modo que aumentos significativos da potência gerada por GDs poderiam não ser viáveis na operação do sistema. Na Fig. 2, observa-se uma curva de geração de uma GD conectada a um SDEE. Na medida em que se incrementa a potência gerada, as perdas se reduzem, até alcançar um valor mínimo (valor máximo de potência gerada igual a 1150 kW). A partir deste ponto, as perdas aumentam, tornando inviável o incremento desta potência.

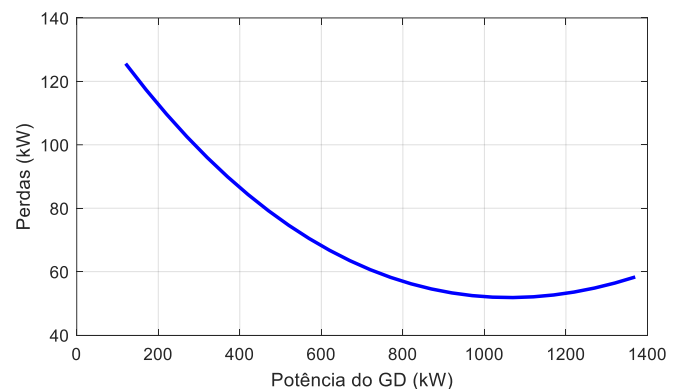


Fig. 2 Relação Potência do GD vs. Perdas, considerando alocação na barra 7 do sistema mostrado na Fig. 1.

Diante dos impactos mencionados, da complexidade dos SDEEs, das limitações de potência gerada e das restrições de operação, estabelece-se, portanto, o problema da alocação de GDs. Dessa forma, em virtude do elevado número de possíveis soluções e da necessidade de encontrar a melhor delas, visando reduzir as perdas elétricas e melhorar o perfil de tensão, verifica-se que tal problema se enquadra dentro da programação inteira mista (Wang et al., 2014), sendo resolvido de forma eficiente por métodos de otimização computacional.

### 2.2 Formulação Matemática da Função Objetivo

Neste trabalho, o problema de alocação foi resolvido visando a redução das perdas ativas e a elevação do perfil de tensão.

Para isso, tem-se no modelo o seguinte sistema de equações e inequações:

$$\min F = w_1 \times f_1 + w_2 \times f_2 \quad (1)$$

onde:

$$w_1 = 0,7; \quad w_2 = 0,3 \quad (2)$$

$$f_1 = \sum_{l=1}^{nl} RI^2, \quad nl = \text{total de linhas} \quad (3)$$

$$f_2 = \frac{1}{\min(V_{\text{barras}})} \quad (4)$$

Sujeito a:

- Capacidade dos alimentadores:

$$I_{\min} < I_{in} < I_{\max} \quad (5)$$

- Capacidade das subestações:

$$I_{\min} < I_{sub} < I_{\max} \quad (6)$$

- Capacidade dos GDs:

$$P_{GD,\min} < P_{GD} < P_{GD,\max} \quad (7)$$

- Equações de fluxo de potência:

$$P_T = \sum_{(k,m) \in \Omega} R_{km} I_{km}^2 \quad (8)$$

$$Q_T = \sum_{(k,m) \in \Omega} X_{km} I_{km}^2 \quad (9)$$

$$\begin{bmatrix} \Delta P \\ \Delta Q \end{bmatrix} = \begin{bmatrix} H & N \\ M & L \end{bmatrix} \cdot \begin{bmatrix} \Delta \delta \\ \Delta V/V \end{bmatrix} \quad (10)$$

- Níveis de tensão nas barras:

$$V_{\min} < V_k < V_{\max} \quad (11)$$

onde:

$V_{\min}$ : tensão mínima de barra;

$V_{\max}$ : tensão máxima de barra;

$V_k$ : tensão na barra  $k$ ;

$P_{GD,\min}$ : potência nominal mínima de uma GD;

$P_{GD,\max}$ : potência nominal máxima de uma GD;

$P_{GD}$ : potência nominal de uma GD;

$P_T$ : potência ativa total do sistema;

$Q_T$ : potência reativa total do sistema;

$R_{km}$ : resistência da linha entre as barras  $k$  e  $m$ ;

$X_{km}$ : reatância da linha entre as barras  $k$  e  $m$ ;

$I_{km}$ : corrente na linha entre as barras  $k$  e  $m$ ;

$\Omega$ : conjunto de barras presente na rede elétrica;

$I_{\min}$ : Capacidade mínima de corrente suportada pelos alimentadores ou subestação;

$I_{\max}$ : Capacidade máxima de corrente suportada pelos alimentadores ou subestação;

$I_{sub}$ : corrente da subestação;

$I_{in}$ : corrente do alimentador;

$H, N, M, L$ : componentes da matriz jacobiana;

$\Delta \delta$ : variação do ângulo das tensões;

$\Delta V$ : variação da tensão das barras;

$\Delta P$ : variação da potência ativa demandada das barras;

$\Delta Q$ : variação da potência reativa demandada das barras.

### 3. METODOLOGIA DE OTIMIZAÇÃO

Para resolver o problema de alocação e dimensionamento de GDs em um SDEE, foram utilizada uma metodologia híbrida, com a utilização de duas técnicas meta-heurísticas, com a finalidade de aumentar a eficiência na busca das melhores soluções.

A primeira técnica é o GRASP (Feo; Resende, 1989), um algoritmo iterativo que consiste em duas etapas: (i) construção de uma solução; e (ii) busca local. A fase de construção é caracterizada por um algoritmo do tipo guloso, que possui uma componente aleatória e adaptativa. Já a fase de busca local é realizada para encontrar melhores resultados comparados com a solução obtida na primeira fase.

A segunda meta-heurística é o VNS (Mladenović; Hansen, 1997), que consiste em uma técnica baseada em um processo de trocas sistemáticas de parâmetros através de estruturas de vizinhança dentro do espaço de soluções, com a finalidade de encontrar soluções ótimas locais e, a partir de mudança de estruturas de vizinhanças, sair destes soluções locais, procurando a solução ótima global. A forma de transitar nas estruturas de vizinhança gera diferentes algoritmos próprios do VNS, sendo aplicado neste trabalho o *Basic VNS* (Mladenović, Hansen, 1997).

#### 3.1 Implementação

##### 3.1.1 Representação de uma Solução

A solução para o problema de Alocação de GDs é representada por uma matriz  $m \times 2$ , onde  $m$  é número de GDs. A Fig. 3 ilustra um exemplo para  $m = 2$ .

	Barra de Alocação	Potência Gerada (kW)
Solução i =	11	300
	25	250

Fig. 3 Representação de uma solução.

##### 3.1.2 Avaliação da Função Objetivo

A avaliação da função objetivo é realizada para cada solução determinada no processo de otimização da metodologia híbrida GRASP-VNS, visando quantificar a qualidade desta solução. Para isso, executa-se uma análise de fluxo de potência que, neste trabalho, utiliza o método de Newton Raphson (Grainger; Stevenson, 1994) para, em seguida, aplicar a eq. (1) e suas restrições.

### 3.1.3 Critério de Parada

Para o algoritmo GRASP, utilizou-se como critério de parada o número de soluções geradas na etapa de construção de soluções. Já para o VNS, ou seja, para a etapa de busca local, adotou-se como critério o número máximo de visitas em cada estrutura de vizinhança.

### 3.1.3 Procedimentos do algoritmo GRASP-VNS

A implementação do GRASP, pode ser dividida em três etapas, conforme descrito a seguir (Oliveira, 2011):

#### Procedimentos para implementação do GRASP

**1ª Etapa:** Leitura dos dados do problema e obtenção da solução inicial;

1.  $f^* \leftarrow \infty; x^* \leftarrow \emptyset;$
2. Ler os dados do problema;
3. **Para**  $k = 1, \dots, MaxIter$ , **faça:**

**2ª Etapa:** Realizar a construção de uma solução utilizando componentes aleatórias (fase de construção)

4.  $\alpha = rand(0-1).$
5. **Se**  $\alpha < 0,5$  **faça:**
6. Construir uma solução  $x$  de forma aleatória.
7. **Senão:**
8. Construir uma solução  $x$  de modo aleatório-guloso.
9. **Fim se**

**3ª Etapa:** Realizar uma melhoria da solução encontrada na fase construtiva.

10. **Para**  $k = 1, \dots, MaxIter$ , **faça:**
11. Encontrar  $y$  aplicando busca local a  $x$  (fase de busca local);
12. **Se**  $f(y) < f^*$ , **então**
13.  $x^* \leftarrow y, f^* \leftarrow f(y);$
14. **Fim se**
15. Retorna  $x^*$

#### FIM GRASP

Na primeira etapa, é realizada a leitura dos dados do problema e, em seguida, na segunda etapa, determina-se aleatoriamente um parâmetro  $\alpha$  que varia entre 0 e 1. Para  $\alpha < 0,5$ , tem-se um indicador totalmente aleatório. Caso contrário, tem-se um indicador Aleatório-Guloso.

**Aleatório:** Escolhe aleatoriamente a barra na qual estará alocada o GD. Em seguida, constroi-se a capacidade de geração do GD (ver Fig. 2) e sorteia-se aleatoriamente na faixa viável de potência um valor. Atribui-se tal valor à GD.

**Aleatório-Guloso:** Utiliza-se um critério de sensibilidade de tensão (VSI) para alocação do GD (Subrahmanyam; Radhakrishna, 2009) injetando o valor da capacidade máxima na barra  $j$  e aplicando a seguinte equação.

$$VSI_j = \sqrt{\frac{\sum_{i=1}^n (1-V_i)^2}{n}} \quad (12)$$

Onde,  $V_i$  é a tensão no  $i$ -ésimo nó e  $n$  é o número de nós. Em seguida, aloca-se o GD de forma aleatória considerando as barras com menor  $VSI_i$ . Já para determinar a capacidade de geração do GD, escolhe-se aleatoriamente um valor na faixa viável de potência. Atribui-se tal valor à GD.

Na terceira etapa, é aplicada uma busca local com base na solução determinada na etapa anterior, utilizando o algoritmo VNS, cuja implementação do Basic VNS é descrita a seguir.

#### Procedimento para aplicação do VNS na busca local

**1ª Etapa:** Define-se  $k_{max} = 2;$

**2ª Etapa (agitação):** é gerada uma solução  $x'$  na  $k$ -ésima vizinhança de  $x$ , trocando-se  $k$  GDs de barras ou alterando-se as potências dos  $k$  GDs, observando a capacidade de geração da barra na qual a GD será instalada (ver Fig.02).

**3ª Etapa (busca local):** aplica-se uma busca local em torno de  $x'$ , alterando a barra ou a potência de um GDs aplicando o “**Critério de busca local**”. Desta forma, obtém-se a solução  $x''$  e avalia-se a função objetivo desta solução.

**4ª Etapa (mover ou não):** caso o valor da função objetivo da solução  $x''$  seja melhor que o valor da solução incumbente  $x$ ,  $x''$  passa a ser  $x$  e volta-se a  $k = 1$ . Caso contrário, continua-se a busca local (etapa 3) até atingir  $Maxvisitas$ , que é escolhido de acordo com o tamanho da rede. Atingindo o valor de  $Maxvisitas$ , faz-se  $k = k + 1;$

**5ª Etapa: Se**  $k_{max} \leq 2$ : volta ao passo 2; **Se não:** FIM VNS

**Critério de busca local:** Com a finalidade de guiar a busca para melhores soluções, foi utilizado um critério aleatório-determinístico, detalhado a seguir.

Para o caso de mudança de barra da GD constrói-se um vetor utilizando o índice de sensibilidade de tensão indicado em (12) e ordena-se de forma ascendente. Em seguida, sorteia-se uma barra no grupo dos 50% dos primeiros elementos do vetor. Já para o caso da mudança de valor de potência, constroi-se a curva de capacidade de potência na barra na qual o GD será realocado ou na barra atual (caso não ocorra realocação de barra) e sorteia-se um valor de potência na faixa de 50% a 100% da capacidade de potência.

Desta forma, a visita de soluções no espaço de busca procura soluções ótimas locais, saindo destas soluções através da troca de estrutura de vizinhança, em busca da solução ótima global.

## 4. RESULTADOS

Neste item, são apresentados os resultados obtidos aplicando a metodologia híbrida proposta. A implementação computacional foi realizada em ambiente Matlab™ considerando duas redes, uma de 33 barras, do IEEE (Baran; Wu, 1989), ilustrada na Fig. 4 e outra de 135 barras (Nascimento, 2005). O número de GDs a serem alocados, bem como a especificação dos critérios de parada do algoritmo são mostrados na Tabela 1.




Fig. 4 SDEE IEEE-33barras.

**Tabela 1. Parâmetros da metodologia.**

Parâmetros	33 barras	135 barras
Nº de GDs disponíveis	2	3
Nº de Soluções (GRASP)	10	20
Nº máximo de visitas na vizinhança $N_k$ (VNS)	$20 \times K$	$30 \times K$

A Tabelas 2 ilustra os resultados considerando dois patamares de operação para o sistema de 33 barras: normal (FC=1,0) e pesado (FC=1,3), onde FC é Fator de Carregamento. Assim, pode-se observar que a melhor solução encontrada para os dois patamares é igual, ao se tratar da barra de alocação dos GDs. As potências de geração, no entanto, são diferentes.

**Tabela 2. Resultados para o sistema IEEE-33 barras.**

Respostas	Barras de Alocação	Potência ativa dos GDs (kW)	Potência reativa dos GDs (kVAR)	Perdas elétricas (kW)	$ V _{min}$ p.u.	Nº de fluxos de potência
Cenário 1 (Fator de carregamento = 1,0)						
Sem GDs	--	--	--	202,677	0,9131	--
Solução aleatória	6; 9	500; 800	314,8; 383,56	117,776	0,9687	--
Melhor 1	13; 30	839; 1085	356,42; 500,22	28,6241	0,9801	1335
Melhor 2	10; 30	994; 1026	480,26; 447,31	29,06089	0,9806	1720
Melhor 3	14; 30	771; 1229	318,5; 335,85	29,35206	0,9801	1532
Cenário 2 (Fator de carregamento = 1,3)						
Sem GDs	--	--	--	359,823	0,884	--
Solução aleatória	6; 9	636; 1178	421,4; 338,7	186,859	0,959	--
Melhor 1	13; 30	1086; 1414	473,8; 650,3	48,776	0,974	1450
Melhor 2	14; 30	993; 1556	430,9; 500,6	49,345	0,974	1320
Melhor 3	10; 30	1296; 1315	626,9; 611,4	49,689	0,975	1334

Já para o sistema de 135 barras tem-se os resultados apresentados na Tabela 3, onde pode-se verificar que as três melhores soluções encontradas possuem valores de tensão iguais. Casos como esse flexibiliza ao operador do sistema elétrico a consideração de outros critérios para adotar alguma dessas soluções na operação do SDEE.

**Tabela 3. Resultados para o sistema 135 barras.**

Respostas	Barras de Alocação	Potência ativa dos GDs (kW)	Potência reativa dos GDs (kVAR)	Perdas elétricas (kW)	$ V _{min}$ p.u.	Nº de fluxos de potência
Cenário 1 (Fator de carregamento = 1,0)						
Sem GDs	--	--	--	320,278	0,931	--
Solução aleatória	4; 62; 103	2423; 482; 280	1103,8; 1061,3; 832,1	292,510	0,934	--
Melhor 1	11; 49; 106	1937; 2186; 2859	1080,3; 902; 545,2	144,788	0,971	996
Melhor 2	11; 27; 107	2197; 2062; 2719	956,5; 1063,1; 1003,9	145,370	0,971	1152
Melhor 3	14; 53; 107	2197; 1917; 2609	813,2; 1001,7; 1053,5	146,255	0,971	1037

Para ilustrar o perfil de tensão da rede de 135 barras foi gerada a Fig. 5, na qual se observa o impacto da GD quanto a elevação das tensões.




Fig. 5 Perfil de tensões no SDEE – 135 barras.

Com a finalidade de avaliar a sensibilidade da variação dos principais parâmetros da metodologia híbrida, foi construída a Fig. 6 para a rede de 135 barras. Cada círculo indica uma configuração desses valores. O tamanho do círculo, por sua vez, indica a convergência; quanto menor o tamanho, maior é a convergência para os resultados encontrados.




Fig. 6 Sensibilidade dos parâmetros da metodologia híbrida SDEE – 135 barras.

Outro parâmetro avaliado para esta rede é curva de redução de perdas elétricas no processo de otimização mostrada na Fig. 7, na qual se observa que a solução inicial (iteração 0) é gerada pela etapa 1 do GRASP. Os ganhos na redução de perdas obtêm-se na busca feita através do VNS, até encontrar a melhor solução (Melhor 1).

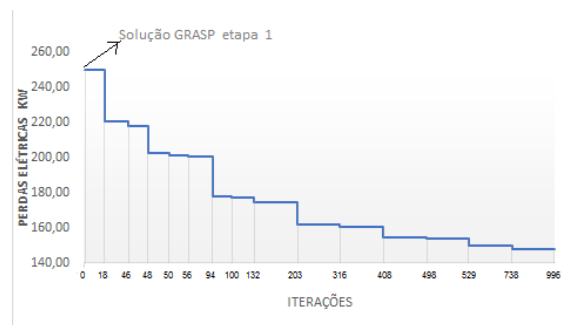


Fig. 7 Perfil de tensões no SDEE – 135 barras.

## 6. CONCLUSÕES

Neste trabalho se apresenta uma nova aplicação de uma metodologia híbrida GRASP-VNS para solucionar o problema de alocação ótima de GDs e seu dimensionamento, visando reduzir as perdas elétricas e melhorar os níveis de tensão em um SDEE.

A aplicação da metodologia híbrida representa uma ferramenta adicional para solucionar este problema, acrescentando na literatura.

A utilização do VNS na etapa de busca local do GRASP foi crucial para encontrar melhores resultados e sair de soluções ótimas locais através de estruturas de vizinhança.

Dos resultados obtidos, confere-se que a estimação de valores próprios dos parâmetros foi obtida através de testes e a sensibilidade destes faz encontrar outros resultados, características comuns nas técnicas meta-heurísticas.

Ainda com base nos resultados apresentados, afirma-se que a inserção de poucos GDs no SDEE traz ganhos, com redução de custos de perdas elétricas, e melhoramento de níveis de tensão.

Como trabalhos futuros, pretende-se fazer o estudo utilizando curvas de consumo associadas a medidores. Também será considerado o ambiente de cidades inteligentes, especificamente a existência de veículos elétricos.

## REFERÊNCIAS

- Abubakar, A.S., Olaniyan, A.A., Ibrahim, A., and Sulaiman, S.H. (2019). An improved analytical method for optimal sizing and placement of power electronic based distributed generation considering harmonic limits. In *2019 IEEE PES/IAS Power Africa*, 122–127. IEEE.
- Ahmed, A., Nadeem, M. F., Sajjad, I. A., Bo, R., and Khan, I. A. (2020). Optimal Allocation of Wind DG with Time Varying Voltage Dependent Loads Using Bio-Inspired: Salp Swarm Algorithm. In *2020 Intern. Conf. on Comp., Math. and Engineering Technologies*, 1-7. IEEE.
- Baran, M., Wu, F. (1989). Network reconfiguration in distribution systems for loss reduction and load balancing. *IEEE Transactions on Power Delivery*, v. 4, n. 2, p. 1401–1407. IEEE.
- Feo, T. A., and Resende, M. G. (1989). A probabilistic heuristic for a computationally difficult set covering problem. *Operations research letters*, 8(2), 67-71.
- Feo, T. A., and Resende, M. G. (1995). Greedy Randomized Adaptive Search Procedures. *Journal of Global Optimization*, 6, 109–133.
- Grainger, J., and Stevenson, S. *Power System Analysis*. (1994). McGraw-Hill.
- Gupta, N. (2016). Probabilistic load flow with detailed wind generator models considering correlated wind generation and correlated loads. *Renewable Energy*, 94,96–105.
- Ha, M.P., Huy, P.D., and Ramachandaramurthy, V. K. (2017). A review of the optimal allocation of distributed generation: Objectives, constraints, methods, and algorithms. *Renewable and Sustainable Energy Reviews*, 75,293–312.
- He, Y., Pang, Y., Li, X., and Zhang, M. (2018). Dynamic subsidy model of photovoltaic distributed generation in china. *Renewable energy*, 118, 555–564.
- Lakshmi, S. and Ganguly, S. (2018). Modelling and allocation of open-UPQC-integrated PV generation system to improve the energy efficiency and power quality of radial distribution networks. *IET Renewable Power Generation*, 12(5), 605–613.
- Lopez, L., Doria-Garcia, J., Pimienta, C., and Arango-Manrique, A. (2019). Distributed Generation Allocation and Sizing: A Comparison of Metaheuristics Techniques. In *2019 IEEE International Conference on Environment and Electrical Engineering and 2019 IEEE Industrial and Commercial Power Systems Europe*, 1-6. IEEE.
- Loudni, S., and Boizumault, P. (2008). Combining VNS with constraint programming for solving anytime optimization problems. *European J. of Oper. Res.*, v. 191 (3), 705-735.
- Mladenović, N., and Hansen, P. (1997). Variable neighborhood search. *Computers & operations research*, 24(11), 1097-1100.
- Nascimento Guimarães M. A. (2005). Reconfiguração de Sistemas de Distribuição de Energia Elétrica utilizando Algoritmos de Busca Tabu. *Dissertação de Mestrado*. UNICAMP.
- Ng, H.N., Salama, M.M.A., Chikhani, A.Y. (2000). Classification of capacitor allocation techniques. *IEEE Transactions on Power Delivery*, 15, 387–392.
- Oliveira, M. B. C. D. (2011). Reconfiguração de alimentadores em sistemas de distribuição usando a metaheurística GRASP.
- Raut, U. and Mishra, S. (2020). An improved sine-cosine algorithm for simultaneous network reconfiguration and DG allocation in power distribution systems. *Applied Soft Computing*, 106293.
- Sambaiah, K. S. and Jayabarathi, T. (2020). A survey on load/power flow methods and DG allocation using grasshopper optimization algorithm in distribution networks. In *Soft Comp. for Problem Solving*, 621-630.
- Subrahmanyam, J. B. V., and Radhakrishna, C. (2009). Distributed generator placement and sizing in unbalanced radial distribution system. *Intern. Journal of Electrical Power and Energy Systems Engineering*, 232-239.
- Truong, K. H., Nallagownden, P., Elamvazuthi, I., and Vo, D. N. (2019). An improved meta-heuristic method to maximize the penetration of distributed generation in radial distribution networks. *Neural Comp. and Applic.*, 1-23.
- Wang, Z., Chen, B., Wang, J., Kim J., Begovic, M. M. (2014). Robust Optimization Based Optimal DG Placement in Microgrids. *IEEE Transactions on Smart Grid*, 2173-2182.